

UNIVERSIDADE ESTADUAL PAULISTA
“Júlio de Mesquita Filho”

Pós-Graduação em Ciência da Computação

Fernando Pereira dos Santos

**Estudo comparativo de técnicas para segmentação e
classificação de imagens de lesões de pele**

UNESP

2016

Fernando Pereira dos Santos

**Estudo comparativo de técnicas para segmentação e
classificação de imagens de lesões de pele**

Orientador: Prof. Dr. Aledir Silveira Pereira

Dissertação de Mestrado elaborada junto ao Programa de Pós-Graduação em Ciência da Computação – Área de Concentração em Processamento de Imagens e Visão Computacional, como parte dos requisitos para a obtenção do título de Mestre em Ciência da Computação.

UNESP

2016

Santos, Fernando Pereira dos.

Estudo comparativo de técnicas para segmentação e classificação de imagens de lesões de pele / Fernando Pereira dos Santos. -- São José do Rio Preto, 2016

145 f. : il., tabs.

Orientador: Aledir Silveira Pereira

Dissertação (mestrado) – Universidade Estadual Paulista “Júlio de Mesquita Filho”, Instituto de Biociências, Letras e Ciências Exatas

1. Computação - Matemática. 2. Processamento de imagens - Técnicas digitais. 3. Pele - Ferimentos e lesões - Classificação. 4. Morfologia matemática. 5. Floresta de caminhos ótimos. I. Pereira, Aledir Silveira. II. Universidade Estadual Paulista "Júlio de Mesquita Filho". Instituto de Biociências, Letras e Ciências Exatas. III. Título.

CDU – 518.72:76

Ficha catalográfica elaborada pela Biblioteca do IBILCE
UNESP - Câmpus de São José do Rio Preto

Fernando Pereira dos Santos

**Estudo comparativo de técnicas para segmentação e
classificação de imagens de lesões de pele**

Dissertação de Mestrado elaborada junto ao Programa de Pós-Graduação em Ciência da Computação – Área de Concentração em Processamento de Imagens e Visão Computacional, como parte dos requisitos para a obtenção do título de Mestre em Ciência da Computação.

BANCA EXAMINADORA

Prof. Dr. Aledir Silveira Pereira
UNESP – São José do Rio Preto
Orientador

Prof. Dr. Maurílio Boaventura
UNESP – São José do Rio Preto

Prof. Dr. Ivan Nunes da Silva
USP – São Carlos

São José do Rio Preto, 16 de Junho de 2016

Dedico este trabalho

À minha esposa Ana.

Aos meus pais Claudécir e Mileide.

AGRADECIMENTOS

Agradeço a Deus pela vida e por ter me escolhido como filho. Todo conhecimento, entendimento e sabedoria vêm de Ti Senhor e este trabalho não foi diferente.

Agradeço à minha querida esposa Ana por ter me incentivado e me apoiado. Dificuldades e noites acordadas, mas você sempre esteve presente para me encorajar, incentivar, impulsionar e acalmar. Te amo!

Agradeço aos meus pais Claudécir e Mileide por todo suporte e dedicação. Vocês sempre me apoiaram e me deram condições para que eu alcançasse meus sonhos e objetivos.

Agradeço ao Prof. Dr. Aledir Silveira Pereira pela confiança e oportunidade de ter entregado a mim este projeto. Sua orientação e conhecimento foram imprescindíveis para o desenvolvimento deste trabalho. Não agradeço somente por ter sido meu mentor, mas também por toda experiência de vida transmitida desde a minha graduação e pela amizade.

Agradeço ao Prof. Dr. Maurílio Boaventura e ao Prof. Dr. Ivan Nunes da Silva por terem aceitado participarem da banca examinadora e qualificação. Os comentários e as observações citadas serviram para melhorar e aprimorar o trabalho desenvolvido, enriquecendo grandemente a minha formação acadêmica.

Agradeço à minha irmã Monize por todos esses anos de companheirismo. Agradeço à Tia Naide por ser minha segunda mãe. Tia Naide, a senhora nunca será esquecida. Agradeço aos meus sogros Paulo e Mara por terem me acolhido e me tratarem como filho e às minhas cunhadas Dânia e Bruna.

Agradeço ao Prof. Dr. João Paulo Papa, ao Prof. Dr. Rodrigo Capobianco Guido e aos colegas Alex Fernando de Araújo, Roberta Barbosa Oliveira, Diego Bruno Renan, Layla Chris Rodrigues Ferreira, Thiago Vallin Spina e Clayton Reginaldo Pereira por toda cooperação. Se não tivessem compartilhado o conhecimento tudo teria sido muito mais difícil.

Agradeço aos amigos Alexei Bueno, Camila Brandão Fantozzi, Fabiana Cota Pontes e Rosana Régia Gomes Marcelino por terem me ensinado o que é ser professor. Dividir a sala de aula com vocês sempre será um prazer.

Muito obrigado.

“Bem-aventurado o homem que encontra sabedoria, e o homem que adquire conhecimento, pois ela é mais proveitosa do que a prata, e dá mais lucro do que o ouro.”

Bíblia Sagrada, Provérbios 3:13-14

RESUMO

Neste trabalho é apresentada uma nova metodologia para a análise e classificação de lesões de pele. O modelo proposto foi dividido em quatro etapas que compreende o pré-processamento das imagens, a segmentação do objeto desejado, a extração de características e a classificação das lesões. Na etapa de pré-processamento, aplica-se o modelo de cor RGB, a quantização de cores e o filtro de difusão anisotrópica. Na segmentação, a imagem suavizada é submetida à operação de fechamento da morfologia matemática, estimativa de peso nos arcos do grafo e à transformada imagem-floresta com apenas duas sementes. A extração de características foi baseada na aplicação da regra ABCD. Na assimetria foi aplicado o conceito de razão de perpendiculares sobre a maior diagonal obtida e, para a borda, o produto vetorial e o ponto de inflexão foram implementados para fornecer o porcentual de curvatura do contorno. Para a cor, valores de média, variância, desvio padrão, homogeneidade e contraste foram calculados. Para a estrutura diferencial foi desenvolvido a dimensão fractal e a energia. Na última etapa, classificação, a floresta de caminhos ótimos foi utilizada. Os resultados da classificação são apresentados por malignidade, quando todos os tipos de lesões estão juntos, e por categorias, quando os tipos de lesão são agrupados dois a dois. Para obter o modelo proposto foram efetuados diversos testes com modelos de cor diferentes, forma de aplicação da quantização, diferenciação no cálculo da quantidade de iterações do filtro de difusão anisotrópica e possibilidade de não aplicar a morfologia matemática.

Palavras-chave: lesões de pele, Regra ABCD, Filtro de Difusão Anisotrópica, Morfologia Matemática, Transformada Imagem-Floresta, Floresta de Caminhos Ótimos e Dimensão Fractal.

ABSTRACT

In this paper a new methodology for the analysis and classification of skin lesions is presented. The suggested model is divided into four steps which comprise the pre processing of images, segmentation of the desired object, feature extraction and lesions classification. In the pre processing step, it is applied the RGB color model, color quantization and anisotropic diffusion filter. In segmentation, the smoothed image is submitted to the closing operation of mathematical morphology, arc-weight estimation in the graph and the image-foresting transform with only two seeds. The feature extraction is based on the application of ABCD rule. In asymmetry was applied the perpendicular ratio concept on the greater diagonal obtained and, to the border, the vector product and the inflection point were implemented to provide the contour curvature percentage. For color, average values, variance, standard deviation, homogeneity and contrast were calculated. For differential structure was developed fractal dimension and energy. In the last stage, classification, optimum-path forest was used. The classification results are presented by malignancy, when all types of lesions are together, and by categories, when the types of lesions are grouped two by two. For the model were performed several tests with different color models, the form of application the quantization, differentiation in the calculation of the quantity of filter iterations of anisotropic diffusion and the possibility of not applying the mathematical morphology.

Keywords: skin lesions, ABCD Rule, Anisotropic Diffusion Filter, Mathematical Morphology, Image-Foresting Transform, Optimum-Path Forest and Fractal Dimension.

LISTA DE FIGURAS

Figura 2.1: Estrutura de camadas da pele [16]	26
Figura 2.2: Manchas: (a) sardas [16]; (b) mancha senil [17]; (c) mancha de gravidez [18]	28
Figura 2.3: Nevos não malignos: (a) nevo juncional; (b) nevo composto; (c) nevo dérmico; (d) nevo halo; (e) nevo azul; (f) nevo <i>spitz</i> ; (g) nevo <i>spilus</i> [15].....	29
Figura 2.4: Ceratose seborréica [19].....	30
Figura 2.5: Nevos congênitos: (a) nevo congênito de tamanho pequeno; (b) nevo congênito de tamanho grande; (c) nevo congênito de tamanho gigante [15]	30
Figura 2.6: Nevo displásico [20]	31
Figura 2.7: Carcinoma basocelular [24]	32
Figura 2.8: Carcinoma espinocelular [24]	32
Figura 2.9: Melanoma [23].....	33
Figura 2.10: Assimetria: (a) simetria; (b) assimetria em um eixo; (c) assimetria em dois eixos [25]	35
Figura 2.11: Borda: (a) borda regular; (b) borda irregular [25].....	35
 Figura 3.1: Representação de: (a) 4-vizinhança; (b) vizinhança diagonal; (c) 8-vizinhança [31]	38
Figura 3.2: Conectividade: (a) de 4; (b) de 8; (c) mista	39
Figura 3.3: Distâncias: (a) euclidiana; (b) <i>city-block</i> ; (c) <i>chessboard</i>	40
Figura 3.4: Modelo RGB [31]	43
Figura 3.5: Localização dos pontos adjacentes ao ponto (i,j).....	50
Figura 3.6: Relações de adjacência: conectividade (a) de 4; (b) de 8; (c) complexa [47].....	55
Figura 3.7: Representação de uma imagem em um grafo com 4-conectividade [48]	57
Figura 3.8: Segmentação da imagem em torno de suas sementes [48]	57
Figura 3.9: Transformada Imagem-Floresta: (a) mapa de custos; (b) mapa de raízes; (c) mapa de predecessores [48-adaptado].....	58
Figura 3.10: Floresta de caminhos ótimos com aprendizado não supervisionado: (a) definição do grafo; (b) aplicação do termo de inicialização; (c) floresta de caminhos ótimos [55]	64
Figura 3.11: Floresta de caminhos ótimos com aprendizado supervisionado usando grafo completo: (a) grafo completo; (b) árvore geradora mínima do grafo; (c) escolha dos protótipos; (d) cálculo dos custos entre as amostras e identificação dos rótulos; (e) processo de classificação de uma amostra de teste para uma das árvores existentes; (f) floresta de caminhos ótimos [56]	68
Figura 3.12: Floresta de caminhos ótimos com aprendizado supervisionado usando grafo K-NN: (a) grafo K-NN; (b) processo de classificação de uma amostra; (c) processo final de classificação [47].....	71

Figura 3.13: Curva de Koch: (a) figura inicial; (b) figura após a primeira iteração; (c) figura após a segunda iteração; (d) figura após a terceira iteração; (e) figura após a quarta iteração [65]	73
Figura 3.14: Sobreposição de círculos no Método de Cálculo Massa-Raio [66]	74
Figura 3.15: Método <i>Box Counting</i> : (a) primeira iteração; (b) segunda iteração [30]	75
Figura 3.16: Método <i>Dividers</i> : (a) maior quantidade de pontos; (b) menor quantidade de pontos [66]	76
Figura 3.17: Método Bouligand-Minkowski [66]	76
 Figura 4.1: Etapas do modelo de processamento adotado	77
Figura 4.2: Etapa de pré-processamento	82
Figura 4.3: Modelos de cor: (a) imagem RGB [19]; (b) imagem RGB após a equalização da componente Y no modelo YIQ; (c) imagem RGB após a equalização do canal I no modelo HSI; (d) imagem em escala de cinza	84
Figura 4.4: Quantização de cores utilizando 8 cores em cada componente: (a) imagem original em RGB [19]; (b) imagem original quantizada; (c) imagem em escala de cinza; (d) imagem em escala de cinza quantizada.	85
Figura 4.5: Filtro de Difusão Anisotrópica: (a) imagem original em RGB [19]; (b) imagem original suavizada; (c) imagem em escala de cinza; (d) imagem em escala de cinza suavizada.	88
Figura 4.6: Etapa de segmentação	89
Figura 4.7: Elemento estruturante utilizado na operação de fechamento	90
Figura 4.8: Morfologia matemática em níveis de cinza: (a) imagem base em níveis de cinza; (b) aplicação isolada da operação de dilatação; (c) aplicação isolada da operação de erosão; (d) aplicação da operação de fechamento, dilatação seguida de erosão	91
Figura 4.9: Nós sementes para as regiões externa (<i>pixel</i> próximo do canto superior esquerdo) e interna (<i>pixel</i> central) da lesão [19-adaptado]	92
Figura 4.10: Estimativa de Peso nos Arcos e Transformada Imagem-Floresta: (a) imagem original em RGB [19]; (b) quantização com 8 intervalos; (c) estimativa de peso nos arcos precedida da operação de fechamento e quantização com 8 intervalos; (d) transformada imagem-floresta com estimativa de peso nos arcos precedida da quantização com 8 intervalos e operação de fechamento; (e) estimativa de peso nos arcos precedida da operação de fechamento e sem quantização; (f) transformada imagem-floresta com estimativa de peso nos arcos precedida da operação de fechamento e sem quantização; (g) estimativa de peso nos arcos precedida somente da quantização com 8 intervalos; (h) transformada imagem-floresta com estimativa de peso nos arcos precedida da quantização com 8 intervalos	95
Figura 4.11: Etapa de extração de características	96
Figura 4.12: Regra ABCD, característica de assimetria: (a) lesão simétrica; (b) lesão assimétrica [15]	97
Figura 4.13: Regra ABCD, característica de borda: (a) lesão; (b) assinatura da região segmentada	99
Figura 4.14: Etapa de classificação	103

Figura 5.1: Semelhança na tonalidade entre a pele e a lesão: (a) contorno no modelo RGB; (b) contorno no modelo YIQ; (c) contorno no modelo HSI; (d) suavização em RGB; (e) suavização em YIQ; (f) suavização em HSI.....	108
Figura 5.2: Diferença na tonalidade entre a pele e a lesão: (a) imagem original [19]; (b) sobreposição do fundo segmentado com o modelo RGB; (c) sobreposição do fundo segmentado com o modelo YIQ; (d) sobreposição do fundo segmentado com o modelo HSI	109
Figura 5.3: Influência da luminosidade e sombreamento na região de fronteira: (a) imagem com luminosidade; (b) imagem com luminosidade; (c) imagem com sombreamento.....	110
Figura 5.4: Luminosidade no modelo RGB: (a) na lesão; (b) na lesão; (c) na lesão e pele; (d) na lesão e pele.....	110
Figura 5.5: Sombreamento: (a) na parte esquerda e superior da imagem; (b) na parte direita e inferior da imagem; (c) na parte direita da imagem	111
Figura 5.6: Quantização de cores: (a) aplicação prévia com 8 intervalos; (b) omissão; (c) aplicação posterior com 8 intervalos	113
Figura 5.7: Heterogeneidade da lesão na diferenciação do intervalo na quantização: (a) suavização com 8 intervalos; (b) suavização com 16 intervalos; (c) suavização com 32 intervalos; (d) suavização com 4 intervalos; (e) contorno com 8 intervalos; (f) contorno com 16 intervalos; (g) contorno com 32 intervalos; (h) contorno com 4 intervalos	115
Figura 5.8: Homogeneidade da lesão na diferenciação do intervalo na quantização: (a) suavização com 8 intervalos; (b) suavização com 16 intervalos; (c) suavização com 32 intervalos; (d) suavização com 4 intervalos; (e) contorno com 8 intervalos; (f) contorno com 16 intervalos; (g) contorno com 32 intervalos; (h) contorno com 4 intervalos	115
Figura 5.9: Definição de contornos com presença de pelos: (a) com filtro de difusão anisotrópica; (b) com filtro de difusão anisotrópica; (c) com filtro de difusão anisotrópica; (d) com filtro da média; (e) com filtro da média; (f) com filtro da média; (g) com filtro da mediana; (h) com filtro da mediana; (i) com filtro da mediana.....	117
Figura 5.10: Aplicação e omissão da operação de fechamento da morfologia matemática: (a) com aplicação; (b) com omissão; (c) com aplicação; (d) com omissão	121
Figura 5.11: Segmentação de nevos halos: (a) marcação no nevo; (b) marcação no nevo; (c) marcação no halo; (d) marcação no nevo	122
 Figura APÊNDICE 1: Sobreposição de imagens: (a) imagem original em RGB [19]; (b) imagem obtida com a segmentação; (c) sobreposição do objeto segmentado; (d) sobreposição do fundo segmentado.....	143
Figura APÊNDICE 2: Desenho das marcações em uma imagem: (a) imagem original em RGB [19]; (b) desenho da fronteira no objeto segmentado; (c) desenho da diagonal no objeto segmentado; (d) identificação das regiões separadas pela diagonal no objeto segmentado...	144
Figura APÊNDICE 3: Desenho das perpendiculares no objeto: (a) imagem original em RGB [19]; (b) desenho da maior diagonal no objeto; (c) objeto segmentado com 10 perpendiculares; (c) objeto segmentado com 20 perpendiculares.....	145
Figura APÊNDICE 4: Desenho da grade do método <i>Box Counting</i> de dimensão fractal: (a) imagem original em RGB [19]; (b) imagem convertida em níveis de cinza; (c) traço das linhas e colunas que identificam as 16 regiões para o cálculo da dimensão fractal.....	145

LISTA DE TABELAS

Tabela 4.1: Classificação das imagens em lesões não malignas, lesões suspeitas e lesões malignas.....	79
Tabela 4.2: Classificação das imagens de lesões não malignas em nevos não malignos e ceratose seborréica.....	80
Tabela 4.3: Classificação das imagens de lesões suspeitas em nevos congênitos e nevos dispásicos.....	80
Tabela 4.4: Divisão dos intervalos no processo da quantização de cores.....	84
Tabela 5.1: Comparativo da taxa de acerto entre os modelos de cor RGB, YIQ e HSI utilizando quantização de cores com 8 intervalos antes do filtro de difusão anisotrópica com 100 iterações.....	112
Tabela 5.2: Comparativo da taxa de acerto entre a omissão, aplicação prévia ou posterior da quantização de cores com 8 intervalos em relação ao filtro de difusão anisotrópica com 100 iterações.....	113
Tabela 5.3: Comparativo da taxa de acerto entre os intervalos propostos para a quantização de cores no modelo RGB seguido de quantização e filtro de difusão anisotrópica com 100 iterações.....	114
Tabela 5.4: Comparativo da taxa de acerto entre o filtro de difusão anisotrópica com 100 iterações, filtro da média e o filtro da mediana utilizando modelo de cor RGB e quantização de cores com 8 intervalos	116
Tabela 5.5: Definição da quantidade de iterações e taxa de acertos na utilização do filtro de difusão anisotrópica no modelo RGB precedido de quantização de cores com 8 intervalos e morfologia matemática.....	118
Tabela 5.6: Definição da quantidade de iterações e total de acertos na utilização do filtro de difusão anisotrópica no modelo RGB precedido de quantização de cores com 8 intervalos e morfologia matemática por tipo de lesão	119
Tabela 5.7: Taxa de acerto na segmentação referente à operação de fechamento da morfologia matemática no modelo RGB seguido de quantização de cores com 8 intervalos e filtro de difusão anisotrópica com 100 iterações.....	120
Tabela 5.8: Taxa de acerto na classificação das lesões de pele na floresta de caminhos ótimos	122
Tabela 5.9: Comparativo da segmentação do modelo proposto com outros trabalhos similares	124
Tabela 5.10: Comparativo da segmentação do modelo proposto com outro trabalho da área por tipo de lesão.....	125
Tabela 5.11: Comparativo da taxa de acerto da classificação do modelo proposto com outros trabalhos da área por categorias.....	125
Tabela 5.12: Taxa de acerto na classificação de outras categorias	127

SUMÁRIO

1 - INTRODUÇÃO	16
1.1 - Objetivos	17
1.2 – Trabalhos relacionados	18
1.3 - Contribuições do trabalho	23
1.4 - Organização do trabalho.....	24
 2 - PELE E SUAS LESÕES.....	25
2.1 - Estrutura, características e funcionalidades	25
2.2 - Lesões de pele	26
2.2.1 - Lesões não malignas.....	27
2.2.2 - Lesões suspeitas	30
2.2.3 - Lesões malignas	31
2.3 - Métodos de identificação e classificação das lesões	33
2.3.1 - Regra ABCD	34
2.3.2 - Método dos Sete Pontos	36
 3 - PROCESSAMENTO DIGITAL DE IMAGENS.....	37
3.1 - Conceitos básicos	37
3.1.1 - Vizinhança.....	38
3.1.2 - Conectividade.....	39
3.1.3 - Distâncias métricas.....	39
3.2 - Filtros	40
3.3 - Morfologia Matemática.....	41
3.4 - Modelos de cor	42
3.4.1 - Modelo RGB	43
3.4.2 - Modelo YIQ	44
3.4.3 - Modelo HSI.....	44
3.5 - Filtro de Difusão Anisotrópica	45
3.5.1 - Processo físico da difusão anisotrópica e definição do filtro	46
3.5.2 - Função gaussiana e tempo ótimo de suavização	53
3.6 - Transformada Imagem-Floresta	54
3.6.1 – Transformada Imagem-Floresta Diferencial.....	59
3.6.2 – Estimativa de peso nos arcos do grafo.....	60

3.7 - Floresta de Caminhos Ótimos	61
3.7.1 - Classificação com aprendizado não supervisionado	62
3.7.2 - Classificação com aprendizado supervisionado por grafo completo	66
3.7.3 - Classificação com aprendizado supervisionado por grafo K-NN	69
3.8 - Dimensão Fractal.....	71
3.8.1 - Métodos de cálculo da Dimensão Fractal	73
4 - MÉTODO DESENVOLVIDO.....	77
4.1 - Aquisição de imagens.....	78
4.2 - Pré-processamento	81
4.2.1 - Modelos de cor	82
4.2.2 - Quantização de cores.....	84
4.2.3 - Filtro de Difusão Anisotrópica	85
4.3 - Segmentação.....	88
4.3.1 – Morfologia Matemática	89
4.3.2 – Transformada Imagem-Floresta Diferencial.....	91
4.4 - Extração de características	96
4.4.1 - Assimetria.....	96
4.4.2 - Borda	98
4.4.3 - Cor.....	100
4.4.4 – Estruturas diferenciais	101
4.5 - Classificação das imagens.....	103
4.5.1 – Conjunto de treinamento e aprendizado supervisionado	104
4.5.2 – Classificação por grafo completo	105
5 - RESULTADOS	107
5.1 – Comparação entre os modelos de cor	107
5.2 – Aplicação e omissão da quantização de cores e seus intervalos.....	112
5.3 – Definição da quantidade de iterações no filtro de difusão anisotrópica	116
5.4 – Associação da morfologia matemática à transformada imagem-floresta	120
5.5 - Classificação das imagens por meio da floresta de caminhos ótimos.....	122
5.6 – Análise comparativa com outros trabalhos	123
6 - CONCLUSÕES	128
6.1 – O modelo ideal encontrado.....	128

6.2 - Análise dos resultados obtidos	129
7 - TRABALHOS FUTUROS.....	131
7.1 - Pré-processamento	131
7.2 - Segmentação.....	132
7.3 - Extração de características	133
7.4 - Classificação das imagens.....	134
REFERÊNCIAS	135
APÊNDICE: Funções de visualização de imagens	143

1 - INTRODUÇÃO

Qualquer doença que possui crescimento desordenado de células anormais com potencial invasivo é denominada como câncer. Existe um conjunto de mais de cem tipos diferentes de doenças com essa característica que ocorrem por condições multifatoriais. Geralmente, a maioria dos cânceres ocorre em etapas ao longo de muitos anos e, desta forma, alguns tipos podem ser evitados se a exposição aos fatores determinantes for eliminada. Sendo assim, se o potencial de malignidade for detectado antes de as células se tornarem malignas ou numa fase inicial da patologia, o tratamento terá mais eficiência e a possibilidade de cura do paciente será mais favorável [1, 2].

De acordo com os dados do Instituto Nacional de Câncer José Alencar Gomes da Silva, INCA, projeções futuras indicam que em 2030 a população mundial terá 21,4 milhões de novos casos de câncer e 13,2 milhões de mortes por câncer devido ao crescimento e envelhecimento da população e redução na mortalidade infantil [1]. Esses dados revelam a preocupação das organizações mundiais de saúde no combate ao câncer.

Somente no Brasil, as estimativas para o biênio 2016-2017 apontam a ocorrência de aproximadamente 600 mil novos casos de câncer. Essas estimativas apontam que o câncer de pele não melanoma será o mais incidente com 180 mil novos casos, representando 30% destes casos. Para essa quantidade, as mulheres estão mais propícias à incidência com estimativa de 94910 novos casos contra 80850 novos casos para os homens. Esses valores correspondem a um risco de 91,98 para cada 100 mil mulheres e 81,66 para cada 100 mil homens [1]. Nos casos de melanoma, as estimativas são de 3000 novos casos em homens e 2670 novos casos em mulheres. Apesar de a estimativa indicar uma incidência baixa em

relação aos casos não melanoma, este tipo de câncer possui letalidade muito alta [1].

Na Austrália, estudos do governo realizados em 2014 apresentaram que a porcentagem de melanoma sobre o total de diagnósticos ficou em aproximadamente 10,89% entre os homens e 9,36% entre as mulheres [2]. Além destes dados, para o ano de 2016, as estimativas indicam um aumento de cerca de 5% do número de casos em relação ao ano de 2014 [2]. As estimativas do número de melanomas nos Estados Unidos para o ano de 2016 são de 83510 novos casos, sendo 51650 em homens e 31860 em mulheres [3]. Essas informações excluem os casos de câncer de pele não melanoma e mostram a necessidade de aumentar a prevenção desse tipo de câncer que envolve desde evitar exposição excessiva aos raios solares até a elaboração de diagnósticos mais precisos, possibilitando tratamentos mais rápidos para que a doença não evolua.

Neste objetivo, o processamento digital de imagens vem sendo utilizado continuamente no auxílio do diagnóstico do câncer de pele pela análise e classificação das lesões de pele para que o paciente seja encaminhado para o tratamento mais adequado. Diversas técnicas podem ser utilizadas neste processo, dentre as quais, o filtro de difusão anisotrópica que busca diminuir os ruídos existentes na imagem e proporcionar a manutenção das bordas nas lesões. A transformada imagem-floresta e a floresta de caminhos ótimos vêm mostrando eficiência em diversas áreas e serão utilizadas, respectivamente, neste trabalho para realizar a segmentação e a classificação das lesões.

1.1 - Objetivos

O objetivo principal deste trabalho foi analisar imagens de lesões de pele e classificá-las de acordo com o seu grau de malignidade. Para alcançar essa finalidade, algumas técnicas como o filtro de difusão anisotrópica, a transformada imagem-floresta diferencial, a floresta de caminhos ótimos e o método *box counting* de dimensão fractal foram implementadas.

Outro objetivo deste trabalho foi realizar um estudo comparativo nas vertentes das técnicas adotadas. No filtro de difusão anisotrópica, a comparação aconteceu por meio da definição da quantidade de iterações do processo. Além dessas comparações, alterações no

modelo de cor escolhido, o processo de quantização de cores e a associação da morfologia matemática à transformada imagem-floresta também foram estudados. Os resultados obtidos por esse conjunto de técnicas também foram comparados com outros trabalhos relacionados da área.

A comparação das imagens ocorreu de duas formas: classificação por tipo de malignidade e classificação por categorias. No primeiro modo, as lesões podem ser classificadas em não malignas, suspeitas e malignas. Na segunda maneira, os tipos de lesão são agrupados em conjunto de duas categorias por vez e classificadas entre si.

1.2 – Trabalhos relacionados

O aumento constante do número de casos de câncer de pele tem incentivado a pesquisa de métodos informatizados no auxílio de diagnósticos médicos. A área de processamento de imagens vem acompanhando essa tendência com propostas diferentes que visam proporcionar ferramentas para que a identificação e a classificação das lesões de pele sejam feitas mais rapidamente e com maior precisão.

No trabalho de Messadi, Cherifi e Bessaid [4] a extração de características foi realizada por meio da Regra ABCD e a segmentação por meio da limiarização e *level set*. A proposta foi dividida em quatro módulos, nos quais o primeiro desses possuiu a função de remover irregularidades como pelos e obter um melhor contraste na imagem. Nessa etapa, conhecida como pré-processamento, foi utilizado um algoritmo que não interfere na textura da lesão. Primeiramente, para a detecção dos pelos foi utilizado um filtro gaussiano seguido de técnicas morfológicas e, logo após, os pelos foram reparados por um esquema de repintura. A segunda etapa, segmentação, foi realizada por um algoritmo não supervisionado baseado em limiarização e *level set*. As imagens foram transformadas para um tamanho padrão e em níveis de cinza. Com isso, aplicou-se o limiar no histograma da imagem para obter uma imagem binária e o *level set* foi utilizado para definir o contorno do objeto segmentado. Essa proposta de segmentação foi comparada com outros algoritmos como *Mean Shift* e *Growcut*, apresentando apenas 4,48% de erro na definição do contorno das bordas contra 10,03% e 7,02% das outras duas técnicas, respectivamente. As características do objeto segmentado,

como assimetria, borda, cor e diâmetro foram extraídas e repassadas para a última etapa do processo, a classificação. Para a classificação foi implementado um algoritmo de aprendizado supervisionado de redes neurais multicamadas que recebeu como entrada as informações extraídas na fase anterior e que teve como objetivo final definir a lesão como melanoma ou não melanoma. Nessa metodologia, a taxa de classificação correta foi de 87,32%.

Dividindo o processamento das imagens de lesões de pele em três etapas, El Abbadi e Miry [5] propuseram uma metodologia que adotou o filtro de Wiener, segmentação por limiarização e morfologia matemática, e avaliação dos resultados pela distância Hamoude e taxa de detecção verdadeira. Primeiramente, as imagens foram convertidas em níveis de cinza para serem filtradas. O filtro de Wiener é baseado em uma aproximação estatística sobre o quadrado médio do erro mínimo, removendo o ruído adicional e, simultaneamente, invertendo o borramento. Com a imagem filtrada foi aplicado o limiar no histograma da imagem, obtendo uma imagem binária e, para eliminar as imperfeições no objeto segmentado, técnicas de morfologia matemática foram aplicadas à imagem. Na distância Hamoude é calculado a proporção de erros da segmentação manual, feita por especialistas da área, com a segmentação obtida nos algoritmos utilizados e a taxa de detecção verdadeira considera a classificação dos *pixels* de modo correto. A taxa de erros da metodologia empregada foi de 11,37% na segmentação com 96,32% de acertos na classificação dos *pixels*. Esses dados quando comparados com outras técnicas como *fuzzy K-means* e OTSU mostraram uma maior precisão. Para o *fuzzy K-means*, a taxa de erros da segmentação foi 13,07% e para OTSU foi de 13,89%. A taxa de acertos da classificação dos *pixels* foi de 93,83% e 93,01% para *fuzzy K-means* e OTSU, respectivamente.

A transformada *wavelet* bidimensional e o método de OTSU foram utilizados por Razazzadeh e Khalili [6] para segmentar as imagens de lesões de pele. Neste trabalho, as imagens foram convertidas para o espaço de cores YUV e aplicou-se um filtro de passa-baixa no canal U para retirar os pelos, linhas de pele, vasos sanguíneos e outras deformidades existentes. Além disso, no pré-processamento realizou-se um ajustamento do canal de intensidade para melhorar o contraste da imagem. Partindo para a segmentação, o canal U foi decomposto em dois níveis pela transformada *wavelet* e aplicou-se o método de OTSU, obtendo uma imagem binária. A transformada *wavelet* é utilizada para decompor o sinal da imagem em quatro diferentes resoluções e o método de OTSU consiste em dividir os *pixels* da imagem em duas categorias distintas: *foreground* e *background*. Com isso, o limiar é obtido encontrando o contraste máximo entre essas duas categorias. Logo após, algoritmos de

reconstrução morfológica foram utilizados para remover pequenos objetos contidos na área segmentada. A proposta foi testada em dez grupos diferentes de imagens, obtendo uma exatidão que variou de 91,07% a 96,19% e especificidade em torno de 99%. A exatidão é uma medida que quantifica a repetição e a reprodução correta do experimento. A especificidade indica a taxa de acerto sobre a identificação correta dos *pixels* da região desprezada.

John et al. [7] propuseram uma metodologia usando segmentação de lesão por distinção de textura e classificação das imagens por redes neurais. Esse tipo de segmentação fez uso da conversão da imagem para o espaço de cor XYZ com extração de características da textura para cada *pixel*. Na sequência, o algoritmo *K-means* foi executado. Esse algoritmo objetiva particionar os *pixels* no agrupamento mais próximo das classes pré-estabelecidas existentes. Com a partição dos *pixels* finalizada é necessário classificar as regiões formadas por eles. Para isso, a segmentação por distinção de textura utilizou um algoritmo de fusão estatística de regiões que é baseado na probabilidade de um *pixel* ser similar ao outro. A metodologia descrita foi comparada a outros métodos como o OTSU e alcançou resultados mais eficientes para a especificidade e exatidão com 99,51% e 98,4%, respectivamente, contra 80,3% e 80,2% para o método de OTSU. Apesar da melhora significativa nesses dois fatores, a sensibilidade nesta metodologia não proporcionou melhores indicadores, mantendo praticamente a mesma eficiência de OTSU, em torno de 93%. A sensibilidade quantifica a proporção dos *pixels* da lesão identificados corretamente.

O algoritmo genético foi aplicado por Sood e Shukla [8] para realizar a segmentação das imagens de lesões de pele em cada canal RGB separadamente. Inicialmente, o filtro da média foi aplicado a cada canal RGB para remoção de ruídos e suavização. Além do filtro, a imagem passou por uma equalização do histograma para aumentar o contraste global. Com isso, o algoritmo genético foi utilizado para segmentar a imagem. Durante a segmentação, algumas operações foram executadas sobre a imagem, como mutação, cruzamento, avaliação de valores, seleção e eliminação, até obter-se o limiar otimizado. Ao resultado da segmentação, cada componente foi binarizada e submetida à operação morfológica de erosão. Os resultados obtidos com o algoritmo genético foram muito expressivos, alcançando quase 100% nos quesitos de sensibilidade, especificidade e exatidão.

Al-Abayechi et al. [9] utilizaram o filtro da média e algumas operações morfológicas na etapa de pré-processamento. Primeiramente, para remover os pelos e reflexos de luz aplicaram-se as operações morfológicas de fechamento e erosão. Logo após, para

reduzir efeitos de pequenas estruturas na imagem utilizou-se o filtro da média. Após a filtragem, as imagens foram convertidas para um modelo de duas coordenadas de cores. Essas coordenadas são formadas pela combinação das componentes do modelo RGB. Dessa forma, foi possível analisar qual a melhor combinação de cores para o restante do processamento. Sendo assim, quando a imagem foi analisada somente com a componente G, a exatidão foi de 97,03% e a sensibilidade de 96,69%. Para a especificidade, o melhor resultado foi com a combinação RG, 98,67%. A segmentação adotada realizou um cálculo sobre os valores da combinação RGB com mais eficiência e separou os *pixels* em duas categorias: objeto e fundo da imagem. Comparando esses valores com o uso de *watershed* e *wavelet*, esse modelo apresentou exatidão de 97,03% e sensibilidade de 96,69%, contra 94,61% e 88,6%, respectivamente. Porém, a especificidade obteve um valor abaixo, 97,26%, mas próximo do valor de 98,21% com *watershed* e *wavelet*.

Com a utilização de um filtro de média adaptativo, Massod e Al-Jumaily [10] realizaram o pré-processamento das imagens de lesões de pele para suavizar as bordas e diminuir os efeitos causados por sombras e presença de pelos. Com a filtragem concluída, o histograma da imagem foi analisado pelo algoritmo *fuzzy C-mean* que determinou o limiar ideal para que a imagem passasse a ser binária. Com isso, a técnica de *level set* foi aplicada para determinar o contorno do objeto segmentado. O histograma da imagem forneceu informações sobre algumas características analisadas para a classificação, como a média, a variância, o desvio padrão, a assimetria, a energia e a entropia. Além desses dados, essa metodologia fez uso da matriz de coocorrência em níveis de cinza para extrair informações sobre a textura e da transformada *wavelet* com *fuzzy* para obter dados sobre frequência e espaço. Com esses dados gerados, a classificação das imagens foi realizada por uma vertente da máquina de vetor de suporte, denominada como *self advising*. Essa versão da máquina de vetor de suporte corrige o conhecimento adquirido na fase de treinamento sobre os erros de classificação. A máquina de vetor de suporte é uma técnica que separa duas classes encontrando o melhor hiperplano que maximize a diferença entre elas. A comparação neste trabalho aconteceu entre as muitas vertentes da máquina de vetor de suporte existentes. Essa metodologia foi comparada aos modelos linear, polinomial, quadrático, função radial e percepção multicamadas, alcançando 89% de eficiência em sensibilidade e 92% em especificidade, valores muito distintos e acima das vertentes citadas.

A suavização gaussiana foi utilizada por R, Suhil e Guru [11] para corrigir algumas imperfeições nas imagens de lesões de pele. Em sequência, a erosão e a dilatação

foram aplicadas às imagens filtradas. A extração de características de cor foi realizada sobre seis diferentes modelos e coletou dados sobre a média, o desvio padrão, a variância e a assimetria. Para a coleta de informações sobre a textura utilizou-se uma matriz de coocorrência em níveis de cinza. Alguns dados analisados sobre a textura foram a entropia, a correlação e a variância. As imagens foram, então, classificadas pela máquina de vetor de suporte, por um classificador K-NN e pela combinação das duas técnicas citadas. Para todos os grupos de imagens analisadas, melanoma, ceratose seborréica e carcinoma espinocelular, a combinação das duas técnicas obteve os melhores resultados do que quando executadas separadamente.

Outro trabalho que utilizou a segmentação de lesão por distinção de textura foi realizado por Jeniva e Santhi [12]. Após a conversão da imagem para o modelo de cor XYZ, executou-se um algoritmo para agrupar os *pixels* nas classes pré-estabelecidas. Com isso, o limiar de OTSU foi aplicado à imagem para que os agrupamentos existentes formassem o objeto desejado e a região de fundo. A necessidade agora estava na delimitação correta do contorno da imagem. Portanto, a operação morfológica de dilatação foi aplicada para preencher os buracos existentes e suavizar a borda. A comparação desse trabalho foi em relação aos filtros utilizados. Os filtros aplicados foram gaussiano, médio e a transformada *wavelet*. Nos atributos de exatidão, sensibilidade e especificidade, a transformada *wavelet* apresentou os melhores resultados com a metodologia construída.

O trabalho de Shimizu et al. [13] analisou imagens de melanomas, nevus, carcinomas basocelulares e cetaroses seborréicas com o objetivo de classificá-las em melanomas e não melanomas. O início do processo consistiu na detecção das bordas por meio de um limiar colorido, remoção de imperfeições e inclusão de brilho. Na fase de segmentação, a lesão foi dividida em quatro regiões: pele normal, periferia, tumor central e tumor completo. A região do tumor completo compreende a periferia e o tumor central. Para cada região dessas citadas foram calculados valores como mínimo, máximo, desvio padrão, assimetria, entropia e intensidade para os canais RGB e HSV, entre outros. Além disso, calculou-se para esses parâmetros a diferença entre as regiões de tumor central e periferia e também entre periferia e pele normal. Outra análise feita envolveu a divisão das regiões de tumor central e periferias em sub-regiões geradas por ângulos e por distâncias. Para essas sub-regiões foram calculadas a média, o desvio padrão e a assimetria. Para extrair informações sobre a textura utilizou-se a matriz de coocorrência em níveis de cinza. A classificação das imagens foi realizada por um modelo em camadas. Primeiramente, o classificador operou sobre dois possíveis fluxos:

melanoma e nevo ou carcinoma basocelular e ceratose seborréica. A segunda camada indica a classificação final das imagens. Essas camadas operam sobre a análise de características, indicando o caminho correto que o fluxo deve seguir. Dessa forma, os dois grupos iniciais indicam um nível de semelhança entre si em características primárias e, na segunda camada, outras características próprias de cada lesão são consideradas. O conjunto de técnicas utilizadas no conjunto de imagens obteve uma taxa de acerto de aproximadamente 80% sobre as lesões não melanomas enquanto que a taxa de acerto sobre os melanomas foi de 90%.

A distinção entre melanoma e nevos displásicos foi estudada no trabalho de Rastgoo et al. [14]. Neste trabalho, as imagens no espaço de cor XYZ foram segmentadas pela distribuição probabilística da componente Z. As características consideradas foram forma, cor e textura. Para a forma, os parâmetros considerados foram a assimetria da borda, a distância dos pontos de borda em relação ao centro e as estatísticas sobre o gradiente da borda. Para a cor, o histograma em RGB, a variância de cores e o histograma do matiz foram analisados. Para a textura foi utilizado a matriz de coocorrência em níveis de cinza, o filtro de Gabor e outras técnicas. Este trabalho teve como foco a comparação entre três diferentes técnicas de classificação: a máquina de vetor de suporte, o gradiente *boosting* e a floresta randômica. A floresta randômica faz uso de árvores de decisão que utilizam descritores para a propagação de uma amostra por seus nós. Os resultados obtidos exibiram um melhor desempenho para a floresta randômica, com sensibilidade alcançada de 98,46%.

A descrição desses trabalhos evidencia a necessidade de estudos das lesões de pele em processamento de imagens. Os estudos explanados utilizam diversas técnicas e focos de pesquisa diferentes, porém com o mesmo propósito de fornecer algoritmos mais precisos e metodologias mais apuradas para o auxílio no diagnóstico dos pacientes.

1.3 - Contribuições do trabalho

As contribuições deste trabalho envolvem a comparação entre os modelos de cor RGB, YIQ e HSI, análise da aplicação ou omissão da quantização de cores em imagens de lesões de pele e seus intervalos, diferenciação na definição da quantidade de iterações no filtro de difusão anisotrópica, associação da morfologia matemática à transformada imagem-

floresta diferencial na segmentação, extração de características das lesões de pele por meio da regra ABCD, classificação das imagens por meio da floresta de caminhos ótimos, estudos comparativos entre as técnicas utilizadas e análise comparativa com outros trabalhos da área.

Além destas comparações, houve a proposta de um modelo para a segmentação e um modelo para a classificação. Sendo assim, neste trabalho foi proposto um conjunto de características apropriado para cada processo de classificação testado.

1.4 - Organização do trabalho

Este trabalho foi organizado em capítulos que descrevem as lesões de pele, as técnicas utilizadas, o trabalho desenvolvido, os resultados alcançados, as conclusões e os trabalhos futuros.

No segundo capítulo é apresentada a estrutura e as características da pele. Além disso, as lesões de pele são descritas de acordo com seu grau de malignidade: lesões não malignas, lesões suspeitas e lesões malignas. E, por fim, os métodos de identificação e classificação de lesões de pele são apresentados. No terceiro capítulo, as técnicas utilizadas neste trabalho são expostas e detalhadas. Após uma breve descrição sobre os conceitos básicos da área de processamento de imagens, morfologia matemática e modelos de cor, seguem a descrição do filtro de difusão anisotrópica, a transformada imagem-floresta, a floresta de caminhos ótimos e a dimensão fractal.

O projeto desenvolvido e a implementação das técnicas utilizadas são explanadas no quarto capítulo. Os resultados obtidos e a análise dos dados deste trabalho em relação a outros são exibidos no quinto capítulo. As conclusões e os trabalhos futuros são expostos no sexto e sétimo capítulos, respectivamente.

2 - PELE E SUAS LESÕES

Neste capítulo são apresentados os conceitos sobre a estrutura da pele, suas características e funcionalidades. A partir desses conceitos, as lesões de pele são descritas conforme o seu grau de malignidade, como em não malignas, suspeitas e malignas. Além disso, estas lesões são identificadas e classificadas por meio de alguns procedimentos denominados de “Regra ABCD” e o “Método dos Sete Pontos”.

2.1 - Estrutura, características e funcionalidades

A pele representa mais de 15% do peso total do corpo humano, apresentando grandes variações de flexibilidade e elasticidade. A principal funcionalidade desse órgão é a proteção do corpo, servindo como um manto de revestimento no organismo e isolando, assim, os componentes orgânicos contra vários riscos como os raios ultravioletas, agentes físicos e químicos, desidratação e ameaças biológicas. Além dessa funcionalidade, este órgão possui capacidade sensorial por meio de suas terminações nervosas, permitindo a identificação de sensações de dor, temperatura e pressão [15, 16].

A pele pode ser dividida em três camadas: epiderme, derme e hipoderme. A epiderme é a camada mais externa da pele formada por células planas e arredondadas. As células planas estão dispostas na superfície de modo a formar um arranjo de escamas e as células arredondadas se situam logo abaixo dessas. Sob essas células, a epiderme possui os melanócitos que produzem a melanina, responsáveis pela pigmentação da pele [16].

A segunda camada, a derme, é composta por vasos sanguíneos, vasos linfáticos, folículos pilosos e glândulas. Estas glândulas podem produzir suor ou sebo que contribuem para o resfriamento do corpo e proteção contra ressecamento, respectivamente. Tanto o suor quanto o sebo alcançam a superfície da epiderme por aberturas chamadas de poros [15].

A hipoderme é a camada mais profunda e contém tecido adiposo. Essa camada permite que a pele tenha a capacidade de deslizamento de acordo com a região do corpo [16]. Na figura (2.1) é possível observar a estrutura de camadas da pele com a epiderme, a derme e a hipoderme.




Figura 2.1: Estrutura de camadas da pele [16]

2.2 - Lesões de pele

A produção anormal de um grupo de células em uma região da pele pode ocasionar algumas lesões. Esta produção anormal pode ser desencadeada por vários fatores e

diferem da produção normal devido à falta de organização na divisão de células e ciclo de vida descontrolado, podendo atingir outras partes do corpo. As lesões podem ser classificadas em não malignas e malignas. Há casos de uma lesão não maligna ter características de uma lesão maligna e precisar de uma análise mais aprofundada para comprovar seu estágio, sendo considerada como uma lesão suspeita [15].

2.2.1 - Lesões não malignas

As lesões não malignas podem ser divididas em manchas, nevos (pintas) e ceratose seborréica. Essas lesões são ocasionadas por causa da alteração na produção da melanina. Quando os melanócitos sofrem alterações na sua quantidade em determinada área da pele ocasionam o clareamento ou escurecimento da região, desenvolvendo o aparecimento das manchas [15]. Entre os tipos de manchas existentes, a sarda, a mancha senil e a mancha de gravidez são as mais comuns.

As sardas são mais frequentes em pessoas claras ou ruivas. Essas pequenas manchas aparecem em regiões com maior exposição aos raios solares, como no rosto e nos ombros. Apesar de não serem lesões com capacidade para desenvolverem uma lesão maligna, as sardas devem ser cuidadas para evitar a ocorrência de queimaduras e o envelhecimento precoce [15].

A mancha senil, também provocada pela exposição excessiva ao sol, aparece geralmente no rosto, antebraço e no dorso das mãos. Essa mancha é caracterizada pela cor castanha e pelo tamanho maior em relação às sardas. Pessoas acima dos 45 anos tendem a ter mais disposição para desenvolver esse tipo de mancha [16].

Devido às alterações hormonais ou o uso de anticoncepcionais, as mulheres podem desenvolver algumas manchas principalmente na região do rosto. Esse tipo de lesão é denominado como manchas de gravidez. Apesar do nome, os homens com tendências genéticas também podem possuir essas manchas [15].

Na figura (2.2) são exibidos os três tipos de manchas mencionadas anteriormente. Na parte (a) da figura são exibidas as sardas, na parte (b) a mancha senil e na parte (c) a mancha de gravidez.



Figura 2.2: Manchas: (a) sardas [16]; (b) mancha senil [17]; (c) mancha de gravidez [18]

As pintas são pequenos tumores formados pela falha na proliferação dos melanócitos, podendo surgir ao longo da vida ou estarem presentes desde o nascimento. Em sua maioria, os nevos são considerados lesões não malignas, porém há alguns que são considerados malignos [15]. As pintas não malignas podem ser classificadas em nevo juncional, nevo composto, nevo dérmico, nevo halo, nevo azul, nevo *spitz* e nevo *spilus*.

O primeiro tipo de nevo, juncional, possui formato oval ou elíptico com bordas lisas e regulares, disposto de maneira plana ou ligeiramente elevada na superfície. A cor predominante dessa lesão apresenta tons de marrom, porém pode ser identificada também pela cor preta. O nevo juncional varia entre um milímetro e um centímetro de diâmetro [15].

O nevo composto possui a forma de nódulo com superfície lisa ou arredondada, borda regular e bem definida, variando em tons de marrom ou semelhante à cor da pele e ter aproximadamente um centímetro de diâmetro [15].

O terceiro tipo, denominado nevo dérmico, geralmente possui formato arredondado e superfície lisa com aproximadamente um centímetro de diâmetro, aproximadamente. Esse tipo de nevo ocorre por causa da perda da capacidade de produção de pigmentação por parte das células, caracterizando um tom acastanhado [15].

O nevo halo é uma pápula marrom de cinco milímetros de diâmetro com um halo arredondado contendo a pinta no seu centro. Há casos em que o nevo pode desaparecer, mantendo apenas a área branca. Há também situações em que o nevo pigmentado é azul ou até mesmo um melanoma [15].

O nevo azul é constituído de uma pápula firme de formato arredondado e de cor azul escura que varia de cinco milímetros a três centímetros. Esse tipo de lesão ocorre geralmente na parte inferior das costas, nas nádegas ou no couro cabeludo [15].

O nevo *spitz* caracteriza-se pela cor rosada, medindo de um a dois centímetros, possuindo superfície lisa e fina. A ocorrência mais comum desse nevo é na infância [15].

E o nevo *spilus* se caracteriza pela cor castanha, podendo chegar até quinze centímetros de diâmetro. A cor varia por toda a extensão da lesão, portanto, têm-se regiões mais claras e regiões mais escuras. A principal ocorrência dessa lesão é no tronco e nos membros inferiores [15].

Os nevos descritos anteriormente são exibidos na figura (2.3), juncional, composto, dérmico, halo, azul, *spitz* e *spilus*, respectivamente. Os nevos juncionais, compostos e dérmicos formam os nevos melanocíticos, também conhecidos como nevos nevocíticos [19].




Figura 2.3: Nevos não malignos: (a) nevo juncional; (b) nevo composto; (c) nevo dérmico; (d) nevo halo; (e) nevo azul; (f) nevo *spitz*; (g) nevo *spilus* [15]

A ceratose seborréica geralmente é formada por pápulas verrucosas que podem aparecer isoladas ou em conjunto. A identificação dessa lesão é realizada pela cor em tons castanhos e recoberta de escamas que formam cistos na camada da epiderme. O tamanho da ceratose seborréica pode variar de um a três centímetros de diâmetro na fase inicial e alcançando até seis centímetros. A superfície é caracterizada por um aspecto gorduroso e pontilhados finos [16]. Essa lesão é comum e hereditária, ocorrendo mais em homens a partir dos 30 anos. Essas características podem ser verificadas na figura (2.4).




Figura 2.4: Ceratose seborréica [19]

2.2.2 - Lesões suspeitas

As lesões suspeitas são aquelas que possuem tendências a se tornarem lesões malignas. Por essa razão, essas lesões devem ser acompanhadas para que, se evoluírem, o tratamento se inicie rapidamente. Há dois tipos mais comuns de lesões suspeitas: nevo congênito e nevo displásico.

O nevo congênito é uma lesão não maligna com possibilidade de evoluir e se transformar em uma lesão maligna. Esse nevo pode ter tamanho variado, sendo que quanto menor for a lesão, menor a chance de evolução. A caracterização é realizada com a deformação da superfície da pele, apresentando pelos ou não e bordas tanto regulares quanto irregulares. A ocorrência pode acontecer em qualquer parte do corpo, com cores variando em tons de marrom e formato arredondado ou oval [15]. Na figura (2.5) é apresentado três lesões de nevos congênitos com tamanhos e formatos diferentes. Na parte (a), o nevo possui tamanho pequeno e formato mais arredondado. Na parte (b), o nevo possui tamanho grande e formato elíptico e, na parte (c), o tamanho é gigante.




Figura 2.5: Nevos congênitos: (a) nevo congênito de tamanho pequeno; (b) nevo congênito de tamanho grande; (c) nevo congênito de tamanho gigante [15]

O nevo displásico é composto geralmente por múltiplas lesões e pode alcançar dois centímetros de diâmetro. Esse nevo é frequentemente de tamanho maior e com mais variedade de cor se comparados com os nevos não malignos. Além disso, são lesões com assimetria e bordas irregulares, características importantes para a identificação dos melanomas [15]. O nevo displásico também é conhecido como nevo de Clark, nevo atípico ou nevo com desordem arquitetural [21]. Na figura (2.6) é exibido o nevo displásico.



Figura 2.6: Nevo displásico [20]

2.2.3 - Lesões malignas

Nas lesões malignas, o câncer de pele é o mais frequente. Essa lesão ocorre geralmente a partir dos 40 anos e é constituída pelo crescimento anormal e descontrolado das células que compõem a pele. A incidência em crianças e pessoas negras é rara, com exceção dos casos que apresentam alterações genéticas [22]. Existem três tipos de câncer de pele: carcinoma basocelular, carcinoma espinocelular e o melanoma [23].

O tipo mais comum é o carcinoma basocelular. Esse câncer praticamente não leva o paciente para a metástase e, portanto, se for detectado precocemente a sua cura é provável. A caracterização dessa lesão é por um nódulo rosado endurecido que mantém um crescimento lento [23]. Também pode ser caracterizado por uma ferida que não se cicatriza ou uma mancha que cresce continuamente [16]. Quando ocorre em locais vitais do corpo oferece grande risco ao paciente [15]. O desenvolvimento desse tipo de câncer de pele geralmente ocorre em pessoas com mais de 40 anos, de pele clara e que acumularam exposição solar durante toda a vida [22]. Na figura (2.7) observa-se uma lesão de pele que foi identificada

como carcinoma basocelular.



Figura 2.7: Carcinoma basocelular [24]

O carcinoma espinocelular é uma forma mais agressiva do que o basocelular e pode provocar metástase. Sem o tratamento adequado, o paciente pode sofrer invasões em estruturas vitais e mutilações importantes [23]. As causas de sua ocorrência podem variar desde uma exposição prolongada aos raios solares ou exposição às substâncias químicas, tabagismo ou, ainda, alterações na imunidade [22]. Esse tumor é caracterizado por um caroço de crescimento progressivo que apresenta uma ferida na superfície. Na figura (2.8), a lesão exibida foi identificada como carcinoma espinocelular.



Figura 2.8: Carcinoma espinocelular [24]

O mais perigoso e menos comum tipo de câncer de pele é o melanoma. O melanoma pode surgir em uma lesão pigmentada já existente ou na pele sem lesão. Essa lesão

ocasiona grande mortalidade e o diagnóstico precoce é imprescindível. A identificação acontece por meio de uma pinta com crescimento continuado e que altera suas características de modo repentino [23].

O melanoma, em sua fase inicial, apresenta crescimento radial, propagando-se através da superfície e, com isso, sendo pouco invasivo. Após essa fase, inicia-se o crescimento vertical, atingindo as outras camadas da pele e, conseqüentemente, os vasos sanguíneos [15]. Geralmente, o melanoma possui forma assimétrica, bordas irregulares, cor negra ou mista e diâmetro maior do que seis milímetros [22]. As características mencionadas para a identificação do melanoma são observadas na figura (2.9).



Figura 2.9: Melanoma [23]

2.3 - Métodos de identificação e classificação das lesões

A identificação das lesões citadas anteriormente é realizada através da análise de suas características. Para isso, duas técnicas são muito utilizadas pelos especialistas da área: a Regra ABCD e o Método dos Sete Pontos.

Na Regra ABCD são analisadas as características de assimetria, borda, cor e estruturas diferenciais. Hoje, essa regra recebeu a inclusão de um quinto parâmetro para a elevação e, com isso, ficou denominada como regra ABCDE. O parâmetro adicional, denominado evolução ou elevação (E), representa deformidades na superfície e também é uma referência ao histórico da lesão [15, 25].

No Método dos Sete Pontos é traçado um diagnóstico baseado em sete características: rede atípica pigmentada, véu azul-esbranquiçado, padrão vascular atípico, estrias irregulares, pontos e glóbulos irregulares, pigmentação irregular e estruturas de regressão [25, 26].

2.3.1 - Regra ABCD

Esta regra foi proposta como um guia para reconhecimento de possíveis melanomas em estágios iniciais de desenvolvimento. A regra inicial sugere a avaliação de quatro propriedades que essas lesões possuem: assimetria, borda, cor e estruturas diferenciais [27]. Esses atributos fornecem informações para a verificação de potencialidade de a lesão ser melanômica, denominada como Pontuação Dermoscópica Total, *PDT* [25, 28]. Essa medida classifica a lesão como não maligna, suspeita ou maligna.

Para cada parâmetro há uma pontuação e um fator de peso. Com a atribuição desses fatores, o *PDT* é calculado e a lesão é classificada. Na equação (2.1), o parâmetro *A* refere-se à assimetria, *B* à borda, *C* à cor e *D* às estruturas diferenciais. Quando o *PDT* possui valores inferiores a 4,75 a lesão é classificada como não maligna. Para casos entre 4,75 e 5,75 a lesão é suspeita e, para valores acima de 5,75, a lesão é maligna [25, 28].

$$PDT = A * 1,3 + B * 0,1 + C * 0,5 + D * 0,5 \quad (2.1)$$

A assimetria possui variação de pontuação entre zero e dois pontos. Essa pontuação é feita baseando-se na divisão da lesão em dois eixos perpendiculares. Quando a lesão é completamente simétrica, a pontuação vale zero. Para assimetria em apenas um eixo a pontuação vale um e, caso a assimetria seja nos dois eixos, a pontuação desse parâmetro equivale ao valor dois [25]. Na figura (2.10), a primeira lesão, figura (2.10a), é caracterizada por simetria nos dois eixos perpendiculares. A segunda lesão, figura (2.10b), é assimétrica em um dos eixos e na terceira lesão, figura (2.10c), há assimetria nos dois eixos traçados.




Figura 2.10: Assimetria: (a) simetria; (b) assimetria em um eixo; (c) assimetria em dois eixos [25]

A borda possui uma variação de zero a oito pontos. A lesão é, então, dividida em oito segmentos iguais e cada corte abrupto encontrado na borda das regiões definidas pelos segmentos equivale a um ponto [25]. Na figura (2.11), a primeira imagem, parte (a), é de uma lesão sem cortes abruptos, caracterizando uma borda regular. Na segunda imagem, figura (2.11b), há uma diferenciação entre as regiões de bordas formadas, caracterizando uma borda irregular.




Figura 2.11: Borda: (a) borda regular; (b) borda irregular [25]

A avaliação do parâmetro cor analisa a presença de seis cores na lesão. Cada cor identificada equivale a um ponto para o parâmetro. As cores são branca, vermelha, marrom claro, marrom escuro, preta e azul. A cor branca só deve ser analisada se a lesão estiver mais clara que a cor da pele do paciente. Geralmente, os melanomas apresentam três ou mais cores.

As estruturas diferenciais consideram a presença de rede pigmentada, áreas homogêneas, estrias, pontos e glóbulos. As estrias e pontos são contados apenas quando existem mais de dois desses elementos claramente visíveis. Para os glóbulos basta existir um elemento. A pontuação varia de um a cinco pontos, sendo que cada estrutura identificada recebe uma unidade de valor [25, 28].

2.3.2 - Método dos Sete Pontos

As sete características deste método são divididas em dois grupos: principal e secundário. No grupo das principais, as características são rede atípica pigmentada, véu azul-esbranquiçado e rede vascular. Para o outro grupo, as secundárias, as características são estrias irregulares, pigmentação irregular, glóbulos irregulares e estruturas de regressão [25]. As características do grupo principal possuem peso dois no cálculo final e as demais possuem peso um. Para cada atributo encontrado na lesão, realiza-se a soma dos pesos e, caso atinja o valor de sete pontos, a identificação do melanoma é confirmada [26].

A rede atípica pigmentada caracteriza-se por apresentar cores em tons de preto, castanho-claro ou cinza, distribuídas de forma irregular por toda a lesão. O véu azul-esbranquiçado é uma pigmentação que varia em tons de azul e sua presença é associada aos melanomas e nevos azuis. Portanto, a presença dessa característica é um fator importante para o diagnóstico. A presença de estruturas vermelhas lineares, pontilhadas ou globulares de forma irregular caracteriza o padrão vascular atípico. Esse fator pode indicar a presença de vasos sanguíneos na lesão, o que possibilita o crescimento de um tumor maligno.

As estrias irregulares são identificadas pela espessura variável das linhas da rede pigmentada por toda a lesão. Os glóbulos irregulares são usualmente circulares ou ovais com coloração variando entre o preto, tons de castanho ou cinza. Geralmente, os glóbulos irregulares estão localizados nas regiões extremas das lesões podendo apresentar tamanhos e formas variáveis [25, 26]. A presença de várias cores na lesão, distribuídas de forma irregular, mostra a existência de pigmentação irregular. E a última característica analisada neste método, estruturas de regressão, é identificada pela associação de regiões brancas com aspecto de cicatriz em relação às regiões de cor azul.

3 - PROCESSAMENTO DIGITAL DE IMAGENS

Neste capítulo são apresentados os conceitos de processamento de imagens, como as etapas do processo, vizinhança, conectividade, distâncias métricas, filtros, morfologia matemática e modelos de cor. Em seguida são descritas as técnicas utilizadas no desenvolvimento do projeto, assim denominadas: o filtro de difusão anisotrópica, a transformada imagem-floresta, o classificador de floresta de caminhos ótimos e a dimensão fractal.

3.1 - Conceitos básicos

O processamento digital de imagens consiste na execução de operações matemáticas para extrair informações que serão analisadas e utilizadas em alguma área do conhecimento humano. Hoje existem muitas técnicas e métodos desenvolvidos que funcionam adequadamente para algumas situações e são compostos de algoritmos implementados em *softwares* [29].

O processo inicia-se com a aquisição de uma imagem capturada de forma bidimensional. A imagem capturada possui informações em forma de sinais elétricos que são descritos no tempo contínuo. Uma vez que a computação funciona com tempo discreto é necessário fazer a conversão dos sinais [30]. Atualmente essa conversão é desnecessária devido ao uso de câmeras digitais que já captam o sinal de modo discreto [29].

A imagem digital necessita de melhorias na sua qualidade. Por essa razão, antes de se fazer o processamento das informações é importante realizar um tratamento que visa a remoção de ruídos. Nessa etapa são aplicados alguns filtros que, além da remoção de ruídos, procura melhorar o contraste para facilitar o encontro das regiões de interesse [29].

Após a aplicação do filtro, a imagem estará pronta para o processo de segmentação. A segmentação consiste em encontrar os grupos de *pixels* que formam os objetos e o fundo da imagem. O objeto é a informação desejada no processo e o fundo é composto pelos *pixels* que serão desprezados. Com a segmentação finalizada, a imagem estará pronta para o processo de extração de características e a classificação dos objetos.

Uma imagem digital $f(x, y)$ é composta por uma matriz de linhas e colunas, em que cada célula corresponde a um ponto denominado *pixel*. Estes *pixels* possuem propriedades como vizinhança, conectividade e distâncias métricas [31].

3.1.1 - Vizinhança

A vizinhança de um *pixel* p é composta por dois vizinhos verticais e dois vizinhos horizontais. Dado um ponto p de coordenadas (x, y) , os vizinhos deste ponto p terão coordenadas $(x + 1, y)$, $(x - 1, y)$, $(x, y + 1)$ e $(x, y - 1)$. Essa vizinhança é conhecida por $N_4(p)$. Com o acréscimo dos vizinhos diagonais ao ponto p , a vizinhança passa a ser chamada de $N_8(p)$. As coordenadas $(x - 1, y - 1)$, $(x - 1, y + 1)$, $(x + 1, y - 1)$ e $(x + 1, y + 1)$ são, então, incorporadas à vizinhança [31, 32]. Os três tipos de vizinhança de um *pixel* p são exibidos na figura (3.1), sendo que os vizinhos são ilustrados com a cor cinza.




Figura 3.1: Representação de: (a) 4-vizinhança; (b) vizinhança diagonal; (c) 8-vizinhança [31]

3.1.2 - Conectividade

A conectividade é utilizada para estabelecer os limites dos objetos na imagem. A conexão de dois *pixels* acontece se eles forem adjacentes de alguma maneira e se seus níveis de cinza satisfazem a um critério qualquer. Essa propriedade pode acontecer de três maneiras. Definindo dois *pixels* quaisquer de uma imagem p e q com valores contidos no conjunto V de tons de cinza, eles possuem 4-conectividade se estão contidos em V e $q \in N_4(p)$. Para o caso de 8-conectividade, os dois pontos devem ter valores em V e $q \in N_8(p)$. A conectividade mista de dois *pixels* acontecerá se eles estiverem contidos em V e $q \in N_4(p)$ ou $q \in N_d(p)$ e $N_4(p) \cap N_d(q) = \emptyset$ [31, 32]. As três conectividades citadas são mostradas na figura (3.2).




Figura 3.2: Conectividade: (a) de 4; (b) de 8; (c) mista

3.1.3 - Distâncias métricas

As distâncias métricas entre dois *pixels* p e q de coordenadas (x, y) e (s, t) , respectivamente, podem ser calculadas por três métodos. A distância euclidiana D_e forma um círculo centrado para o cálculo definido na equação (3.1). A distância *city-block*, também chamada de D_4 , forma um losango cujo valor é calculado por módulos, como na equação (3.2). E a distância *chessboard* D_8 forma um quadrado centrado na origem, definida na equação (3.3).

$$D_e(p, q) = \sqrt{(x - s)^2 + (y - t)^2} \quad (3.1)$$

$$D_4(p, q) = |x - s| + |y - t| \quad (3.2)$$

$$D_8(p, q) = \max(|x - s|, |y - t|) \quad (3.3)$$

As formações geométricas geradas pelas distâncias calculadas anteriormente entre dois pontos são ilustradas na figura (3.3).




Figura 3.3: Distâncias: (a) euclidiana; (b) *city-block*; (c) *chessboard*

3.2 - Filtros

A filtragem é realizada por meio de máscaras que são aplicadas à imagem digitalizada e pode ser classificada como filtros lineares ou não lineares. Os filtros lineares se baseiam em uma função de transferência relacionada à sua função de resposta por meio da transformada de Fourier. Se essa condição não é atendida, o filtro é classificado como não linear [31].

Os filtros do tipo passa-baixa consistem em atenuar ou eliminar as componentes de alta frequência no domínio da transformada de Fourier. As altas frequências correspondem às regiões de borda e, portanto, seu uso tem o efeito de suavização, provocando um leve borramento na imagem. Os filtros do tipo passa-alta se caracterizam pelo processo inverso. A aplicação desse tipo de filtro causa a atenuação ou eliminação das componentes de baixa frequência, realçando as bordas e regiões de alto contraste da imagem [31].

Entre os filtros mais simples estão o filtro da média e o filtro da mediana. O filtro da média utiliza-se de uma máscara composta por uma matriz quadrada com todos os

coeficientes com valores iguais a um. A essa matriz multiplica-se o valor do *pixel* pelo seu respectivo coeficiente. Com isso, somam-se os valores resultantes e multiplica-se por um valor fracionário, em que o numerador também é um e o denominador é a quantidade de coeficientes da matriz.

O filtro da mediana utiliza-se do cálculo da mediana dos vizinhos do *pixel* para encontrar o valor resultante, por isso não faz uso de convolução. Quando a máscara se situa sobre o *pixel*, os valores de seus vizinhos devem ser ordenados e o elemento mais central é o valor atribuído para o *pixel* central [31]. Em situações na qual a quantidade de elementos é par, a mediana será a média aritmética dos dois elementos mais centrais.

3.3 - Morfologia Matemática

A morfologia matemática pode ser aplicada em muitas áreas do processamento de imagens como realce, filtragem, segmentação, esqueletização, afinamento e detecção de bordas, entre outras. Essa técnica consiste em extrair informações de uma imagem a partir da transformação realizada com um elemento estruturante descrito por um conjunto definido [31]. Duas importantes operações da morfologia matemática são a dilatação e a erosão.

O elemento estruturante é um conjunto definido em forma e tamanho utilizado no processo de transformação. O formato e o tamanho são modificados de acordo com as propriedades geométricas dos objetos que serão processados na imagem [33]. Como as imagens são bidimensionais, o elemento estruturante também assume essa forma, porém com tamanho muito menor que a resolução da imagem analisada. Os valores atribuídos a esses conjuntos dependem do tipo de abordagem desejada.

A dilatação de um conjunto A , imagem, por B , elemento estruturante, é definida por $A \oplus B$. Estes dois conjuntos não vazios estão no espaço $\mathbb{Z}^2$. O processo da dilatação consiste em obter a reflexão de B sobre a sua origem e depois realizar a translação dessa reflexão por x . A dilatação é, então, o conjunto de todos os deslocamentos para os quais a intersecção de $\hat{B}$ e A sobreponham-se, ao menos, um elemento não nulo [31, 32]. A dilatação permite aumentar o objeto, preencher pequenos buracos e conectar objetos próximos [33]. O processo da dilatação é definido na equação (3.4).

$$A \oplus B = \{x / [(B)_x \cap A] \subseteq A\} \quad (3.4)$$

A erosão também é denotada pelos conjuntos A e B pertencentes ao espaço $\mathbb{Z}^2$. Esse processo indica que $A \ominus B$ é composto por todos os conjuntos x tais que B trasladado de x está contido em A , como definido na equação (3.5) [31, 32]. A erosão é muito utilizada para diminuir os objetos, eliminar objetos menores do que o elemento estruturante, aumentar buracos e permitir a separação de objetos próximos [33].

$$A \ominus B = \{x / (B)_x \subseteq A\} \quad (3.5)$$

Duas outras importantes operações morfológicas são a abertura e o fechamento. A abertura é utilizada geralmente para suavizar o contorno das imagens e, com isso, pequenos istmos são quebrados e as proeminências delgadas são eliminadas. A operação de fechamento, ao contrário da abertura, é empregada para fundir pequenas quebras e alargar golfos estreitos, eliminando pequenos orifícios e preenchendo lacunas no contorno. O resultado da erosão seguido da dilatação pelo elemento estruturante B define a abertura. Entretanto, o fechamento é denotado pela dilatação seguida da erosão pelo elemento estruturante [31, 32].

3.4 - Modelos de cor

Os modelos de cor são especificados em um sistema de coordenadas tridimensionais e cada cor é uma combinação dos valores dessas coordenadas. Esses modelos são utilizados para qualificar uma cor de acordo com alguns atributos como tonalidade, saturação e brilho [34]. Os modelos mais utilizados são o RGB para os monitores e câmeras fotográficas, o YIQ para as televisões coloridas e o HSI para a manipulação de imagens coloridas [32].

Uma técnica de grande importância que pode ser aplicada aos modelos de cor é a quantização de cores. Essa técnica é usada para reduzir a quantidade de cores em uma

imagem e consiste em duas etapas. Na primeira etapa é necessário realizar a divisão do espaço de cores em intervalos e, na segunda etapa, substitui-se a intensidade de cada *pixel* pelo menor valor ou pelo valor médio do intervalo a que ela pertence. Dessa forma, a quantidade de cores utilizada no processo é a quantidade de intervalos existentes [35]. Em imagens coloridas, este processo deve acontecer em todas as componentes.

3.4.1 - Modelo RGB

No modelo de cor RGB, as cores são representadas em sua forma espectral primária de vermelho, verde e azul em um sistema de coordenadas cartesianas com cada plano definido independentemente um do outro. Nesse modelo, a definição das demais cores acontece com a combinação dos valores das três coordenadas, no qual se obtém a cor ciana com a ausência total do vermelho, a cor magenta com a ausência total do verde e a cor amarela com a ausência total do azul. A representação da cor preta é dada pela ausência total das três cores e a cor branca pela presença total das três cores. Nesse modelo, a escala de cinza estende-se do preto até o branco [31, 32]. Na figura (3.4), o subespaço de cores definido no modelo RGB é exibido.




Figura 3.4: Modelo RGB [31]

3.4.2 - Modelo YIQ

O modelo YIQ é o padrão das transmissões de televisão colorida que funciona como uma recodificação do RGB para uma maior eficiência e compatibilidade para os padrões monocromáticos. Esse modelo foi desenvolvido para separar a componente de brilho, que permite maior sensibilidade à visão humana, das componentes de cromaticidade. Dessa forma, pode-se aprimorar o contraste sem distorcer as informações de matiz e saturação da imagem original, eliminando as influências de luminosidade. Esta característica faz o modelo YIQ ser muito utilizado na filtragem de luz e sombras em imagens [31, 32].

A conversão do modelo RGB para o modelo YIQ é obtida por meio do uso de multiplicação de matrizes. Essa relação é descrita na equação (3.6).

$$\begin{bmatrix} Y \\ I \\ Q \end{bmatrix} = \begin{bmatrix} 0,299 & 0,587 & 0,114 \\ 0,596 & -0,275 & -0,321 \\ 0,212 & -0,523 & 0,311 \end{bmatrix} * \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (3.6)$$

3.4.3 - Modelo HSI

No modelo HSI é tratado as componentes de matiz, saturação e intensidade. O matiz descreve o grau de pureza da cor e a saturação descreve o grau de diluição dessa cor pela luz branca. Esse modelo é muito importante no processamento de imagens por desassociar a intensidade da cor na imagem e por relacionar o matiz e a saturação à percepção humana das cores [32].

A conversão do modelo RGB para HSI é exibido nas equações (3.7) para a componente de matiz, na equação (3.8) para a componente de saturação e na equação (3.9) para a intensidade.

$$H = \cos^{-1} * \frac{((R - G) + (R - B))/2}{\sqrt{(R - G)^2 + (R - B) * (G - B)}} \quad (3.7)$$

$$S = 1 - \frac{3}{R + G + B} * \min(R, G, B) \quad (3.8)$$

$$I = \frac{R + G + B}{3} \quad (3.9)$$

A equação (3.8), que trata a componente de saturação, é válida somente se $I > 0$. Caso contrário, $S = 0$. Após o cálculo do matiz, na equação (3.7), deve-se verificar se $B > G$ e, em caso afirmativo, realizar $H = 360 - H$.

Outros modelos, como o HSV e o HSL, são similares ao modelo HSI e tratam a luminância e luminosidade, respectivamente, variando de zero (cor preta) a um (cor branca). A luminância será o máximo entre as três componentes do modelo RGB e a luminosidade é a média entre o valor máximo e mínimo das componentes do modelo RGB.

3.5 - Filtro de Difusão Anisotrópica

Um filtro de difusão consiste em submeter uma imagem original $I(x, y)$ numa família de imagens derivadas $I(x, y; t)$ obtidas pela convolução da imagem original com o filtro gaussiano $G(x, y; t)$ com variância de tempo t [36]. Essa relação é mostrada na equação (3.10).

$$I(x, y; t) = I_0(x, y) * G(x, y; t) \quad (3.10)$$

Nessa definição é mostrada que dada uma imagem original qualquer, novas imagens serão geradas sempre a partir da imagem anterior até atingir a imagem ótima. Esse processo acontece aplicando uma função gaussiana G para gerar a máscara de convolução utilizada na iteração.

Os modelos de filtros baseados na equação de difusão buscam obter suavização e ao mesmo tempo manter as fronteiras dos objetos contidos na imagem. Porém, nas regiões onde o processo de difusão é muito intenso, as fronteiras originais da imagem são perdidas. Para solucionar essa questão, o filtro de difusão anisotrópica foi desenvolvido com a proposta de suavizar completamente as regiões internas e superficialmente as regiões de bordas [37].

O filtro de difusão anisotrópica é do tipo não linear e permite a suavização seletiva da imagem por meio de iterações que são definidas de acordo com a quantidade de ruídos presentes na imagem utilizando convolução com máscara adaptativa, ou seja, inibe a suavização em *pixels* de borda e estimula a suavização em regiões internas da imagem usando uma máscara que se altera conforme as propriedades definidas na iteração atual [38]. Esse filtro é muito utilizado para tratar a remoção de ruídos, melhorando, assim, determinadas características da imagem.

O filtro em si consiste em aplicar um processo orientado por propriedades locais na imagem utilizando um modelo que inibe problemas de borramento e localização, fazendo com que as bordas permaneçam mesmo após filtragens consecutivas. Para conseguir inibir a suavização nos *pixels* da borda é necessário aplicar um processo não uniforme que reduza a difusividade nos locais mais prováveis de serem bordas [38].

Porém, o filtro possui algumas desvantagens em sua utilização. Como o filtro inibe a suavização nos *pixels* da borda, os ruídos existentes nela não são eliminados. Outro fator importante é que, por ser um método iterativo, seu processamento acaba sendo computacionalmente intenso. Para cada iteração do processo, o coeficiente de difusão deve ser calculado em cada *pixel* com base na sua vizinhança. Para que não se tenha perda de informações relevantes deve-se controlar a quantidade de iterações que o filtro executará.

3.5.1 - Processo físico da difusão anisotrópica e definição do filtro

A difusão é um processo físico que equilibra diferenças de concentração sem criar ou destruir massa. A partir disso, na Lei de Fick é mostrado que um gradiente de concentração ∇u provoca um fluxo j que é compensado por um tensor de difusão D , como mostrado na equação (3.11) [39].

$$j = -D * \nabla u \quad (3.11)$$

Com isso, pode-se aplicar um operador de divergência *div* no fluxo resultante. Na equação de continuidade da difusão (3.12) é mostrado que em um determinado tempo t esse operador atua no fluxo estabelecido [39].

$$\partial_t u = -div(j) \quad (3.12)$$

Com as duas equações definidas, obtém-se a equação de difusão original (3.13).

$$\partial_t u = div(D * \nabla u) \quad (3.13)$$

Na equação (3.13), o termo u caracteriza a concentração e D expressa o tensor de difusão que é utilizado para definir a intensidade do fluxo juntamente com o gradiente da concentração ∇u . Caso o gradiente de concentração e o fluxo sejam paralelos, eles são chamados de isotrópicos. Caso contrário, um valor escalar positivo de difusividade g é definido considerando o gradiente da concentração. Esse valor leva em consideração a probabilidade de um ponto fazer parte ou não de uma borda, como descrito na equação (3.14).

$$u_t = div(g(\nabla u) * \nabla u) \quad (3.14)$$

A equação (3.14) foi proposta por Perona e Malik para representar um método de difusão não linear que reduz a difusividade em locais com grande probabilidade de serem bordas. O modelo não linear utiliza a difusão de maneira adaptativa, ou seja, com máscaras que são geradas a cada iteração no processo, ao contrário da maneira linear que utiliza a difusividade escalar [39].

A equação de difusão de Perona e Malik considera três critérios: casualidade, localização imediata e suavização por partes [40]. No critério de casualidade é considerado

que nenhum detalhe espúrio será gerado quando a resolução da imagem for diminuída. A cada resolução gerada, as regiões de contorno devem ser bem definidas para a localização imediata. E, na suavização por partes, ela deve acontecer principalmente nas partes internas da imagem.

Para definir a equação (3.14), Perona e Malik usaram a equação (3.13) relacionando-a como na equação (3.15), com o parâmetro c sendo uma constante independente da localização no espaço [40]. Dessa forma, conclui-se que esse parâmetro representa o tensor da difusão da equação (3.13).

$$\partial_t u = \text{div}(D * \nabla u) = \text{div}(c(x, y, t) * \nabla u) \quad (3.15)$$

Para garantir que a região a ser suavizada será a área interna, o valor que o parâmetro c deve assumir é um. Caso o valor seja zero, indica que está sobre a borda. Com isso, define-se uma função g que calcula a posição estimada do ponto $\nabla u(x, y, t)$.

$$c(x, y, t) = g(\|\nabla u(x, y, t)\|) \quad (3.16)$$

Substituindo $g(\|\nabla u(x, y, t)\|)$ da equação (3.16) na equação (3.15) obtém-se:

$$\partial_t u = \text{div}(D * \nabla u) = \text{div}(g(\|\nabla u(x, y, t)\|) * \nabla u) \quad (3.17)$$

A partir da equação (3.17) obtém-se a equação (3.14). A equação de difusão sofreu algumas alterações para ter uma melhor aproximação no resultado final da imagem. A equação de Perona e Malik [40] foi adaptada por Alvarez, Lions e Morel [41] resultando na equação (3.18).

$$u_t = g * |\nabla u| * \text{div}\left(\frac{\nabla u}{|\nabla u|}\right) \quad (3.18)$$

Adicionalmente a essa alteração, Nordström [42] propôs o termo $(u - I)$ para que as bordas fossem preservadas e Barcelos, Boaventura e Silva Júnior [43] propuseram a inserção de um termo de moderação $(1 - g)$ para fazer o balanceamento entre o termo de Nordström e o termo de difusão. A expressão ficou definida como na equação (3.19).

$$u_t = g * |\nabla u| * \operatorname{div} \left(\frac{\nabla u}{|\nabla u|} \right) - \lambda * (1 - g) * (u - I) \quad (3.19)$$

Na equação (3.19), u é a imagem suavizada com escala de suavização na iteração t que deverá ser sempre maior que zero. A equação tem por base a imagem original I , um parâmetro de velocidade da difusão λ que atua como peso, o operador de divergência div e o valor de gradiente de u , ∇u . O termo g é uma função de suavização gaussiana, tal que $g(0) = 1$, $g(s) \geq 0$ e $g(s) \rightarrow 0$, quando $s \rightarrow \infty$ [40, 44].

Baseando-se nessas definições, quando o valor de g é equivalente a um, a região precisa ser fortemente suavizada e quando é equivalente a zero, a região não pode ser suavizada. A função de suavização g pode ser definida utilizando uma constante k e uma função gaussiana G_T [35], como na equação (3.20).

$$g = \frac{1}{1 + k * |\nabla (G_T u)|^2} \quad (3.20)$$

O termo $|\nabla (G_T u)|$ deve ser calculado para encontrar a média ponderada dos níveis de cores na vizinhança de um determinado *pixel* por meio do cálculo das derivadas de primeira ordem. Com isso, o produto da convolução conv é obtido pela equação (3.21).

$$\operatorname{conv}(i, j) = (G_T u)(i, j) \quad (3.21)$$

Para calcular o produto da convolução é necessário realizar a média dos pontos no eixo x e no eixo y . O cálculo do eixo x toma por base o ponto anterior $(i - 1)$ e posterior

$(i + 1)$ do eixo j . O cálculo do eixo y funciona de maneira similar para o ponto anterior $(j - 1)$ e posterior $(j + 1)$ do eixo i . Cada cálculo efetuado resulta em uma constante para o ponto em questão. Na figura (3.5) é exibido a localização dos pontos adjacentes a uma localização (i, j) qualquer na imagem.




Figura 3.5: Localização dos pontos adjacentes ao ponto (i, j)

Na equação (3.22), utilizando o operador de diferenças centradas, é obtido o produto da convolução no eixo x e na equação (3.23) para o eixo y [35].

$$\frac{\partial conv_{(i,j)}}{\partial x} \cong \frac{conv_{(i+1,j)} - conv_{(i-1,j)}}{2} = c_1 \quad (3.22)$$

$$\frac{\partial conv_{(i,j)}}{\partial y} \cong \frac{conv_{(i,j+1)} - conv_{(i,j-1)}}{2} = c_2 \quad (3.23)$$

Com as definições das duas constantes anteriores pode-se retomar o cálculo do termo $\nabla(G_T u)$ em questão, obtendo o seguinte resultado na equação (3.28) [35]:

$$\nabla(G_T u) = \left(\frac{\partial conv}{\partial x}, \frac{\partial conv}{\partial y} \right) \quad (3.24)$$

$$|\nabla(G_T u)| = \sqrt{\left(\frac{\partial conv}{\partial x} \right)^2 + \left(\frac{\partial conv}{\partial y} \right)^2} \quad (3.25)$$

$$|\nabla(G_T u)| = \sqrt{\left(\frac{\partial G_T u}{\partial x}\right)^2 + \left(\frac{\partial G_T u}{\partial y}\right)^2} \quad (3.26)$$

$$|\nabla(G_T u)| = \sqrt{c_1^2 + c_2^2} \quad (3.27)$$

$$|\nabla(G_T u)|^2 = c_1^2 + c_2^2 \quad (3.28)$$

Substituindo o resultado da equação (3.28) na equação de suavização descrita em (3.20), obtém-se a equação (3.29).

$$g = \frac{1}{1 + k * (c_1^2 + c_2^2)} \quad (3.29)$$

A equação (3.29) passou a ser discreta e, portanto, passível de ser implementada computacionalmente. Porém, para que esse método seja completamente implementado é necessário discretizar outro termo da equação de difusão, o termo de difusão exibido em (3.30) [35]:

$$|\nabla u| * \operatorname{div} \left(\frac{\nabla u}{|\nabla u|} \right) \quad (3.30)$$

O termo de difusão também pode ser expresso como na equação (3.31).

$$|\nabla u| * \operatorname{div} \left(\frac{\nabla u}{|\nabla u|} \right) = \frac{u_x^2 u_{yy} - 2u_x u_y u_{xy} + u_y^2 u_{xx}}{u_x^2 + u_y^2} \quad (3.31)$$

Para obter os valores que compõem esse termo, é preciso utilizar os operadores de diferenças centradas, obtendo os valores de u_x e u_y em (3.32) e (3.33), respectivamente.

$$u_x \cong \frac{u_{(i+1,j)} - u_{(i-1,j)}}{2} \quad (3.32)$$

$$u_y \cong \frac{u_{(i,j+1)} - u_{(i,j-1)}}{2} \quad (3.33)$$

Continuando o desenvolvimento do termo de difusão, o valor da concentração u de x em relação a y é definido utilizando derivada parcial mista e, com isso, obtém-se a equação (3.36).

$$u_{xy} \cong \frac{(u_x)_{j+1} - (u_x)_{j-1}}{2} \quad (3.34)$$

$$u_{xy} \cong \frac{\frac{u_{(i+1,j+1)} - u_{(i-1,j+1)}}{2} - \frac{u_{(i+1,j-1)} - u_{(i-1,j-1)}}{2}}{2} \quad (3.35)$$

$$u_{xy} \cong \frac{u_{(i+1,j+1)} - u_{(i-1,j+1)} - u_{(i+1,j-1)} + u_{(i-1,j-1)}}{4} \quad (3.36)$$

Usando derivadas de segunda ordem em relação a x e a y , obtém-se:

$$u_{xx} \cong u_{(i+1,j)} - 2u_{(i,j)} + u_{(i-1,j)} \quad (3.37)$$

$$u_{yy} \cong u_{(i,j+1)} - 2u_{(i,j)} + u_{(i,j-1)} \quad (3.38)$$

Assim, obtém-se todos os termos que compõem o termo da difusão, equação (3.31). Com as definições anteriores, a equação de difusão apresentada na equação (3.19) pode ser reescrita por uma aproximação numérica discreta implementada computacionalmente como apresentada na equação (3.39).

$$\begin{aligned}
u_{i,j}^{t+1} = u_{i,j}^t + \Delta t * & \left[g * \frac{\left(\frac{u_{i+1,j}^t - u_{i-1,j}^t}{2} \right)^2 * (u_{i,j+1}^t - 2u_{i,j}^t + u_{i,j-1}^t)}{\left(\frac{u_{i+1,j}^t - u_{i-1,j}^t}{2} \right)^2 + \left(\frac{u_{i,j+1}^t - u_{i,j-1}^t}{2} \right)^2} \right] \\
- \Delta t & \left[g * \frac{(u_{i+1,j}^t - u_{i-1,j}^t) * (u_{i,j+1}^t - u_{i,j-1}^t) * \left(\frac{u_{i+1,j+1}^t - u_{i+1,j-1}^t - u_{i-1,j+1}^t + u_{i-1,j-1}^t}{2} \right)}{\left(\frac{u_{i+1,j}^t - u_{i-1,j}^t}{2} \right)^2 + \left(\frac{u_{i,j+1}^t - u_{i,j-1}^t}{2} \right)^2} \right] \\
+ \Delta t & \left[g * \frac{\left(\frac{u_{i,j+1}^t - u_{i,j-1}^t}{2} \right)^2 * (u_{i+1,j}^t - 2u_{i,j}^t + u_{i-1,j}^t)}{\left(\frac{u_{i+1,j}^t - u_{i-1,j}^t}{2} \right)^2 + \left(\frac{u_{i,j+1}^t - u_{i,j-1}^t}{2} \right)^2} - \lambda * (1 - g) * (u_{i,j}^t - I) \right] \quad (3.39)
\end{aligned}$$

A imagem gerada $u_{i,j}^{t+1}$ apresenta o resultado da aplicação da imagem original I no tempo $t + 1$, sendo que t varia de $1, 2, \dots, N$. A definição do tempo t pode ser definida por um valor fixo de iterações desejadas ou por meio do cálculo de um valor ótimo baseado na quantidade de ruído existente.

3.5.2 - Função gaussiana e tempo ótimo de suavização

A quantidade de iterações necessárias para a execução do filtro é uma variável crucial nesse processo. No filtro de difusão anisotrópica, a necessidade de interromper o processo é realizada por causa do alto custo computacional, pois a imagem pode continuar sofrendo a filtragem sem ser degenerada após o ponto de parada [37].

Por conta disso, Silva Júnior [37] propôs uma relação para calcular o tempo ótimo de suavização T_o necessário para atingir o grau de suavização adequado e eficiente em uma imagem. Essa relação é exibida na equação (3.40).

$$T_o = \frac{\sigma^2}{a} \quad (3.40)$$

Na equação (3.40) é relacionado o desvio padrão do ruído da função gaussiana da imagem σ com a constante a contida no núcleo de suavização gaussiana. Esse desvio também é relacionado com a evolução na escala temporal t , como na equação (3.41).

$$\sigma^2 = 2 * t \quad (3.41)$$

A função gaussiana utilizada é descrita na equação (3.42).

$$G_t(x, y) = \frac{1}{2 * a * \pi * t} * e^{\frac{-(x^2 + y^2)}{2 * a * t}} \quad (3.42)$$

Com isso, a função de suavização gaussiana pode ser escrita como na equação (3.43).

$$G_t(x, y) = \frac{1}{a * \pi * \sigma^2} * e^{\frac{-(x^2 + y^2)}{a * \sigma^2}} \quad (3.43)$$

Essa função fornece filtros passa-baixa e, como os ruídos são altas frequências, esses sinais são eliminados durante o processo de filtragem [37].

3.6 - Transformada Imagem-Floresta

A transformada imagem-floresta, proposta por Falcão, Stolfi e Lotufo [45], é uma técnica para modelar, implementar e avaliar operadores de processamento de imagens baseados em conectividade. O algoritmo desta técnica é essencialmente o algoritmo de menor caminho de Dijkstra [46] modificado para múltiplas origens. A definição da transformada imagem-floresta é independente da natureza dos *pixels* e da dimensão da imagem, podendo

ser aplicada em imagens coloridas de altas dimensões e até mesmo em sequências de vídeo [45].

Esse modelo de segmentação reduz problemas no cálculo de uma floresta de caminhos ótimos em um grafo derivado da imagem. Os caminhos são calculados por uma função dependente da aplicação e com base em propriedades da imagem [47]. A busca por caminhos ótimos é dependente do conjunto de *pixels* iniciais, marcados como nós sementes. As sementes competem pelos vértices do grafo e geram as regiões internas e externas à área de interesse que delimita o objeto desejado. Para que esse processo ocorra é importante escolher sementes dentro e fora da área de interesse [48].

Dada uma imagem $\hat{I} = (D_I, I)$ que pode ser visualizada como um grafo cujos nós são as amostras (*pixels*) e as arestas são definidas por uma relação de adjacência qualquer A , um caminho é uma sequência de amostras $\pi_{sk} = \langle s_1, s_2, \dots, s_k \rangle$, onde $(s_i, s_{i+1}) \in A$ para $1 \leq i \leq k - 1$. Um caminho é trivial se $\pi_s = \langle s \rangle$. A cada caminho π_s é associado um valor dado por uma função de valor de caminho suave $f(\pi_s)$. Um caminho π_s é considerado ótimo se $f(\pi_s) \leq f(\tau_s)$ para qualquer caminho τ_s , onde π_s e τ_s terminam na mesma amostra s , independente de sua origem. A concatenação do caminho π_s com término em s e arco (s, t) é denotado por $\pi_s \cdot \langle s, t \rangle$ [47].

Na figura (3.6) são exibidas três formas de relação de adjacência euclidiana. Na parte (a), o ponto central s possui conectividade com seus quatros vizinhos e estabelece a distância $d(s, t) = 1$. A conectividade do ponto central s com seus oito vizinhos é dado pelo acréscimo de $d(s, t) = \sqrt{2}$ em (b). E, na parte (c), a relação de adjacência é acrescida por $d(s, t) = \sqrt{5}$, estabelecendo uma conectividade mais complexa [45].




Figura 3.6: Relações de adjacência: conectividade (a) de 4; (b) de 8; (c) complexa [47]

A função de valor de caminho f é suave quando existe um caminho ótimo π_t trivial ou quando possui a forma $\pi_s \cdot \langle s, t \rangle$ para qualquer amostra t , sendo que na relação $f(\pi_s) \leq f(\pi_t)$ o valor de π_s é ótimo e, para qualquer caminho ótimo τ_s definido, a relação $f(\tau_s \cdot \langle s, t \rangle) = f(\pi_t)$ é verdadeira [44]. Essa função determina o custo do caminho entre dois nós e denota a diferença entre os valores dos *pixels*. Portanto, os *pixels* que possuem valores próximos terão custos menores e tendem a ter um grau de similaridade maior [48].

Como a busca por caminhos ótimos na transformada imagem-floresta restringe a quantidade de nós ao conjunto S de nós sementes, esse conjunto é embutido na função de valor de caminho, definindo f_{max} como mostrado nas equações (3.44) e (3.45). A dissimilaridade entre os nós adjacentes s e t é dado por $d(s, t)$ e a distância máxima entre as amostras adjacentes em π_s , quando não é trivial, é dado por $f_{max}(\pi_s)$ [47]. Desta forma, na equação (3.44) há a atribuição dos valores iniciais às sementes e, na equação (3.45), há a propagação dos valores durante a execução do processo.

$$f_{max}(\langle s \rangle) = \begin{cases} 0, & \text{se } s \in S \\ +\infty, & \text{caso contrário} \end{cases} \quad (3.44)$$

$$f_{max}(\pi_s \cdot \langle s, t \rangle) = \max \{f_{max}(\pi_s), d(s, t)\} \quad (3.45)$$

Ao aplicar a função de valor de caminhos suaves nos nós sementes, os demais nós do grafo são alcançados produzindo um caminho de valor ótimo. A união destes caminhos forma uma floresta orientada sobre toda a imagem [47]. Com isso, para cada *pixel* da imagem, três atributos são produzidos: o predecessor no caminho ótimo, o valor do caminho e o nó raiz correspondente [45].

Na figura (3.7) é exibido um grafo com 4-conectividade que representa uma imagem. Os nós sementes são expressos com a marcação destacada dos demais, apresentando círculos maiores nos vértices. Os valores atribuídos aos vértices correspondem à intensidade de cada *pixel* na imagem. Uma semente está localizada dentro da região de interesse, que corresponde ao ponto na terceira linha e quarta coluna com o valor sete, e a outra semente está fora da região de interesse, que corresponde ao ponto inferior esquerdo, com valor zero.




Figura 3.7: Representação de uma imagem em um grafo com 4-conectividade [48]

Ao grafo exibido na figura (3.7), calcula-se a função de custo fazendo a diferença da intensidade do *pixel* escolhido com a intensidade de seu predecessor, como exibido na figura (3.8). A segmentação na imagem distinguiu o retângulo central da região externa. Há casos de a segmentação não ser ideal e, para essas situações, o usuário deve escolher mais nós sementes e executar novamente o algoritmo.




Figura 3.8: Segmentação da imagem em torno de suas sementes [48]

O algoritmo da transformada imagem-floresta necessita como dados de entrada, além da imagem de entrada I , um conjunto de nós sementes S , uma relação de adjacência A e uma função suave de valor de caminho f . O processamento do algoritmo resultará em um mapa de custos V , um mapa de raízes R e um mapa de predecessores P . O mapa de predecessores P atribui para cada *pixel* s da imagem I a coordenada de um *pixel* ou uma marca *nil* indicando a ausência de predecessor [47]. A ausência de predecessor para um *pixel* marca esse ponto como um nó raiz da imagem. Em um mapa de predecessores, o caminho ótimo de uma raiz $R(s)$ até s é denotado por $P^*(s)$.

Em cada iteração do processo, os três mapas são atualizados para refletir os custos, a região de influência da raiz e os predecessores. Na figura (3.9) é exibido o mapa de custos, o mapa de raízes e o mapa de predecessores para a primeira iteração do grafo da figura (3.7). No mapa de custos, as sementes possuem valores iguais a zero e seus vizinhos possuem o custo do caminho até a sua raiz. Os demais pontos ainda não foram alcançados e, por isso, mantêm os valores iniciais. No mapa de raízes é mostrada a abrangência de cada raiz e os nós alcançados por ela. E, no mapa de predecessores, cada nó raiz possui valor nulo e os demais nós alcançados armazenam a coordenada de seu predecessor.

Mapa de Custos								
	1	2	3	4	5	6	7	8
1	∞	∞	∞	∞	∞	∞	∞	∞
2	∞	∞	∞	1	∞	∞	∞	∞
3	∞	∞	1	0	1	∞	∞	∞
4	∞	∞	∞	2	∞	∞	∞	∞
5	1	∞	∞	∞	∞	∞	∞	∞
6	0	2	∞	∞	∞	∞	∞	∞
(a)								
Mapa de Raízes								
	1	2	3	4	5	6	7	8
1	0	0	2	1	2	3	1	2
2	2	2	8	8	7	8	2	1
3	9	1	8	7	6	9	1	9
4	9	2	7	9	8	7	3	9
5	1	2	2	3	2	2	3	1
6	0	2	1	3	0	9	2	8
(b)								
Mapa de Predecessores								
	1	2	3	4	5	6	7	8
1	-	-	-	-	-	-	-	-
2	-	-	-	4,3	-	-	-	-
3	-	-	4,3	nil	4,3	-	-	-
4	-	-	-	4,3	-	-	-	-
5	1,6	-	-	-	-	-	-	-
6	nil	1,6	-	-	-	-	-	-
(c)								

Figura 3.9: Transformada Imagem-Floresta: (a) mapa de custos; (b) mapa de raízes; (c) mapa de predecessores [48-adaptado]

Em certos casos, uma mesma amostra poderá ser disputada por mais de uma raiz sendo necessário definir um critério de desempate para o algoritmo. De certa forma, o algoritmo da transformada imagem-floresta possui uma solução para esses casos, atribuindo a amostra para a raiz que a alcança-la primeiro [49]. Com isso, o critério de desempate reside na implementação da fila de prioridade. A fila é utilizada no algoritmo para armazenar os nós que foram alcançados na iteração para serem utilizados como fronteira da floresta em crescimento na próxima iteração [48]. Para que haja desempate, a fila pode seguir políticas de implementação como *first-in-first-out* (FIFO) ou *last-in-first-out* (LIFO). Caso a opção seja *first-in-first-out*, a árvore da primeira semente armazenada na fila será analisada e, caso seja *last-in-first-out*, a árvore da última semente armazenada na fila será analisada. Sendo assim, é possível escolher qual árvore será analisada primeiramente na próxima iteração [50].

3.6.1 – Transformada Imagem-Floresta Diferencial

No algoritmo proposto por Falcão e Bergo [51], Transformada Imagem-Floresta Diferencial, o modelo original da transformada imagem-floresta é modificado na conquista do nó por uma raiz, permitindo que o conjunto de nós sementes seja alterado com a remoção de árvores existentes e com a adição de novas sementes. Neste algoritmo é utilizado um mapa adicional para indicar a relação de cada *pixel* com a fila de prioridades, denominado como mapa de cores. Neste mapa, os *pixels* podem receber três valores: branco, cinza e preto. O valor branco é usado para indicar que o *pixel* analisado nunca esteve na fila de prioridades, o valor cinza para indicar que o *pixel* está na fila no momento e o valor preto para indicar que o *pixel* já saiu da fila de prioridades [52].

Além dos dados de entrada do modelo original e do mapa de cores, nesta técnica é necessário um conjunto de *pixels* cujas árvores serão removidas da floresta, chamados de marcadores de remoção M_R . Quando o conjunto $M_R = 0$, a transformada imagem-floresta diferencial atua como o modelo original da transformada, calculando uma floresta de caminhos mínimos válida para o conjunto de nós sementes definidos como raízes. Por este fator é comprovado que o modelo original é um caso particular da transformada imagem-floresta diferencial. Caso contrário, quando uma árvore existente na floresta é removida, novos caminhos de custo mínimo devem ser calculados para todos os *pixels* pertencentes a essa árvore. Para isso, um conjunto de fronteira, que possui *pixels* com custos inalterados e estão enraizados pelas árvores não removidas, é utilizado para reconquistar os pontos não enraizados, oferecendo caminhos mínimos como uma extensão das raízes existentes [52].

A propagação de novas sementes que foram adicionadas é restrita aos pontos que só podem ser atingidos por caminhos enraizados com custo menor ao custo já oferecido por outra raiz ou que tiveram seus custos modificados por causa da conquista de algum predecessor por outra árvore. Essa metodologia evita a formação de ilhas, pontos que não pertencem a nenhuma árvore, em regiões de empate entre uma raiz pré-existente e uma nova semente [52].

A remoção de árvores existentes, a adição de novas sementes ou mesmo as duas operações simultâneas na imagem faz com que na versão diferencial a correção iterativa seja possível. Desta forma, o conjunto inicial de nós sementes pode ser modificado sem que todo o processo seja refeito na imagem, fato que não acontece no modelo original [52].

3.6.2 – Estimativa de peso nos arcos do grafo

O uso da estimativa de peso nos arcos do grafo proporciona na transformada imagem-floresta a diminuição da quantidade de sementes necessárias para o processamento. Sendo assim, com apenas duas raízes, uma para a região interna e outra para a região externa, é possível realizar a segmentação do objeto. Esta estimativa consiste na classificação *fuzzy* e na atribuição de peso aos arcos, na qual os maiores pesos estarão nas regiões de fronteira.

Dado um grafo completo (T, A) , em que $T = T_o \cup T_b$ é um conjunto de treinamento e A é uma relação de adjacência, o peso do arco entre dois pontos $s, t \in T$ com $\lambda(s) \neq \lambda(t)$ é dado por $w(s, t) = \|F(s) - F(t)\|$. Na relação λ são definidos dois rótulos distintos: objeto e fundo da imagem. Com isso, T_o e T_b formam as amostras de pontos do conjunto de treinamento para o objeto e para o fundo da imagem. Sendo assim, um valor *fuzzy* deve ser calculado para cada *pixel* da imagem a fim de identificar qual a classe mais adequada para este ponto. Para isso, dois valores de conectividade são calculados para o mesmo *pixel*: $V_o(t)$ considerando o sub-grafo T_o e $V_b(t)$ considerando o sub-grafo T_b [53]. Nas equações (3.46) e (3.47) são apresentadas as definições de $V_o(t)$ e $V_b(t)$.

$$V_o(t) = \min \{ \max \{ V_o(s), w(s, t) \} \}, \forall s \in T_o \quad (3.46)$$

$$V_b(t) = \min \{ \max \{ V_b(s), w(s, t) \} \}, \forall s \in T_b \quad (3.47)$$

Com os valores calculados, o ponto pertencente ao objeto terá valores baixos para $V_o(t)$ e valores altos para $V_b(t)$. O inverso define os pontos do fundo. Portanto, a chance de um *pixel* fazer parte do objeto é definida pelo valor de $M_o(t)$, como na equação (3.48) [53].

$$M_o(t) = \frac{V_b(t)}{V_o(t) + V_b(t)} \quad (3.48)$$

Após a classificação *fuzzy* inicia-se a etapa de atribuição de pesos aos arcos. Nesta fase da estimativa, uma imagem $\widehat{W} = (D_I, W)$ é constituída no qual W é definido de acordo

com três parâmetros, como demonstrado na equação (3.49). O parâmetro $0 \leq \gamma \leq 1$ balanceia a importância entre o gradiente do objeto $W_o(s) = \|\sum_{\forall t \in A(s)} M_o(t) - M_o(s)\|$ e o gradiente da característica $W_f(s) = \max_b \|\sum_{\forall t \in A(s)} F_b(t) - F_b(s)\|$, na qual busca-se a diferença máxima entre as diversas imagens filtradas que existam para essa imagem [53].

$$W(s) = \gamma * W_o(s) + (1 - \gamma) * W_f(s) \quad (3.49)$$

3.7 - Floresta de Caminhos Ótimos

A floresta de caminhos ótimos é uma técnica utilizada para reconhecimento de padrões no processamento digital de imagens. A identificação e classificação de objetos de uma imagem é uma tarefa extremamente difícil e custosa, mas de fundamental importância.

Essa técnica modela o reconhecimento de padrões utilizando um grafo definido no espaço de atributos, no qual os nós são as amostras e os arcos são as relações de adjacência pré-estabelecidas. Os nós e os arcos podem ser ponderados e utilizam funções de custo para particionar o grafo em árvores de caminhos ótimos. A floresta de caminhos ótimos é um classificador que cria partições discretas ótimas computadas pelo algoritmo da transformada imagem-floresta [47]. Duas abordagens distintas podem ser implementadas para a classificação dos objetos: aprendizado não supervisionado e aprendizado supervisionado.

A abordagem não supervisionada agrupa amostras por semelhanças e as decisões são tomadas na construção de limiares no conjunto de dados. Com isso, o agrupamento é definido por meio de descritores e os grupos podem possuir tamanhos e formas diferentes. Além dessas desvantagens, o número de grupos resultantes pode variar muito entre as amostras [47].

A abordagem supervisionada realiza as decisões de classificação baseada no conhecimento prévio do conjunto de dados. Esse conhecimento prévio é atingido pelo treinamento do classificador por meio da indicação manual da classificação correta do objeto analisado. Para as florestas de caminhos ótimos com aprendizado supervisionado, a classificação pode utilizar um grafo completo ou um grafo K-NN [47].

3.7.1 - Classificação com aprendizado não supervisionado

Na floresta de caminhos ótimos de classificação com aprendizado não supervisionado, proposta por Rocha, Falcão e Meloni [54], os nós denotam as amostras e os arcos conectam os k -vizinhos mais próximos no espaço de atributos.

O grafo gerado é ponderado nos nós por valores de densidades calculadas considerando o peso dos arcos entre os vetores de atributos das amostras adjacentes. Esse cálculo é realizado por uma função de densidade de probabilidade que é utilizada para encontrar as árvores da floresta de caminhos ótimos no grafo. Cada árvore é enraizada em um máximo da função de densidade de probabilidade e denota o valor do melhor k encontrado, minimizando uma medida de corte e maximizando a função de valor de caminho [47].

Para uma base de dados Z com amostras s e t existe um vetor de atributos $\vec{v}(s)$ e uma distância $d(s, t)$ entre as amostras. Para uma relação de adjacência A , a amostra t será adjacente a s se a relação (3.50) for satisfeita [47]. A relação de adjacência representa um nível de semelhança entre as amostras de acordo com algum significado semântico.

$$t \in A(s) \text{ ou } (s, t) \in A \quad (3.50)$$

Portanto, $t \in A_1(s)$ se $d(s, t) \leq d_f$ ou $t \in A_2(s)$ se t é o k -vizinho mais próximo de s no espaço de atributos [55]. O valor de d_f é dado pelo comprimento do maior arco em (Z, A_k) e deve ser sempre maior que um. Com isso, o par (Z, A_k) define um grafo K-NN com arcos ponderados por $d(s, t)$ e os nós ponderados por um valor de densidade $\rho(s)$. O valor da densidade é obtido pela função de densidade de probabilidade denotado na equação (3.51).

$$\rho(s) = \frac{1}{\sqrt{2 * \pi * \sigma^2 * |A(s)|}} * \sum_{\forall t \in A(s)} \exp\left(\frac{-d^2(s, t)}{2 * \sigma^2}\right) \quad (3.51)$$

O parâmetro σ é calculado em função de d_f , sendo que $\sigma = d_f/3$. Para a realização desse cálculo consideram-se todos os nós e assume-se que uma função gaussiana

cobre a quase totalidade das amostras, sendo que $d(s, t) \in [0, 3\sigma]$.

A relação de adjacência A_1 resulta em uma relação de conectividade simétrica. A conectividade assimétrica acontece no caso da relação de adjacência A_2 , pois é possível gerar um subconjunto de amostras adjacentes com um mesmo valor de densidade no máximo da equação (3.51). Sendo assim, é possível garantir a conectividade entre qualquer par de amostras nesse máximo [55]. Para evitar que as amostras desse subconjunto possam alcançar outras amostras e influenciar um caminho ótimo, é preciso modificar a relação de adjacência A_2 para que também seja simétrica [47]. Com isso, a relação de adjacência A_2 é definida como A_3 e deve ser satisfeita como mostrado em (3.52).

$$\text{se } t \in A_2(s) \text{ e } s \notin A_2(t) \text{ e } \rho(s) = \rho(t), \text{ então } A_3(t) \leftarrow A_2(t) \cup \{s\} \quad (3.52)$$

Com a relação (3.52) satisfeita, cada máximo terá apenas uma amostra, formando o conjunto S . Portanto, pode-se definir a maximização da função de conectividade f_1 em duas partes: o termo de inicialização, equação (3.53), e o termo de propagação, equação (3.54) [47, 56].

$$f_1(\langle t \rangle) = \begin{cases} \rho(t), & \text{se } t \in S \\ -\infty, & \text{caso contrário} \end{cases} \quad (3.53)$$

$$f_1(\pi_s \cdot \langle s, t \rangle) = \min \{f_1(\pi_s), \rho(t)\} \quad (3.54)$$

O termo de propagação associa a cada caminho π_t o menor valor de densidade ao longo do mesmo. Cada amostra do conjunto define um caminho trivial $\langle t \rangle$ a outra amostra, pois não é possível traçar outro caminho sem passar pelas densidades menores que $\rho(t)$ obteve. Para os casos em que a função se inicia com $-\infty$, todos os valores obtidos serão maiores que o valor inicial e, portanto, o caminho ótimo será aquele cujo menor valor de densidade seja máximo [47].

Na figura (3.10a), os nós possuem seus respectivos pesos definidos pela função de densidade de probabilidade $\rho(t)$ e existem apenas dois máximos definidos: o valor cinco no

extremo superior e o valor três no extremo inferior do grafo. Na figura (3.10b), o grafo possui pesos somente para as raízes definidas e, com isso, todos os demais nós possuem valor inicial de $-\infty$, seguindo a definição do termo de inicialização da equação (3.53) [47]. Na última imagem, figura (3.10c), as árvores foram geradas a partir dos máximos encontrados, formando a floresta de caminhos ótimos com o termo de propagação da função de conectividade f_1 , equação (3.54). A linha tracejada representa o caminho ótimo $P^*(t)$ do predecessor $P(t)$ até a raiz $R(t)$.




Figura 3.10: Floresta de caminhos ótimos com aprendizado não supervisionado: (a) definição do grafo; (b) aplicação do termo de inicialização; (c) floresta de caminhos ótimos [55]

Porém, como os máximos da função de densidade de probabilidade não são conhecidos, eles podem ser encontrados com a escolha apropriada dos valores iniciais h da função de conectividade. Dessa maneira, quando $f_1(\langle t \rangle) = h(t) < \rho(t)$, $\forall t \in Z$ alguns máximos serão preservados e outros não. Estes máximos não preservados serão alcançados por caminhos cujos valores são maiores que seus respectivos valores iniciais [47]. A função $h(t)$ é descrita na equação (3.55), na qual depende do valor de δ , definido na equação (3.56). Dessa forma, todos os máximos da função de probabilidade serão preservados e os demais serão alcançados por caminhos provenientes de outros máximos.

$$h(t) = \rho(t) - \delta \quad (3.55)$$

$$\delta = \min_{(s, t) \in A | \rho(t) \neq \rho(s)} |\rho(t) - \rho(s)| \quad (3.56)$$

Outra preocupação na versão não supervisionada da floresta de caminhos ótimos é evitar a divisão da zona de influência de um máximo em múltiplas zonas. A solução desse problema é detectar uma primeira amostra para cada máximo, modificando a função f_1 e obtendo a função f_2 , como descrito nas equações (3.57) e (3.58) [56].

$$f_2(\langle t \rangle) = \begin{cases} \rho(t), & \text{se } t \in S \\ h(t), & \text{caso contrário} \end{cases} \quad (3.57)$$

$$f_2(\pi_s \cdot \langle s, t \rangle) = \min \{f(\pi_s), \rho(t)\} \quad (3.58)$$

Até este ponto do processo, as funções de densidade e conectividade estão prontas. O último item para definir é encontrar o melhor valor de k . Para isso, Rocha, Falcão e Meloni [54] consideraram o corte mínimo no grafo de acordo com a medida $C(k)$ sugerida por Shi e Malik [57], como definido nas equações (3.59), (3.60) e (3.61), no qual o termo $L(t)$ é o rótulo da amostra t , W'_i utiliza todos os pesos dos arcos existentes e W_i utiliza somente os pesos dos arcos pertencentes à árvore [47, 58].

$$C(k) = \sum_{i=1}^c \frac{W'_i}{W_i + W'_i} \quad (3.59)$$

$$W'_i = \sum_{\forall (s,t) \in A \mid L(s)=i, L(t) \neq i} \frac{1}{d(s,t)} \quad (3.60)$$

$$W_i = \sum_{\forall (s,t) \in A \mid L(s)=i, L(t)=i} \frac{1}{d(s,t)} \quad (3.61)$$

O algoritmo do classificador de aprendizado não supervisionado da floresta de caminhos ótimos utiliza o grafo (Z, A_k) e a função ρ como dados de entrada. A saída é composta pelo mapa de rótulos L , o mapa de custos V e o mapa de predecessores P .

3.7.2 - Classificação com aprendizado supervisionado por grafo completo

A classificação supervisionada por grafo completo baseada em florestas de caminhos ótimos, proposta por Papa et al. [59, 60], possui algumas vantagens como, por exemplo, ser livre de parâmetros, possuir tratamento nativo de problemas multiclases e não fazer alusão sobre a separabilidade das classes [47].

Nesta abordagem, as amostras são os nós e os elementos mais representativos de cada classe do conjunto de treinamento, os protótipos, são escolhidos como os elementos das regiões de fronteira entre as classes. Desta forma, esses elementos competem pelas amostras oferecendo caminhos de menor custo e seus respectivos rótulos. Cada caminho encontrado identifica uma árvore de caminho ótimo e a união dessas árvores forma a floresta de caminhos ótimos [47].

Para um conjunto de treinamento Z_1 com amostras $|Z_1|$ e um conjunto de testes Z_2 com amostras $|Z_2|$, uma base de dados Z com rótulo λ é dado por $Z = Z_1 \cup Z_2$. A associação de uma amostra a uma classe é dada pela função $\lambda(s)$, em que $s \in Z_1 \cup Z_2$. Dado um conjunto de protótipos $S \in Z_1$ e um algoritmo $\vec{v}$ que extrai n atributos de qualquer amostra s e retorna um vetor de atributos $\vec{v}(s) \in \mathbb{R}^n$, a distância $d(s, t)$ das amostras s e t é a distância entre os vetores de atributos $\vec{v}(s)$ e $\vec{v}(t)$. Com os elementos descritos, o classificador deve usar o conjunto de protótipos S , o conjunto de treinamento Z_1 e a relação $(\vec{v}, d)$ para prever o rótulo $\lambda(s)$ correto para qualquer amostra $s \in Z_2$ [47].

Considerando um grafo completo (Z_1, A) cujos nós são as amostras em Z_1 , um arco é definido por qualquer par de amostras em A , ou seja, $A = Z_1 \times Z_1$. A função de custo suave para agrupar as amostras com propriedades similares para o algoritmo da floresta de caminhos ótimos é exibido em (3.62) e (3.63). Por esta definição, o custo oferecido por um protótipo a uma amostra na função de custo suave é o valor do maior arco encontrado no caminho ótimo formado entre eles.

$$f_{max}(\langle s \rangle) = \begin{cases} 0, & \text{se } s \in S \\ +\infty, & \text{caso contrário} \end{cases} \quad (3.62)$$

$$f_{max}(\pi_s \cdot \langle s, t \rangle) = \max \{f_{max}(\pi_s), d(s, t)\} \quad (3.63)$$

A associação de um caminho ótimo $P^*(s)$ de S a toda amostra $s \in Z_1$ forma uma floresta de caminhos ótimos P . Essa floresta é uma função sem ciclos, na qual todas as amostras s estão associadas a seu predecessor $P(s)$ em $P^*(s)$ ou a uma marca *nil* quando $s \in S$. Dessa forma, considerando $R(s) \in S$ como a raiz de $P^*(s)$, ela pode ser alcançada por $P(s)$ [47].

O algoritmo do classificador supervisionado baseado em floresta de caminhos ótimos usando grafo completo utiliza como dados de entrada um conjunto de treinamento Z_1 rotulado por λ , protótipos $S \subset Z_1$, um vetor de atributos com distâncias (v, d) e uma função f para o cálculo das distâncias. A saída do algoritmo proporciona uma floresta de caminhos ótimos P , um mapa de valores de custo de caminhos V e um mapa de rótulos L [47]. O processo do algoritmo necessita realizar a inicialização de P e V para cada amostra $s \in Z_1$ e cada amostra $s \in S$ é inserida em uma fila para análise. Com os mapas inicializados, a cada iteração um caminho de custo ótimo é obtido. As amostras são analisadas para atribuição ao caminho de menor custo encontrado e, caso haja empate, essas amostras são atribuídas ao primeiro caminho que o atingiu.

O treinamento dessa vertente de floresta de caminhos ótimos consiste em encontrar o conjunto S dos elementos mais representativos de cada classe, os protótipos. Esse conjunto pode ser definido de maneira aleatória ou por estimativas nas regiões de sobreposição de amostras ou nas fronteiras entre as classes [47]. Dado um grafo completo (Z_1, A) , como na figura (3.11a), para encontrar o conjunto de protótipos por estimativas calcula-se a árvore geradora mínima e obtém-se um grafo conexo acíclico, cujos nós são todas as amostras em Z_1 e os arcos são ponderados e não direcionados, como na figura (3.11b). Os protótipos escolhidos são os nós conectados que pertencem a classes diferentes, figura (3.11c). Com a remoção do arco entre esses nós, amostras com círculos pontilhados, é possível computar a floresta de caminhos ótimos. Nesse ponto do processo, cada amostra recebe dois valores: o custo para o seu predecessor, indicado pela seta entre as amostras e o identificador do rótulo. Os nós raízes possuem custo zero. Quando uma amostra de teste, triângulo, será analisada, ela ainda não possui custo e nem rótulo, apenas o valor da distância para os nós já constituintes das árvores, figura (3.11d). A amostra é, então, processada e recebe o seu valor de custo e rótulo, sendo conectada a uma das árvores existentes, figura (3.11e). Na parte (f) da imagem é exibida a floresta de caminhos ótimos obtida.




Figura 3.11: Floresta de caminhos ótimos com aprendizado supervisionado usando grafo completo: (a) grafo completo; (b) árvore geradora mínima do grafo; (c) escolha dos protótipos; (d) cálculo dos custos entre as amostras e identificação dos rótulos; (e) processo de classificação de uma amostra de teste para uma das árvores existentes; (f) floresta de caminhos ótimos [56]

Para computar a floresta de caminhos ótimos com erro zero de classificação, as equações (3.62) e (3.63) precisam ser modificadas de forma que os arcos constituídos entre amostras de classes diferentes sejam ponderados com valores altos, o que impossibilitaria aos protótipos de uma classe conquistar elementos de outras classes [47]. A função de custo suave a ser utilizada é definida nas equações (3.64) e (3.65).

$$f_{\max}(\langle t \rangle) = \begin{cases} 0, & \text{se } t \in S \\ +\infty, & \text{caso contrário} \end{cases} \quad (3.64)$$

$$f_{\max}(\pi_s \cdot \langle s, t \rangle) = \begin{cases} +\infty, & \text{se } \lambda(t) \neq \lambda(s) \\ \max\{f_{\max}(\pi_s), d(s, t)\}, & \text{caso contrário} \end{cases} \quad (3.65)$$

A classificação de uma amostra teste $t \in Z_2$ considera a conectividade desta amostra com todas as outras amostras $s \in Z_1$ existentes no grafo. Sendo assim, a amostra t terá o caminho ótimo $P^*(t)$ à raiz $R(t) \in S$ mais fortemente conexa a ela [47]. Desta forma, o

valor ótimo $V(t)$ da amostra t é definido como na equação (3.66).

$$V(t) = \min \{ \max \{ V(s), d(s, t) \} \}, \forall s \in Z_1 \quad (3.66)$$

Para todas as amostras $s \in Z_1$ calcula-se o máximo entre o seu custo e a sua distância para a amostra t . O valor de $V(t)$ será o valor mínimo entre todos os máximos calculados.

3.7.3 - Classificação com aprendizado supervisionado por grafo K-NN

A floresta de caminhos ótimos com aprendizado supervisionado utilizando grafo K-NN, proposta por Papa e Falcão [61], também modela as amostras como nós de um grafo. Diferentemente do modelo de grafo completo, apresentado anteriormente, no modelo com grafo K-NN a relação de adjacência utiliza os k-vizinhos mais próximos e tanto os arcos quanto os nós são ponderados. A metodologia desta técnica se baseia em estimar os protótipos nos pontos de alta concentração de amostras.

Assim como no grafo completo, para um conjunto de treinamento Z_1 com amostras $|Z_1|$ e um conjunto de testes Z_2 com amostras $|Z_2|$, uma base de dados Z com rótulo λ é dado por $Z = Z_1 \cup Z_2$. Portanto, para um grafo (Z_1, A_k) , o algoritmo para o grafo K-NN particiona o conjunto Z_1 em uma floresta de caminhos ótimos por meio de uma função de densidade de probabilidade, indicada na equação (3.51) [47]. Os valores proporcionados por essa função são atribuídos aos nós e o peso dos arcos é definido pela distância $d(s, t)$ entre duas amostras $s, t \in Z_1$. As equações (3.57) e (3.58), exibidas anteriormente, associam um valor de densidade inicial para um nó terminal s e, respectivamente, um caminho mínimo entre os valores de densidade.

O algoritmo da floresta de caminhos ótimos com grafo K-NN é muito semelhante ao algoritmo da versão não supervisionada, diferenciando no conjunto de entrada que passa a ser rotulado por λ . As raízes da floresta formam um subconjunto dos máximos da função de densidade de probabilidade e as árvores são compostas pelas amostras mais fortemente

conexas que recebem o mesmo rótulo de sua raiz [47].

Além do grafo K-NN, esse algoritmo utiliza a função de valor de caminho f_2 , equações (3.57) e (3.58), e a definição de $\lambda(s)$ para todo $s \in Z_1$. Como saída, o algoritmo produz o mapa de rótulos L , o mapa de valores de caminho V e a floresta de caminhos ótimos P . A inicialização do mapa de valores utiliza a relação $V(s) \leftarrow \rho(s) - \delta$ e o mapa de rótulos utiliza a relação $L(s) \leftarrow \lambda(s)$. O processo do algoritmo prossegue a fim de encontrar o melhor caminho de todos os nós para uma das raízes marcadas [47]. A definição de δ é dada pela equação (3.56).

O treinamento desse método consiste em ter pelo menos um máximo da função de densidade para cada classe representada e que $L(t) = \lambda(t)$ para todo $t \in Z_1$. Quando esta igualdade não acontece, ocorre um erro de classificação no conjunto de treinamento. Sendo assim, essas propriedades não podem ser garantidas com a função f_2 utilizada [47]. Por este motivo, a função f_3 foi desenvolvida considerando a definição dos rótulos, como mostrado nas equações (3.67) e (3.68).

$$f_3(\langle t \rangle) = \begin{cases} \rho(t), & \text{se } t \in S \\ \rho(t) - \delta, & \text{caso contrário} \end{cases} \quad (3.67)$$

$$f_3(\pi_s \cdot \langle s, t \rangle) = \begin{cases} -\infty, & \text{se } \lambda(t) \neq \lambda(s) \\ \min \{f_2(\pi_s), \rho(t)\}, & \text{caso contrário} \end{cases} \quad (3.68)$$

A classificação dos elementos está associada com o rótulo da raiz da árvore à qual o nó foi incorporado. Considerando os k-vizinhos mais próximos da amostra $t \in Z_2$, o valor da densidade pode ser calculado pela equação (3.51) e o caminho ótimo selecionado satisfará a equação (3.69).

$$V(t) = \max_{\forall (s, t) \in A_{k^*}} \{\min \{V(s), \rho(t)\}\} \quad (3.69)$$

Na figura (3.12) é ilustrado o processo de classificação da floresta de caminhos ótimos com aprendizado supervisionado com grafo K-NN. Os nós constituintes do grafo são

ponderados com indicadores (x, y) para o valor de densidade e o rótulo da classe pertencente, respectivamente. Os elementos circulados com pontilhados representam os máximos de cada classe, parte (a). Na parte (b) da figura, uma amostra em formato de triângulo a ser classificada está conectada aos k -vizinhos mais próximos [47]. Na parte (c), o elemento foi classificado satisfazendo a equação (3.69), sendo conquistado pela primeira classe.




Figura 3.12: Floresta de caminhos ótimos com aprendizado supervisionado usando grafo K-NN: (a) grafo K-NN; (b) processo de classificação de uma amostra; (c) processo final de classificação [47]

3.8 - Dimensão Fractal

O termo fractal, conceito introduzido por Mandelbrot [62], designa objetos geométricos e estruturas complexas dotados das propriedades de similaridade, complexidade infinita e dimensão geométrica [30]. Esses objetos são gerados por um processo recursivo e apresentam uma infinidade de formas diferentes, impossibilitando estabelecer um formato padrão. Por essas características, esses objetos não podem ser representados corretamente pela

geometria euclidiana.

A primeira propriedade do fractal, similaridade, permite que esses objetos possam ser divididos em várias partes sucessivas idênticas ao formato original, ou seja, em cada observação a forma da parte é a mesma do início [22]. Portanto, independente da escala de ampliação ou redução, uma parte da estrutura terá a mesma forma do todo. Além da similaridade, um objeto fractal possui complexidade infinita, pois a quantidade de irregularidades que ele possui impede que todo o objeto seja coberto durante a sua análise [30]. Com isso, por menor que seja, sempre existirá parte do objeto inatingível. E a terceira propriedade diz respeito à dimensão do fractal. Essa propriedade quantifica a densidade dos objetos utilizados para cobrir a estrutura original. A dimensão D pode ser calculada pela quantidade de elementos necessários para cobrir o objeto original N e a quantidade de elementos correspondente a uma fração do tamanho anterior T [15]. O cálculo da dimensão de um objeto é dado pela equação (3.70).

$$D = \frac{\log(N)}{\log(1/T)} \quad (3.70)$$

O valor resultante de D poderá ser inteiro ou fracionário. Para valores inteiros, o coeficiente passa a considerar a geometria clássica ou euclidiana, sendo que $D = 1$ representa uma reta, $D = 2$ representa um plano e $D = 3$ representa um volume. No caso dos valores serem fracionários, se o valor obtido estiver entre $1 < D < 2$ representará uma curva, entre $2 < D < 3$ denotará uma superfície e o valor entre $3 < D < 4$ será um volume [22]. Portanto, quanto maior a dimensão, maior é a irregularidade do objeto [63].

A Curva de Koch foi um dos primeiros fractais de curvas descritos. Esse fractal usa como base a estrutura de um triângulo equilátero [64, 65]. O processo consiste em dividir cada lado do triângulo em três segmentos idênticos de reta e no segmento médio de cada lado construir um triângulo equilátero. Esse processo deve se repetir indefinidamente. A construção da Curva de Koch para as quatro primeiras iterações são ilustradas na figura (3.13). A dimensão da Curva de Koch é aproximadamente 1,2618, obtida por meio da equação (3.70). A cada iteração a quantidade de lados obtidos é quadruplicada e o comprimento de cada lado é reduzido para um terço.




Figura 3.13: Curva de Koch: (a) figura inicial; (b) figura após a primeira iteração; (c) figura após a segunda iteração; (d) figura após a terceira iteração; (e) figura após a quarta iteração [65]

O conceito de similaridade é encontrado por toda a figura, não importando a iteração observada no momento. A cada repetição quatro novas cópias do objeto são adicionadas a cada nível da curva [64]. Como o processo pode ser repetido indefinidamente, a propriedade de complexidade infinita também é satisfeita. Com isso, o cálculo da dimensão é possível, comprovando o conceito de fractal do objeto.

Em processamento de imagens, a dimensão fractal é utilizada, principalmente, para descrever propriedades de texturas e definição de forma dos objetos [15, 30]. A análise de texturas utiliza a dimensão fractal para verificar a variação dos níveis de cinza de uma imagem, estimando a textura do objeto. Na definição de formas, a dimensão fractal pode ser utilizada para separar os objetos constituintes de uma imagem por meio do nível de ocupação do espaço e para medir o comprimento de curvas irregulares das estruturas. Além disso, a dimensão fractal também pode ser utilizada como parâmetro na comparação de diferentes objetos em uma mesma imagem [66].

3.8.1 - Métodos de cálculo da Dimensão Fractal

Existem várias técnicas para se obter a estimativa da dimensão fractal. Entretanto, cada método se baseia em medições diferentes, podendo ser aplicado apenas a certos tipos de estrutura. Caso contrário, para objetos iguais e métodos diferentes, os resultados obtidos seriam contraditórios. Entre os métodos existentes, o Método de Cálculo de Massa-Raio é baseado na contagem de círculos inseridos no interior do objeto, o Método Análise de Intersecção Acumulativa é fundamentado pelo cálculo do número de subdivisões do objeto, o *Box Counting* é operado com o uso de quadrados que cobrem a área do objeto, o *Dividers* é utilizado em contornos de curvas auto-semelhantes e, no Método de Bouligand-Minkowski, a

dilatação de discos é utilizada [63].

O Método de Cálculo Massa-Raio é utilizado sobre imagens binárias sobrepondo círculos e contando a quantidade de pontos presentes no interior do círculo. O cálculo poderá ser realizado através da utilização de um ou mais círculos constituídos. No caso da utilização de apenas um círculo, o ponto central do círculo como centro de massa é uma escolha apropriada para o processo [66]. Caso contrário, uma forma arbitrária de escolha poderá identificar os diferentes centros dos círculos. Para essa situação, a massa média calculada nos círculos deve ser levada em consideração. Na figura (3.14) são considerados vários círculos sobrepostos sobre o objeto analisado.




Figura 3.14: Sobreposição de círculos no Método de Cálculo Massa-Raio [66]

O cálculo da dimensão fractal desse método utiliza-se do número de pontos $M_r(A)$ existentes do tipo A e um raio r . A definição do raio deve ser um valor válido em $0 < r < r_{max}$. O raio máximo r_{max} pode ser definido pelo usuário, mas é comumente atribuído o raio de giro da imagem, estabelecendo, assim, o maior valor possível [63].

O Método Análise de Intersecção Acumulativa, apesar de ser similar ao Massa-Raio, é utilizado com a quantidade de subdivisões existentes na região definida. A semelhança está na possibilidade de usar um ou mais círculos no cálculo, na definição do raio máximo e na equação da dimensão do objeto. Os pontos que fazem parte tanto da borda do círculo quanto do objeto analisado são ordenados pelo valor do ângulo do centro do círculo e armazenados em um vetor. Com o vetor preenchido verifica-se a adjacência dos pontos consecutivos. A ausência de adjacência na intersecção deve ser contada [66].

O *Box Counting* é um método aplicável a qualquer estrutura e muito utilizado devido à sua facilidade de implementação e simplicidade. O processo consiste em cobrir a imagem com uma malha de quadrados e contar essa quantidade utilizada para cobrir toda a área do objeto. A dimensão é calculada com base no número de quadrados necessários $N_r(A)$ e no tamanho do lado do quadrado r [63, 66].

A sobreposição da malha de quadrados e a contagem de quadrados necessários para cobrir a imagem são realizadas por um processo iterativo, aonde a cada iteração o tamanho dos quadrados é reduzido [15, 22, 63]. O somatório de todas as dimensões fractais encontradas no processo possibilita medir a irregularidade e quantificar a textura da imagem [66]. Na figura (3.15) são mostradas duas iterações do processo *Box Counting*. Na segunda iteração, o tamanho dos quadrados utilizados foi reduzido, obtendo uma melhor precisão na definição do objeto.




Figura 3.15: Método *Box Counting*: (a) primeira iteração; (b) segunda iteração [30]

Algumas variações dessa técnica podem ser implementadas, como por exemplo, a diferenciação de quadrados completamente preenchidos e parcialmente preenchidos, trazendo benefícios sobre o cálculo em certas ocasiões. Um problema considerado nesse método é a variação de resultados calculados. Isso pode acontecer por causa da disposição da malha sobreposta e o tamanho dos quadrados definidos para o processo [66].

Também conhecido com *Compass*, o *Dividers* é um método exato para trabalho com curvas auto-semelhantes. Constitui um processo muito simples de implementação, porém os objetos devem ter um contorno bem definido [63]. A base desse método está no fato de o perímetro de um objeto fractal ser proporcional ao tamanho de uma régua r usada para medir

o contorno de seu perímetro $l(r)$. A desvantagem desse método está na variação do resultado calculado por causa do ponto de início da curva. Por esse fato, é necessário repetir o mesmo processo variando o ponto inicial [66]. A diferença de precisão na escolha dos pontos em um mesmo objeto é retratada na figura (3.16). Na primeira imagem há mais pontos identificados, o que permite uma definição mais precisa do perímetro.




Figura 3.16: Método *Dividers*: (a) maior quantidade de pontos; (b) menor quantidade de pontos [66]

No Método de Bouligand-Minkowski são produzidos os resultados mais confiáveis e consistentes para a dimensão fractal. A base do processo está na área de influência de um disco de raio r utilizado para criar uma dilatação no objeto analisado. Se o objeto sofrer pequenas alterações, a área de influência do disco também se altera. A alta sensibilidade existente nas variações do objeto analisado comprova sua consistência nos resultados apresentados. A dimensão fractal obtida nesse método utiliza a área dilatada $A(r)$ e o raio r como parâmetros para o cálculo [66]. Na figura (3.17), um disco de raio r percorre toda a extensão do objeto definindo uma dilatação na curva. Nesse percurso, o centro do disco coincide com a extremidade da estrutura analisada.



Figura 3.17: Método Bouligand-Minkowski [66]

4 - MÉTODO DESENVOLVIDO

O método desenvolvido neste trabalho foi decomposto em quatro partes distintas: pré-processamento, segmentação, extração de características e classificação das imagens. As imagens analisadas seguem essa sequência de processamento até a obtenção do seu resultado, como exibido na figura (4.1).




Figura 4.1: Etapas do modelo de processamento adotado

Cada imagem analisada inicializará na etapa de pré-processamento. Nessa etapa acontece a seleção do modelo de cor utilizado, a aplicação do filtro de difusão anisotrópica e a quantização de cores. Na segunda etapa, segmentação, é aplicada a transformada imagem-floresta diferencial, precedida ou não de morfologia matemática, para que haja a separação entre o objeto de interesse que será analisado e o fundo da imagem que será desprezado. Com a imagem segmentada, as características contidas no objeto são detectadas de acordo com os critérios estabelecidos na regra ABCD (assimetria, borda, cor e estruturas diferenciais). Ao final do processo, o classificador de floresta de caminhos ótimos indicará o tipo de lesão de pele contida na imagem: lesão não maligna, lesão suspeita ou lesão maligna.

Os algoritmos deste trabalho foram implementados em linguagem C com a utilização da biblioteca OpenCV [67] para a manipulação das imagens. A descrição aprofundada das etapas que constituem o método e os algoritmos implementados estão detalhados ao longo deste capítulo em seções específicas para cada etapa.

4.1 - Aquisição de imagens

As imagens utilizadas neste trabalho foram obtidas em diversas fontes, como Dermatology Information System - DermIS [19], DermAtlas [20], Dermatology Atlas [24], Loyola University Chicago [68], YSP Dermatology Image Database [69] e Dermoscopy Atlas [70], totalizando 284 imagens de lesões de pele. Essas imagens são compostas de 106 imagens de lesões não malignas (nevus e ceratoses seborréicas), 36 imagens de lesões suspeitas (nevus congênitos e nevus displásicos) e 142 imagens de lesões malignas (melanomas). A classificação das imagens foi realizada por especialistas da área ligados às fontes mencionadas.

As imagens foram catalogadas em quatro grupos para o processamento: nevus não malignos, ceratoses seborréicas, nevus suspeitos e melanomas. O resultado esperado do processamento é definido de acordo com o grau de malignidade da lesão. Nesse caso, para o grupo dos nevus não malignos e ceratoses seborréicas o resultado esperado é “não maligno”, para o grupo dos nevus congênitos e nevus displásicos o resultado esperado é “suspeito” e, para os melanomas, o resultado esperado é “maligno”. Ao término do processamento, cada

imagem terá o seu resultado final para a análise comprobatória da eficiência da metodologia adotada.

As imagens possuem diversas irregularidades como diferenças de iluminação, sombras, pelos, linhas de pele e sangue. Adicionalmente, as imagens podem possuir codificações e tamanhos diferentes, mas com largura e comprimento iguais. Devido a este fato, algumas imagens foram manipuladas em suas dimensões, entretanto, a composição da lesão não foi modificada. Apesar da implementação dos algoritmos deste trabalho atender a todos esses requisitos, todas as imagens foram convertidas para o formato JPG. Este padrão foi escolhido por oferecer imagens de qualidade com tamanho de armazenamento pequeno, além de oferecer o mesmo tipo de codificação dos *pixels* em todas as imagens [71].

Na tabela (4.1) as imagens foram distribuídas em lesões não malignas, lesões suspeitas e lesões malignas. Cada linha da tabela indica a origem das imagens. Além da distribuição, na tabela (4.1) é exibido o total de imagens de cada tipo de malignidade e o total referente a cada banco de origem.

Tabela 4.1: Classificação das imagens em lesões não malignas, lesões suspeitas e lesões malignas

Banco de Imagens	Lesões Não Malignas	Lesões Suspeitas	Lesões Malignas	Total
DermIS [19]	39	7	89	135
DermAtlas [20]	27	12	20	59
Dermatology Atlas [24]	6	0	12	18
Loyola University Chicago [68]	2	1	2	5
YSP Dermatology Image Database [69]	4	0	1	5
Dermoscopy Atlas [70]	28	16	18	62
Total	106	36	142	284

Na tabela (4.2) são exibidos os dados referentes somente às lesões não malignas. Essas imagens foram catalogadas em 73 imagens de nevos e 33 imagens de ceratoses seborréicas. Os nevos ainda podem ser reclassificados em 23 imagens do tipo melanocítico ou nevocítico (juncional, composto e dérmico), 22 imagens do tipo halo, 12 imagens do tipo azul e 16 imagens do tipo *spitz*.

Tabela 4.2: Classificação das imagens de lesões não malignas em nevos não malignos e ceratose seborréica

Banco de Imagens	Nevos Não Malignos	Ceratose Seborréica	Total
DermIS [19]	27	12	39
DermAtlas [20]	24	3	27
Dermatology Atlas [24]	6	0	6
Loyola University Chicago [68]	0	2	2
YSP Dermatology Image Database [69]	1	3	4
Dermoscopy Atlas [70]	15	13	28
Total	73	33	106

Na tabela (4.3) são exibidos os dados referentes às lesões suspeitas. As lesões suspeitas foram catalogadas em 17 imagens de nevos congênitos e 19 imagens de nevos displásicos. A totalização dos resultados também é apresentada por tipo de lesão e por origem.

Tabela 4.3: Classificação das imagens de lesões suspeitas em nevos congênitos e nevos displásicos

Banco de Imagens	Nevos Congênitos	Nevos Displásicos	Total
DermIS [19]	6	1	7
DermAtlas [20]	10	2	12
Loyola University Chicago [68]	1	0	1
Dermoscopy Atlas [70]	0	16	16
Total	17	19	36

As imagens de melanomas mencionadas anteriormente são oriundas de todas as fontes citadas, sendo que a maioria delas, 89 imagens, provém de DermIS [19]. As demais imagens estão distribuídas entre as outras fontes sendo que, 20 foram obtidas de DermAtlas [20], 12 fazem parte da base de imagens de Dermatology Atlas [24], 2 imagens advém de Loyola University Chicago [68], apenas 1 imagem procede de YSP Dermatology Image Database [69] e as 18 imagens restantes são de Dermoscopy Atlas [70].

4.2 - Pré-processamento

Na etapa de pré-processamento é realizada a filtragem da imagem para eliminação de ruídos existentes, melhoria de contraste e tratamento de iluminação e sombreamento. Esta fase é importante por amenizar as imperfeições da imagem e por proporcionar bordas realçadas para a etapa seguinte de segmentação.

O pré-processamento, neste trabalho, inicia-se com a escolha do modelo de cor desejado. Os modelos de cores disponíveis são o RGB, o YIQ, o HSI e em níveis de cinza. Esses três modelos de cor foram escolhidos por proporcionarem resultados expressivos na literatura consultada para este trabalho. O modelo em níveis de cinza não é utilizado diretamente como parte da etapa de pré-processamento. Este modelo foi incorporado ao trabalho devido à sua importância na etapa de segmentação, que está detalhado na seção (4.3). Outro fator que anula a utilização da escala de cinza na etapa de pré-processamento é a extração de características de cor, descrito na subseção (4.4.3), na qual considera as três componentes do modelo de cor que constitui a imagem. Após a seleção do modelo de cor que será utilizado, o processo pode seguir três caminhos distintos até obter a imagem filtrada. Esses caminhos se diferenciam devido à aplicação ou omissão da quantização de cores.

A quantização de cores é uma etapa opcional no processamento das imagens neste trabalho. Dessa forma, a quantização pode ser omitida e, após a seleção do modelo de cor, aplica-se diretamente o filtro de difusão anisotrópica. Além desse percurso, a quantização pode ser aplicada antes ou depois do filtro utilizado. Sendo assim, seleciona-se o modelo de cor, aplica-se a quantização e o filtro ou, seleciona-se o modelo de cor, realiza-se a filtragem e, em seguida, a quantização de cores.

O filtro de difusão anisotrópica foi escolhido por oferecer excelentes resultados, suavizando as regiões internas e mantendo as bordas [37]. Essa propriedade é importante para o processamento de imagens de pele, pois a borda é uma das características analisadas para a classificação da malignidade da lesão [15, 35].

Na figura (4.2) é exibida a estrutura da etapa de pré-processamento que foi construída. Nesta figura é possível observar os três caminhos descritos anteriormente, desde a imagem original até à imagem resultante no processo. A imagem resultante é aproveitada na etapa de segmentação para a separação entre a região a ser estudada e a região de fundo.




Figura 4.2: Etapa de pré-processamento

Os itens que compõem a etapa de pré-processamento estão descritos em subseções específicas para a implementação dos modelos de cor, quantização de cores e filtro de difusão anisotrópica.

4.2.1 - Modelos de cor

Os modelos de cor disponíveis neste trabalho são o RGB, o YIQ e o HSI, além da possibilidade da imagem ser convertida em níveis de cinza. A opção de escolher um determinado modelo de cor proporcionou uma maior flexibilidade ao trabalho desenvolvido e um estudo comparativo entre esses modelos. Desta forma foi possível analisar os resultados obtidos e seleccionar o modelo de cor ideal para as imagens trabalhadas.

A imagem original é fornecida no modelo de cor RGB. Este modelo é caracterizado por representar a forma espectral das três cores primárias: vermelho, verde e

azul [31, 32]. Sendo assim, o modelo RGB não separa a luminosidade da cromaticidade. Se o modelo utilizado for este mesmo não é necessário realizar nenhum procedimento adicional e a imagem segue o fluxo estabelecido na etapa de pré-processamento. Caso contrário, a conversão para o modelo adotado é necessária.

As imagens de pele podem ter diferenças de luminosidade e sombreamento. Sendo assim, nos modelos de cor YIQ e HSI são realizadas a separação da luminosidade das componentes de cor constituintes da imagem. Desta forma, trabalha-se com a cor sem a influência da luz [31, 32]. Caso o modelo escolhido seja o formato YIQ, a conversão acontece pelo uso da equação (3.6). Caso o modelo escolhido seja o formato HSI, a conversão faz uso das equações (3.7), (3.8) e (3.9) para encontrar os valores referentes ao matiz, à saturação e à intensidade, respectivamente.

As componentes de luminosidade Y no modelo YIQ e I no modelo HSI passam por um tratamento adicional na utilização desses modelos. Somente nestas componentes é realizada a equalização do histograma para ter uma melhor distribuição de luz por toda a imagem. Este tratamento visa corrigir imperfeições de luminosidades e possíveis sombras. Na sequência, a imagem é convertida novamente para o modelo RGB. Após a conversão, o processo segue para a quantização de cores ou para a aplicação do filtro.

Além desses três modelos de cores citados, a imagem pode ser transformada em níveis de cinza. A conversão é realizada pelo uso da equação (4.1), cujo parâmetro R refere-se ao valor da componente de cor vermelha no modelo RGB, G ao valor da componente verde e B da componente azul [71].

$$V = 0,3 * R + 0,59 * G + 0,11 * B \quad (4.1)$$

Na figura (4.3a) é mostrada a imagem original no modelo de cor RGB. A imagem exibida em (4.3b) foi convertida para YIQ, passou pela equalização do histograma na componente Y e foi convertida novamente para o modelo RGB. A imagem em (4.3c) é resultado da conversão para HSI, equalização do histograma na componente I e conversão para RGB. E a imagem apresentada em (4.3d) é uma conversão direta da imagem original para escala de cinza por meio da equação (4.1).




Figura 4.3: Modelos de cor: (a) imagem RGB [19]; (b) imagem RGB após a equalização da componente Y no modelo YIQ; (c) imagem RGB após a equalização do canal I no modelo HSI; (d) imagem em escala de cinza

4.2.2 - Quantização de cores

O processo de quantização é utilizado para reduzir a quantidade de cores de uma imagem para facilitar a segmentação do objeto analisado evitando a supersegmentação. Este processo é realizado por meio da divisão das cores em intervalos pré-definidos seguido da substituição do valor do *pixel* por um valor correspondente [35]. Desta forma, é necessário escolher uma metodologia para definir o intervalo ao qual o *pixel* analisado irá pertencer.

Neste trabalho são utilizados três conjuntos de intervalos que foram testados juntamente às demais técnicas. Com isso, um estudo comparativo entre os conjuntos foi obtido. Na tabela (4.4) são mostrados os conjuntos utilizados. Sendo assim, no primeiro conjunto, o primeiro intervalo engloba os valores de 0 a 7, o segundo intervalo engloba os valores de 8 a 15 e, assim, sucessivamente até o último intervalo, valores de 248 a 255. O valor do *pixel* analisado é trocado pelo limite inferior do intervalo correspondente. Desta forma, se o valor do ponto é 9, este passa a ser 8 e se o valor do *pixel* é 15, este também recebe o valor 8. Este processo ocorre da mesma maneira nos outros conjuntos.

Tabela 4.4: Divisão dos intervalos no processo da quantização de cores

Conjuntos	Intervalos
Primeiro Conjunto	32 intervalos englobando 8 valores cada
Segundo Conjunto	16 intervalos englobando 16 valores cada
Terceiro Conjunto	8 intervalos englobando 32 valores cada

Partindo do princípio de que cada imagem é constituída por três componentes, a quantização de cores é aplicada em todas as componentes da imagem separadamente. Portanto, tomando o terceiro conjunto como exemplo, cada componente tem somente 8 possíveis valores distintos e, como são três componentes, o máximo de cores nesta imagem gerada é 512. A exceção ocorre nas imagens em escala de cinza, pois existe somente uma componente e, com isso, a quantidade máxima de cores é a própria quantidade de intervalos.

Além dos intervalos, a quantização pode ser omitida ou aplicada durante a etapa de pré-processamento. A aplicação pode ocorrer antes ou após o filtro de difusão anisotrópica. A ordem de aplicação ou omissão da quantização nas imagens agregou dados ao estudo e proporcionou informações para encontrar o modelo ideal.

Na figura (4.4) é mostrada a quantização de cores em imagens utilizando o terceiro conjunto de intervalos. Em (4.4a), a imagem original colorida RGB foi quantizada resultando na figura (4.4b). Do mesmo modo, a figura (4.4c) em níveis de cinza foi quantizada resultando na figura (4.4d). Estas imagens não foram filtradas e nem convertidas anteriormente para nenhum outro modelo de cor.




Figura 4.4: Quantização de cores utilizando 8 cores em cada componente: (a) imagem original em RGB [19]; (b) imagem original quantizada; (c) imagem em escala de cinza; (d) imagem em escala de cinza quantizada.

4.2.3 - Filtro de Difusão Anisotrópica

Na filtragem da imagem utilizou-se o filtro de difusão anisotrópica. Este filtro foi escolhido por proporcionar suavização nas regiões internas e manter o contorno nas regiões de fronteira. Essa propriedade é importante para o processamento de imagens de pele, pois a

borda é uma das características analisadas na classificação da malignidade da lesão [15, 35].

Com o objetivo de obter dados comparativos, além do filtro de difusão anisotrópica, o filtro da média e o filtro da mediana também foram implementados. Nestes dois filtros citados foi utilizada a vizinhança de oito para estabelecer a matriz quadrática do processo [31, 32]. A máscara quadrática de tamanho três foi escolhida por oferecer a menor perda da definição da imagem, fato que ocorre com máscaras de tamanho maior no filtro da média. O filtro da mediana possui grande aplicabilidade em imagens com ruídos impulsivos. Neste caso, os *pixels* que constituem os ruídos, durante a aplicação do filtro, estarão em uma das extremidades durante a ordenação e seu valor será desconsiderado [72].

No algoritmo desenvolvido para o filtro de difusão anisotrópica, a equação (3.39) foi implementada juntamente com a função gaussiana mostrada na equação (3.43) que é utilizada na função de suavização, exibida na equação (3.20). O algoritmo foi ajustado para realizar a filtragem nas três componentes de cores separadamente. Porém, se for o caso de analisar imagens em escala de cinza basta atribuir o mesmo valor do *pixel* nas três componentes que o algoritmo manterá a sua funcionalidade. Na função de suavização, o termo $|\nabla (G_T u)|^2$ é definido de acordo com a equação (4.2), no qual $G_\sigma(x, y)$ está relacionado a uma coordenada $u_{i,j}$ [37].

$$\begin{aligned}
 |\nabla (G_T u)|^2 = & \frac{1}{36} * \{G_\sigma(1,1) * u_{(i-1,j-1)} + G_\sigma(-1,1) * u_{(i+1,j-1)} + G_\sigma(1,-1) * u_{(i-1,j+1)} \\
 & + G_\sigma(-1,-1) * u_{(i+1,j+1)} + 16 * G_\sigma(0,0) * u_{(i,j)} + 4 * [G_\sigma(0,1) * u_{(i,j-1)} \\
 & + G_\sigma(1,0) * u_{(i-1,j)} + G_\sigma(-1,0) * u_{(i+1,j)} + G_\sigma(0,1) * u_{(i,j+1)}]\} \quad (4.2)
 \end{aligned}$$

O resultado da difusão anisotrópica x obtido em cada *pixel* para cada canal pode estar fora do intervalo de cores $I = [0, \dots, 255]$ que define as componentes e, portanto, é necessário uma normalização dos valores. Para isso, calcula-se o determinante considerando o valor máximo e mínimo encontrado durante a iteração e, dessa forma, o valor normalizado y é definido [31]. A matriz para o cálculo do determinante é exibida na equação (4.3) e na equação (4.4) é apresentada a equação resultante desta aplicação.

$$\det \begin{bmatrix} \text{mínimo} & \text{máximo} & x \\ 0 & 255 & y \\ 1 & 1 & 1 \end{bmatrix} = 0 \quad (4.3)$$

$$y = \frac{255 * (x - \text{mínimo})}{\text{máximo} - \text{mínimo}} \quad (4.4)$$

O filtro de difusão anisotrópica possui algumas constantes que precisam ser definidas como: o desvio padrão de ruído σ , a velocidade da difusão λ , a evolução temporal Δt e os parâmetros a da função gaussiana e k da função de suavização. A quantidade de iterações do método, definida na equação (3.40), necessita dos valores de σ e a . Segundo Silva Júnior [37], essa equação foi definida com a adoção de $\lambda = \sigma$. Os valores desses parâmetros foram definidos baseados em testes utilizados em outros trabalhos [15, 35] e terão valores tais como $\Delta t = 0.1$, $k = 0.0008$, $a = 0.01$ e $\lambda = \sigma = 1$. A constante a recebeu este valor para que a quantidade de iterações permanecesse em 100, valor estabelecido por Oliveira [15], segundo a definição da equação (3.40) [37].

Apesar do uso de um valor fixo de iterações para o filtro, neste trabalho é proposta outra metodologia para a definição da quantidade de iterações. Partindo do princípio de que a imagem pode continuar sofrendo a filtragem sem ser degenerada após o ponto de parada [37], nesta proposta é realizada a comparação da imagem gerada na iteração atual com a imagem gerada na iteração anterior. Analisando o resultado desta comparação, se houver diferença entre as intensidades dos *pixels*, há imagens diferentes e, portanto, a imagem ainda não alcançou o ponto de parada. Nessa situação, a filtragem necessita de mais iterações. Esse processo prossegue até que a imagem gerada seja igual à imagem anterior. Essa afirmação é válida em casos contínuos, porém quando se faz uso da discretização, uma margem de erro na diferença da intensidade entre os *pixels* é aceitável. Sendo assim, quando a expressão $|\text{valorAtual} - \text{valorAnterior}| \leq \text{erro}$ é satisfeita para todas as coordenadas em todas as componentes, a iteração do filtro é interrompida. Junto às constantes definidas anteriormente, foram testados três valores para satisfazer a expressão da margem de erro aceitável, assumindo os valores 3, 5 e 7 de intensidade.

Na figura (4.5) é mostrada a aplicação do filtro de difusão anisotrópica. Na parte (a) é exibida a imagem original em RGB. Essa imagem também pode ser visualizada após a conversão em níveis de cinza, parte (c). As imagens em (b) e (d) são as originais (a) e (c) após

a aplicação do filtro de difusão anisotrópica com 100 repetições. As imagens apresentadas na figura (4.5) não foram submetidas ao processo de quantização de cores e nem convertidas anteriormente para nenhum outro modelo de cor.




Figura 4.5: Filtro de Difusão Anisotrópica: (a) imagem original em RGB [19]; (b) imagem original suavizada; (c) imagem em escala de cinza; (d) imagem em escala de cinza suavizada.

Um dos problemas recorrentes em filtros é o tratamento dos *pixels* que se situam nas margens da imagem. Essa situação ocorre pela falta de alguns vizinhos necessários para o *pixel* analisado e, por isso, deve-se adotar alguma alternativa que supra a ausência desses valores. Partindo do princípio de que esses vizinhos, nas imagens de lesões de pele, sempre fazem parte da pele, o valor adotado para eles foi o mesmo valor do *pixel* situado na margem. Com isso, a ideia de continuidade da pele se estende do ponto em questão para os seus vizinhos. Tomando como exemplo o filtro de difusão anisotrópica com 100 repetições, a influência do valor adotado para essa ausência se estenderá até o centésimo vizinho do ponto analisado. Por esta razão, o valor adotado aqui busca diminuir ao máximo essa influência. A alternativa escolhida foi aplicada nos três filtros implementados.

4.3 - Segmentação

Com a imagem suavizada, na etapa de segmentação o objeto de interesse é isolado do fundo da imagem. Para isso, a transformada imagem-floresta diferencial pode ser utilizada separadamente ou em conjunto com a operação morfológica de fechamento neste trabalho. Na

figura (4.6) é apresentada a estrutura da etapa de segmentação desenvolvida. A imagem resultante da etapa de pré-processamento pode ser submetida diretamente à transformada imagem-floresta, ou primeiramente à operação de fechamento e, em seguida, à transformada.




Figura 4.6: Etapa de segmentação

Apesar da morfologia matemática e da transformada imagem-floresta diferencial poderem ser aplicadas diretamente em imagens coloridas [45], as imagens foram convertidas para a escala de cinza a fim de reduzir a carga de processamento nos algoritmos.

4.3.1 – Morfologia Matemática

A operação de fechamento da morfologia matemática foi escolhida devido à sua capacidade de eliminar pequenos objetos e preencher lacunas [31, 32]. As imagens de pele podem possuir muitas irregularidades, como é o caso dos pelos que podem ser eliminados com o uso deste recurso. Desta forma, as imperfeições são mapeadas em pele ou em lesão. Este fato também evita a necessidade de se escolher múltiplos nós sementes na transformada imagem-floresta. No uso da operação de fechamento, os detalhes escuros são reduzidos e os elementos claros são praticamente inalterados durante a dilatação. E, com a erosão, a imagem é escurecida novamente sem reintroduzir os detalhes removidos.

A extensão da morfologia matemática binária para imagens em escala de cinza é facilmente extensível. Na dilatação, para cada coordenada do plano, são calculadas as somas do valor do *pixel* com seu valor correspondente no elemento estruturante. O valor resultante para essa coordenada é o máximo entre essas somas. E, na erosão, o valor resultante é o mínimo das subtrações entre o valor do *pixel* com o valor do elemento estruturante [32]. Nas equações (4.5) e (4.6) são denotadas respectivamente as definições da dilatação e erosão em que o parâmetro de deslocamento $(s - x), (t - y)$ está contido no domínio da imagem e (x, y) no domínio do elemento estruturante b .

$$(f \oplus b)(s, t) = \max \{f(s - x, t - y) + b(x, y)\} \quad (4.5)$$

$$(f \ominus b)(s, t) = \min \{f(s + x, t + y) - b(x, y)\} \quad (4.6)$$

Segundo Neves [33], o elemento estruturante adequado para uma imagem deve ser escolhido de acordo com as características de convexidade, não convexidade, isotropia e anisotropia do objeto analisado. Desta forma, se o objetivo é eliminar pelos, o elemento estruturante com melhor rendimento deverá ter o formato linear. Outra propriedade do elemento estruturante é o seu tamanho. Para evitar que a região que compreende a lesão seja danificada, o tamanho deve ser pequeno. Para imagens em níveis de cinza, o elemento estruturante utilizado é composto por uma máscara de pesos. Com isso, para que a imagem fique mais clara e os detalhes escuros sejam removidos durante a dilatação, os pesos determinados devem ser valores positivos [32]. O mesmo acontece para a operação da erosão, utilizam-se valores positivos para que a imagem se torne mais escura e reduza os detalhes mais claros. O elemento estruturante adotado é exibido na figura (4.7).

1		1		1
	1	1	1	
1	1	1	1	1
	1	1	1	
1		1		1

Figura 4.7: Elemento estruturante utilizado na operação de fechamento

No elemento estruturante adotado, os espaços vazios são os *pixels* desconsiderados na aplicação da operação. Os demais espaços foram considerados por formarem as linhas horizontal, vertical e as diagonais. O mesmo peso foi atribuído a todos os espaços considerados por oferecer a mesma importância entre eles. A aplicação da equação (4.4) para normalização dos dados fora do intervalo $I = [0, \dots, 255]$ ocorre após a operação.

Na figura (4.8) é apresentado o resultado das operações de dilatação (4.8b) e erosão (4.8c) de uma imagem em escala de cinza (4.8a). Na operação de fechamento, imagem (4.8d), a aplicação da dilatação deixou a imagem mais clara, reduzindo a presença dos pelos e, com a erosão, a imagem voltou a ser mais escura novamente. Nesta imagem é possível observar que a quantidade de linhas que representam os pelos foi reduzida drasticamente. A imagem em (4.8a) não passou por nenhum processo de filtragem ou quantização de cores e foi submetida somente à conversão direta do modelo RGB.




Figura 4.8: Morfologia matemática em níveis de cinza: (a) imagem base em níveis de cinza; (b) aplicação isolada da operação de dilatação; (c) aplicação isolada da operação de erosão; (d) aplicação da operação de fechamento, dilatação seguida de erosão

4.3.2 – Transformada Imagem-Floresta Diferencial

A transformada imagem-floresta diferencial [51] necessita da escolha de nós sementes, uma relação de adjacência, uma função de custo suave e marcadores de remoção como dados de entrada de seu algoritmo. Em imagens de pele, geralmente, as lesões se concentram no centro e o fundo está contido por todo o limite da imagem. Sendo assim, a escolha do *pixel* central da imagem para denotar a semente da região interna e um *pixel* próximo do canto superior esquerdo para designar a semente da região externa são escolhas

apropriadas e que foram utilizadas neste estudo. O *pixel* superior esquerdo não foi escolhido como nó semente por pertencer à margem da imagem, o que poderia acarretar discrepâncias nos resultados por causa de imagens obtidas com fundos não pertencentes à região de pele.

Como padrão, a coordenada $(x, y) = (10, 10)$ foi adotada como o *pixel* próximo do canto superior esquerdo. Este valor foi escolhido após a análise visual das imagens aqui utilizadas, independentemente do tamanho delas. O *pixel* central é encontrado verificando a quantidade de pontos nos eixos x e y e dividindo por dois. Na figura (4.9) são apresentados os dois *pixels* citados anteriormente, que denotam as regiões externa e interna.



Figura 4.9: Nós sementes para as regiões externa (*pixel* próximo do canto superior esquerdo) e interna (*pixel* central) da lesão [19-adaptado]

Além dos nós sementes, o algoritmo também necessita da definição de uma relação de adjacência e uma função suave de valor de caminho. A relação de adjacência aplicada neste algoritmo é a distância euclidiana com valor $d(s, t) = 1$. Desta forma, um *pixel* p está conectado a quatro vizinhos de coordenadas $(x + 1, y)$, $(x - 1, y)$, $(x, y + 1)$ e $(x, y - 1)$ [31, 32]. A função suave de valor de caminho adotada está descrita nas equações (3.44) para a inicialização dos valores e (3.45) para a atualização dos valores. Neste trabalho não foi utilizado os marcadores de remoção e, por esta causa, $M_R = 0$.

O pseudocódigo que descreve a transformada imagem-floresta diferencial é exposto no algoritmo (4.1). A saída do algoritmo é composta pelo mapa de valores de caminhos V , mapa de predecessores P e o mapa de raízes R . O mapa de raízes R relaciona os *pixels* analisados a um dos nós sementes escolhidos inicialmente. Desta forma, as coordenadas que estão associadas ao *pixel* central fazem parte do objeto desejado.

Adicionalmente, no algoritmo é definida a relação de adjacência A , a função suave de valor de caminho f , uma fila de prioridades Q com política de desempate FIFO que está inicialmente vazia e o mapa de cores C para indicar a relação dos *pixels* à fila de prioridades. Adicionalmente, é possível incorporar aos dados de entrada um mapa de rótulos L para que se tenha uma imagem binária resultante. Desta forma, os *pixels* associados à semente interna recebem o valor zero e os demais o valor 255. A implementação do algoritmo se baseou na adaptação do trabalho de Falcão e Spina [73] que disponibilizaram o código da transformada imagem-floresta diferencial.

Algoritmo 4.1 - Transformada Imagem-Floresta Diferencial

```

Para cada nó  $s$  do grafo derivado da imagem faça
     $P(s) \leftarrow \text{nulo}$ 
     $R(s) \leftarrow s$ 
     $V(s) \leftarrow f(<p>)$ 
     $C(s) \leftarrow \text{branco}$ 
    Se  $V(s)$  for finito então
         $\text{Insira } s \text{ em } Q$ 
         $C(s) \leftarrow \text{cinza}$ 
    Se nó  $s$  é semente da região interna então
         $L(s) \leftarrow 0$ 
    Se nó  $s$  é semente da região externa então
         $L(s) \leftarrow 255$ 
Enquanto  $Q$  não for vazia faça
    Remova  $s$  de  $Q$  tal que  $V(s)$  é mínimo
     $C(s) \leftarrow \text{preto}$ 
    Para cada nó  $t \in A(s)$  tal que  $V(t) > V(s)$  faça
        Se  $C(t) \neq \text{preto}$  então
             $\text{custo} \leftarrow f(P * (s) \cdot <s, t>)$ 
            Se  $\text{custo} < V(t)$  ou  $P(t) = s$  então
                Se  $C(t) = \text{cinza}$  então
                     $\text{Remova } t \text{ de } Q$ 
                     $C(t) = \text{preto}$ 
                 $P(t) \leftarrow s$ 
                 $R(t) \leftarrow R(s)$ 
                 $V(t) \leftarrow \text{custo}$ 
                 $L(t) \leftarrow L(s)$ 
                 $C(t) = \text{cinza}$ 
                 $\text{Insira } t \text{ em } Q$ 
    Retorne  $\{V, P, R, L\}$ 

```

No algoritmo (4.1) todos os mapas possuem a mesma dimensão e tamanho da imagem de entrada. Sendo assim, cada posição nos mapas corresponde diretamente a uma

coordenada da imagem. Inicialmente, o mapa de predecessores P está vazio para todas as posições e para cada nó do mapa de raízes R , o valor atribuído é a própria coordenada do elemento. A função suave de valor de caminho é utilizada para inicializar o mapa de custos V . Se a posição é marcada como um nó semente, o valor atribuído é zero e, caso contrário, o valor nulo. Se a posição é nó semente, ela é inserida na fila de prioridades. Para todas as posições do mapa de cores C , a cor branca é atribuída, exceto para as posições adicionadas na fila de prioridades que recebem a cor cinza. E, por último, no mapa de rótulos L , os pontos que pertencem à região interna recebem o valor zero e os pontos pertencentes à região externa recebem o valor 255.

Com a inicialização pronta, enquanto a fila de prioridades não for vazia, o nó com custo menor será retirado para análise e sua cor alterada para preto. Para cada nó adjacente ao nó extraído da fila, se sua cor for diferente de preto, calcula-se o custo entre eles e, se este for menor que o valor do adjacente ou se este nó é uma raiz, atualiza-se para o nó adjacente o mapa de predecessores P com o nó retirado da fila, o mapa de raízes R e o mapa de rótulos L com o valor do nó analisado e o mapa de custos V com o novo custo. Caso a cor do nó adjacente seja cinza, indicando que ele já está na fila, ele é retirado da fila e tem sua cor atualizada para preto. E, para finalizar o processo, o nó adjacente é inserido na fila de prioridades novamente para futura análise e sua cor alterada para cinza.

Para que a segmentação com apenas duas sementes seja eficiente na transformada imagem-floresta é necessário utilizar previamente a estimativa de peso nos arcos do grafo, na qual é verificada a probabilidade de cada *pixel* pertencer ou não ao objeto [53]. Desta forma, a imagem segmentada na transformada é a imagem resultante da estimativa.

Para realizar a estimativa é preciso definir um classificador *fuzzy*, um conjunto de treinamento T e uma relação de adjacência A . Sendo assim, o classificador utilizado foi a floresta de caminhos ótimos *fuzzy*, os *pixels* que formam o conjunto de treinamento são os mesmos definidos para a transformada, ou seja, o *pixel* central para a região interna e o *pixel* próximo ao canto superior esquerdo para a região externa ao objeto, e a relação de adjacência adotada também foi a distância euclidiana. Nesta fase, calculam-se os valores de conectividade V_o e V_b , definidos nas equações (3.46) e (3.47), para encontrar o valor *fuzzy* do *pixel*, equação (3.48). Logo após, na atribuição dos pesos, a combinação do gradiente do objeto W_o com o gradiente das características W_f , conforme descrito na equação (3.49), proporciona a imagem que será segmentada na transformada imagem-floresta diferencial.

Para esta equação foi adotado $\gamma = 0.5$, indicando que os gradientes possuem a mesma relevância.

Na figura (4.10) são mostrados alguns resultados da etapa de segmentação. Na parte (a) é apresentada a imagem original em RGB. Em (4.10b) é exibida a imagem resultante da quantização de cores com oito intervalos. As imagens resultantes da estimativa de peso nos arcos e da transformada imagem-floresta são exibidas, respectivamente, em três casos. No primeiro caso, as imagens (4.10c) e (4.10d) foram obtidas com o uso precedente da quantização de cores com oito intervalos e da operação de fechamento da morfologia matemática. No segundo caso, imagens (4.10e) e (4.10f), há aplicação somente da operação de fechamento da morfologia matemática. E o último caso há aplicação somente da quantização de cores com oito intervalos, imagens (4.10g) e (4.10h). Essas imagens não foram submetidas a nenhum processo de conversão para outro modelo de cor ou suavização.




Figura 4.10: Estimativa de Peso nos Arcos e Transformada Imagem-Floresta: (a) imagem original em RGB [19];

(b) quantização com 8 intervalos; (c) estimativa de peso nos arcos precedida da operação de fechamento e quantização com 8 intervalos; (d) transformada imagem-floresta com estimativa de peso nos arcos precedida da quantização com 8 intervalos e operação de fechamento; (e) estimativa de peso nos arcos precedida da operação de fechamento e sem quantização; (f) transformada imagem-floresta com estimativa de peso nos arcos precedida da operação de fechamento e sem quantização; (g) estimativa de peso nos arcos precedida somente da quantização com 8 intervalos; (h) transformada imagem-floresta com estimativa de peso nos arcos precedida da quantização com 8 intervalos

4.4 - Extração de características

Após a segmentação, na etapa de extração de características é realizada a coleta das informações necessárias do objeto de estudo para classificá-lo. A lesão segmentada foi, neste trabalho, avaliada pela regra ABCD.

Na regra ABCD, a lesão contida na imagem é definida por meio da descrição das características de assimetria, borda, cor e estruturas diferenciais. A esses parâmetros são definidas pontuações para o cálculo da Pontuação Dermoscópica Total, como mostrado na equação (2.1). A metodologia aqui implementada se baseia nos trabalhos de Oliveira [15] e Araújo [35] consistindo em definir se a lesão é assimétrica ou simétrica, se a borda é regular ou irregular, se a cor é homogênea ou heterogênea e se a textura é uniforme ou não uniforme.

Na figura (4.11) é representada a etapa de extração de características. Após a segmentação da lesão, a imagem resultante é utilizada pelos descritores de assimetria, borda, cor e estruturas diferenciais. Após a extração, os vetores de características obtidos são analisados no classificador.




Figura 4.11: Etapa de extração de características

4.4.1 - Assimetria

A assimetria é analisada por meio da definição de segmentos de reta sobre o objeto segmentado. Ao traçar um segmento de reta sobre a lesão, o objeto é dividido em duas

regiões distintas que são comparadas. Se essas regiões são similares, elas são consideradas simétricas. Caso contrário, assimétricas.

Para analisar a assimetria, um segmento de reta D é traçado ligando os dois pontos da borda da lesão mais distantes entre si, dividindo-a em duas regiões. Para encontrar os pontos mais distantes entre si calcula-se a distância euclidiana, equação (3.1), entre todos os pares de *pixels* contidos na borda do objeto. Logo após, um segundo segmento é traçado perpendicularmente em relação ao primeiro. Com isso, obtêm-se duas retas P_1 e P_2 que se iniciam no segmento D e terminam em um ponto da borda. Considerando somente os segmentos P_1 e P_2 , a razão do tamanho do menor deles em relação ao tamanho do maior deles indica o grau de assimetria neste ponto. Quando este coeficiente fica próximo de zero, as regiões são mais assimétricas e, quando o coeficiente fica próximo de um, as regiões são mais simétricas neste ponto. Os segmentos perpendiculares são traçados de acordo com a quantidade desejada.

Na figura (4.12) são mostradas duas lesões de pele. A linha branca denota a fronteira entre a lesão analisada e o fundo da imagem. Sobre os objetos segmentados é traçado uma linha amarela D que liga os pontos mais distantes calculados pela distância euclidiana. Sobre este segmento de cor amarela é traçado uma reta perpendicular para denotar o segundo eixo desejado, linhas azul e vermelha, P_1 e P_2 , respectivamente. Na parte (a) é possível observar que há pouca diferença entre as regiões divididas pelo segmento D , sendo considerada uma lesão simétrica. Na parte (b), as regiões definidas por D são muito diferentes entre si, sendo considerada como uma lesão assimétrica.




Figura 4.12: Regra ABCD, característica de assimetria: (a) lesão simétrica; (b) lesão assimétrica [15]

A quantidade de retas perpendiculares traçadas poderá ser diferente em cada imagem devido ao tamanho do primeiro segmento. Sendo assim, para manter a mesma quantidade de retas perpendiculares entre todas as imagens analisadas é necessário diferenciar a distância entre elas sobre o primeiro eixo. Considerando n o número de retas desejadas, o valor do diâmetro D deverá ser dividido por $n + 1$ espaços.

Após o cálculo das razões, calcula-se a área de cada região definida pelo segmento de reta D . A área de cada região é obtida pelo somatório da quantidade de *pixels* existentes entre os pontos que formam a diagonal e os pontos pertencentes ao contorno. Cada somatório é dividido pela quantidade total de *pixels* da lesão segmentada. Desta forma, a área de cada região é representada pelo seu proporcional em relação ao todo.

As informações sobre as razões calculadas entre as retas perpendiculares são armazenadas em um vetor de características que será avaliado pelo classificador da floresta de caminhos ótimos. Para a característica de assimetria, um vetor foi construído e possui informações sobre a média de 10, 20, 30, 40 e 50 razões traçadas sobre o primeiro segmento e seus respectivos desvios padrão. Além dessas informações, a menor razão de 10, a maior razão de 10 e os proporcionais das duas áreas são adicionados a este vetor. Desta forma, consideram-se quatorze valores para caracterizar a lesão como simétrica ou assimétrica.

4.4.2 - Borda

A segunda característica analisada é a borda. Para medir o grau de regularidade da borda e classificá-la, as informações são extraídas a partir da representação unidimensional do contorno da lesão, denominada como assinatura [32]. Com a fronteira do objeto definida e utilizando vizinhança de oito, a assinatura é encontrada com a determinação da sequência correta dos *pixels* no contorno. Para isso, é necessário encontrar o centro geométrico da região selecionada e definir o ponto inicial do contorno. Este ponto central é o encontro da diagonal da região com sua maior perpendicular. Como a diagonal já foi calculada no descritor da assimetria, é necessário apenas comparar as perpendiculares traçadas também na assimetria para definir qual é a maior.

Na figura (4.13a) é exibida uma imagem de lesão de pele com a fronteira definida pela linha branca. Na parte (b) da figura, a assinatura da respectiva lesão é mostrada

representando a distância do ponto da fronteira até a margem da imagem referente às colunas.




Figura 4.13: Regra ABCD, característica de borda: (a) lesão; (b) assinatura da região segmentada

Para analisar as características da borda, o produto vetorial e o ponto de inflexão foram utilizados. Assim, a quantidade de picos, vales e retas contidos na assinatura da fronteira são contadas a partir do uso destas duas técnicas.

O produto vetorial P utiliza três pontos $p_1(x_1, y_1)$, $p_2(x_2, y_2)$ e $p_3(x_3, y_3)$ para definir sua direção com variação de i pixels de intervalo entre esses pontos. Um vale é identificado quando $P < 0$, para os valores de $P > 0$ se tem um pico e quando $P = 0$ obtém-se uma reta. O cálculo do produto vetorial é definido na equação (4.7).

$$P = (x_2 - x_1) * (y_3 - y_1) - (y_2 - y_1) * (x_3 - x_1) \quad (4.7)$$

O ponto de inflexão analisa i pontos vizinhos da direita e i pontos vizinhos da esquerda de um ponto P . Analisando esses vizinhos verifica-se se o ponto P sofre uma mudança de direção. Tomando como base a coordenada y , os pontos que estiverem abaixo do ponto P recebem valor de peso 1 e os pontos que estiverem acima recebem valor de peso -1. Após a atribuição dos pesos, realiza-se a soma de cada lado do ponto P . Se o valor absoluto da soma de cada lado for maior ou igual a dois é denotada uma irregularidade pequena. Para as irregularidades grandes, o valor absoluto da soma deve ser maior ou igual a sete. A identificação de picos, vales e retas no ponto de inflexão se define pela soma dos dois lados. Se a soma é positiva a inflexão é um pico, se a soma é negativa a inflexão é um vale e se a soma é zero a inflexão é uma reta.

A identificação de irregularidades pequenas ou grandes no produto vetorial e a quantidade de vizinhos do ponto de inflexão são definidas pelo valor de i . Baseando-se no trabalho de Oliveira [15] e Araújo [35], os valores utilizados foram $i = 4$ para as pequenas irregularidades e $i = 15$ para as grandes irregularidades. As quantidades de picos, vales e retas do produto vetorial são divididas pela quantidade de amostras analisadas e no ponto de inflexão pela quantidade de pontos de inflexão encontrados. Portanto, o somatório da quantidade de picos com vales e retas é sempre um.

As proporções de picos, vales e retas para pequenas e grandes irregularidades obtidas no produto vetorial e no ponto de inflexão são armazenadas em um vetor de característica. Além desses doze valores, calcularam-se também as seis médias correspondentes entre as proporções obtidas no produto vetorial com as proporções obtidas no ponto de inflexão. Portanto, no fator borda são considerados dezoito parâmetros para classificar a lesão como borda regular ou borda irregular.

4.4.3 - Cor

A variedade de cores na tonalidade da lesão é uma das características utilizadas para definir o grau de malignidade. As lesões malignas possuem tonalidade mais heterogênea e as lesões não malignas possuem tonalidade mais homogênea. Sendo assim, a verificação das cores presentes na região da lesão foi realizada por meio da análise da média, da variância e do desvio padrão nos *pixels* pertencentes ao objeto segmentado. O desvio padrão é obtido com a raiz quadrada da variância. Esta, por sua vez, é obtida com o somatório dos quadrados do valor do *pixel* p subtraído da média μ e dividido pela quantidade de termos N , como na equação (4.8) [11].

$$Variância = \frac{1}{N} * \sum_{j=1}^N (p_j - \mu)^2 \quad (4.8)$$

Na característica de cor, neste trabalho, também é considerada a homogeneidade e o contraste na região da lesão. A homogeneidade é uma medida que indica a uniformidade da

tonalidade e é descrita na equação (4.9) em que i e j são as coordenadas da imagem e $p(i, j)$ é o valor do *pixel* [4]. A definição do contraste [4] é mostrada na equação (4.10).

$$Homogeneidade = \sum_{i=0}^{N-1} \sum_{j=0}^{M-1} \frac{p(i, j)}{1 + |i - j|} \quad (4.9)$$

$$Contraste = \sum_{i=0}^{N-1} \sum_{j=0}^{M-1} [(i - j)^2] * p(i, j) \quad (4.10)$$

Para essa propriedade da regra ABCD foi utilizado um vetor de características para armazenar as informações necessárias da região segmentada. Este vetor contém os dados da média, da variância, do desvio padrão, da homogeneidade e do contraste de cada canal RGB e também em níveis de cinza. Para a cor são considerados, então, vinte valores para que a lesão seja classificada como heterogênea ou homogênea.

4.4.4 – Estruturas diferenciais

A característica de estruturas diferenciais envolve a análise de textura da lesão para classificá-la em uniforme ou não uniforme. Neste trabalho, o método *Box Counting* da dimensão fractal foi utilizado com esta finalidade. Este método utiliza uma grade que é posta sobre a imagem, dividindo-a em partes cada vez menores [30].

Na aplicação do *Box Counting* em imagens representadas com níveis de cinza, cada região resultante da grade é tratada como um espaço de três dimensões, na qual as coordenadas da imagem formam o plano e os valores dos *pixels* correspondem à elevação da superfície [72]. Desta forma, quando todos os *pixels* da região analisada possuem o mesmo valor, a elevação da superfície é nula e, portanto, a dimensão fractal é 2. Caso contrário, quando há variação no valor dos *pixels* a elevação da superfície é gerada, criando um volume incompleto. Portanto, a dimensão fractal, nestes casos, varia no intervalo de $2 < D < 3$.

Neste trabalho, o cálculo da dimensão fractal, exibido na equação (3.70), foi realizado primeiramente na região da lesão segmentada. Logo após, sobre a imagem completa foi posta a grade relativa à primeira iteração do método, obtendo dezesseis partes. Portanto, a dimensão fractal é calculada separadamente em cada região obtida. Nos casos em que a quantidade de linhas ou colunas não seja múltipla de quatro, a imagem não pode ser dividida em partes de mesmo tamanho. Então, os quadrantes da direita e os quadrantes inferiores podem ter tamanhos diferentes dos demais. Essa diferença pode variar somente de um a três *pixels* por linha e/ou coluna. Porém, o cálculo da dimensão fractal considera essas diferenças. Além destas informações, calculou-se também o valor médio e o desvio padrão entre as regiões obtidas.

Outra medida considerada na textura é a energia. Como apresentado por Guido [74], a textura pode ser interpretada como conjuntos periódicos de concentração de energia. Sendo assim, a energia é calculada em sub-regiões da imagem. Na equação (4.11) é apresentada a definição matemática da energia.

$$Energia = \sum_{i=0}^{N-1} \sum_{j=0}^{M-1} [p(i,j)]^2 \quad (4.11)$$

Na metodologia empregada para extrair os valores de energia não há sobreposição de regiões e o tamanho das sub-regiões varia de acordo com os parâmetros de entrada, implicando em diferentes níveis de resolução. Estes parâmetros são formados pela escolha de números primos que são elevados ao quadrado e somados, definindo a quantidade total de sub-regiões em que a energia será extraída. O uso dos números primos é para evitar que ocorra sobreposição total de uma região com outra. A quantidade de números primos indica a quantidade de agrupamentos de energia. Sendo assim, os números primos escolhidos foram 2, 3, 5, 7 e 11, dividindo a imagem, primeiramente, em 4 sub-regiões e, posteriormente, em 9, 25, 49 e 121 sub-regiões.

Os valores calculados da dimensão fractal e da energia foram armazenados em um vetor de características para posterior análise na floresta de caminhos ótimos. Neste vetor é armazenada a dimensão fractal da região da lesão, o valor médio entre as dimensões calculadas nas sub-regiões, o respectivo desvio padrão e os dezesseis valores de cada sub-

região. Ademais, os valores de energia são incorporados ao vetor, totalizando dezenove valores de dimensão fractal e duzentos e oito valores de energia para classificar a textura em uniforme ou não uniforme.

4.5 - Classificação das imagens

A classificação das imagens foi realizada pela aplicação da floresta de caminhos ótimos com aprendizado supervisionado por grafo completo. A floresta de caminhos ótimos foi escolhida por apresentar resultados eficientes com menor tempo de resposta em relação a outros classificadores [47].

Os vetores de características gerados durante a etapa de extração de características pela regra ABCD são utilizados na floresta de caminhos ótimos para a classificação da lesão. Primeiramente, os vetores de assimetria são utilizados para definir se a lesão é assimétrica ou simétrica. O mesmo acontece com os vetores da borda para identificar se ela é regular ou irregular, com a cor para rotulá-la como heterogênea ou homogênea e com a textura para catalogá-la como uniforme ou não uniforme. Estas informações são utilizadas para classificar as lesões em três classes distintas: lesão maligna, lesão suspeita ou lesão não maligna. A estrutura da etapa de classificação é apresentada na figura (4.14).




Figura 4.14: Etapa de classificação

Além da classificação por malignidade ilustrada na figura (4.14), neste trabalho também é realizada a classificação por tipo de lesão. Sendo assim, cada tipo de lesão (nevo não maligno, ceratose seborréica, nevo suspeito e melanoma) é analisado com apenas mais um tipo por vez, totalizando seis cruzamentos distintos.

A aplicação da floresta de caminhos ótimos às imagens ocorre em duas fases. Primeiramente, ocorre a fase de treinamento, subseção (4.5.1), para que haja um conhecimento prévio das classes definidas e dos parâmetros de comparação das características e, logo após, acontece a classificação das imagens, subseção (4.5.2). A codificação desenvolvida da floresta de caminhos ótimos foi baseada no trabalho de Papa et al. [75] que disponibilizaram a implementação desta técnica.

4.5.1 – Conjunto de treinamento e aprendizado supervisionado

A fase de treinamento da floresta de caminhos ótimos é formada por três etapas que se inicia com a definição da relação de adjacência, prossegue com a escolha dos protótipos e finaliza com a adoção da função de custo suave. Com estas definições, o algoritmo de treinamento é executado para encontrar a floresta de caminhos ótimos.

Na primeira etapa, a definição da relação de adjacência é baseada na escolha do tipo de grafo adotado para o algoritmo. Desta forma, neste trabalho, foi escolhido o grafo completo. A escolha da relação de adjacência modifica o algoritmo de treinamento, o algoritmo de classificação e o tratamento das informações de entrada para o processamento, conforme exposto na subseção (4.5.2) que trata a respeito da classificação por grafo completo na floresta de caminhos ótimos.

Na utilização do grafo completo, os protótipos são escolhidos como os elementos das regiões de fronteira entre as classes de modo aleatório ou por estimativas [47]. Neste trabalho, os protótipos para o grafo completo foram escolhidos por meio da metodologia da árvore geradora mínima, conforme processo detalhado na figura (3.11a-c). Como o objetivo é classificar as imagens em três categorias (lesões malignas, lesões suspeitas e lesões não malignas), a quantidade mínima de protótipos selecionados deve ser três, um para cada categoria adotada.

Devido à diferenciação do grafo utilizado, a adoção da função de custo suave é diferente em cada versão. Sendo assim, a função de custo utilizada na versão com grafo completo para a fase de treinamento é definida nas equações (3.64) e (3.65).

Com as definições destes três itens, o algoritmo de treinamento pode ser executado. Na versão da floresta de caminhos ótimos por grafo completo, o algoritmo de treinamento é o mesmo algoritmo da classificação, conforme exposto no algoritmo (4.2).

As imagens que irão formar o conjunto de treinamento são escolhidas pela própria floresta de caminhos ótimos, necessitando apenas da definição do tamanho deste conjunto. Com a fase de treinamento finalizada, o algoritmo de classificação pode ser executado nas imagens.

4.5.2 – Classificação por grafo completo

Na floresta de caminhos ótimos com aprendizado supervisionado por grafo completo, as amostras são denotadas pelos nós e os protótipos do conjunto de treinamento são escolhidos como os elementos mais representativos das regiões de fronteira entre as classes. Desta forma, os protótipos competem pelas demais amostras oferecendo seu rótulo até que todas as amostras sejam conquistadas e, com isso, a floresta de caminhos ótimos esteja completamente formada [47].

O algoritmo da floresta de caminhos ótimos por grafo completo utiliza como dados de entrada um conjunto de treinamento Z_1 , protótipos S , uma função f para o cálculo das distâncias e um vetor de atributos v . O conjunto de treinamento foi descrito na subseção (4.5.1) e os protótipos foram obtidos diretamente por estimativas no algoritmo de treinamento do método. A função de custo ótimo utilizada na classificação é exibida nas equações (3.62) e (3.63) e os vetores de atributos foram gerados na etapa de extração de características, seção (4.4). Adicionalmente à classificação da floresta de caminhos ótimos por grafo completo, uma fila de prioridades Q com política de desempate FIFO e que está inicialmente vazia é utilizada no algoritmo. A saída deste algoritmo é formada pelo mapa de rótulos L , pelo mapa de custos V e pela floresta de caminhos ótimos P .

No algoritmo (4.2) é mostrada a floresta de caminhos ótimos por grafo completo [47]. O início do algoritmo se dá com a etapa de inicialização, na qual para cada amostra pertencente ao conjunto de treinamento, a floresta de caminhos ótimos P e o seu custo V são nulos. Logo após, para cada protótipo s atribui-se ao custo o valor zero e ao mapa de rótulos L atribui-se a classe deste protótipo, inserindo-o na fila de prioridades Q . Com a inicialização dos valores finalizada, o algoritmo prossegue analisando a fila de prioridades. Enquanto houver itens na fila há a remoção de uma amostra desta fila para análise. Para cada amostra do conjunto de treinamento calcula-se o custo para a amostra retirada da fila de prioridades. A amostra de treinamento que oferecer o menor custo também oferece o seu rótulo. Desta forma, as amostras do conjunto de treinamento classificam as amostras do conjunto de testes.

Algoritmo 4.2 - Floresta de Caminhos Ótimos por grafo completo

```

Para todo  $s \in Z_1$  faça
     $P(s) \leftarrow \text{nulo}$ 
     $V(s) \leftarrow +\infty$ 
Para todo  $s \in S$  faça
     $V(s) \leftarrow 0$ 
     $P(s) \leftarrow \text{nulo}$ 
     $L(s) = \lambda(s)$ 
    Insira  $s$  em  $Q$ 
Enquanto  $Q$  não for vazia faça
    Remova  $s$  de  $Q$  tal que  $V(s)$  é mínimo
    Para cada  $t \in Z_1$  tal que  $s \neq t$  e  $V(t) > V(s)$  faça
         $\text{custo} \leftarrow \max\{V(s), d(s,t)\}$ 
        Se  $\text{cust} < V(t)$  então
            Se  $V(t) \neq +\infty$  então
                Remova  $t$  de  $Q$ 
             $P(t) \leftarrow s$ 
             $L(t) \leftarrow L(s)$ 
             $V(t) \leftarrow \text{custo}$ 
            Insira  $t$  em  $Q$ 
Retorne  $\{V, P, L\}$ 

```

5 - RESULTADOS

Neste capítulo os resultados de segmentação e classificação obtidos são descritos. Estes resultados estão divididos em seções que mostram as comparações realizadas na estrutura como o modelo de cor, a quantização de cores, a quantidade de iterações do filtro de difusão anisotrópica, a aplicação em conjunto da transformada imagem-floresta com a morfologia matemática e o classificador de floresta de caminhos ótimos por grafo completo. O objetivo foi analisar estas modificações para encontrar o modelo ideal em cada fator. Sendo assim, um modelo proposto foi definido para estas técnicas na análise de imagens de lesão de pele. Este capítulo se encerra com as informações comparativas do modelo proposto em relação a outros trabalhos realizados na área.

5.1 – Comparação entre os modelos de cor

Neste trabalho foram implementados três modelos de cor distintos: RGB, YIQ e HSI. Como apresentado na seção (3.4), apenas o modelo RGB mantém a cromaticidade junto à luminosidade em seus canais de composição. Junto a este fator, as imagens de lesão de pele podem ser obtidas com variação de sombreamento, luminosidade ou ambos e, além disso, as lesões podem ser constituídas por tonalidades semelhantes à tonalidade da pele ou serem bem distintas. Baseando-se nestas interferências, a influência que estas características podem exercer na segmentação da lesão foi estudada neste trabalho. Na utilização dos modelos YIQ e HSI ocorre a equalização do histograma nos canais de luminosidade e, logo após, novamente

a conversão para o modelo RGB.

Primeiramente, nos casos em que há semelhança entre a tonalidade da lesão e a tonalidade da pele, os contornos foram melhores definidos no modelo RGB por causa da distribuição da luminosidade da imagem na equalização do histograma nos outros dois modelos de cor. Como a lesão geralmente possui tonalidade mais escura que a pele ocorre o escurecimento da imagem, ocasionando um aumento na probabilidade das partes próximas da fronteira serem agregadas à lesão, como apresentado na figura (5.1).

Na imagem mostrada na figura (5.1a), o contorno definido utilizando o modelo de cor RGB é muito mais preciso que os contornos definidos usando os modelos de cor YIQ e HSI, figuras (5.1b) e (5.1c), respectivamente. A lesão contida no contorno possui tonalidade muito parecida com a tonalidade da pele na sua região inferior. Esses contornos foram obtidos por meio das imagens resultantes na etapa de pré-processamento com a aplicação da quantização de cores com 8 intervalos e filtro de difusão anisotrópica com 100 iterações. As imagens exibidas em (5.1d), (5.1e) e (5.1f) são resultados da suavização descrita nos modelos RGB, YIQ e HSI, nesta ordem.




Figura 5.1: Semelhança na tonalidade entre a pele e a lesão: (a) contorno no modelo RGB; (b) contorno no modelo YIQ; (c) contorno no modelo HSI; (d) suavização em RGB; (e) suavização em YIQ; (f) suavização em HSI

Por outro lado, a tonalidade da lesão pode ser bem distinta da tonalidade da pele. Nestes casos, a definição do contorno da lesão é, na maioria das imagens, semelhante nos três modelos de cor. Mas, mesmo assim o modelo RGB se sobressai aos demais na precisão. Com isso, na figura (5.2), quatro imagens de lesão são exibidas. Na figura (5.2a) a imagem original é processada com quantização de cores com 8 intervalos e, em seguida, pelo filtro de difusão anisotrópica com 100 iterações. O contorno obtido quando a imagem permaneceu no modelo de cor RGB, figura (5.2b), é mais bem definido do que quando a imagem passou pela conversão e equalização nos modelos YIQ e HSI, exibidas nas figuras (5.2c) e (5.2d).




Figura 5.2: Diferença na tonalidade entre a pele e a lesão: (a) imagem original [19]; (b) sobreposição do fundo segmentado com o modelo RGB; (c) sobreposição do fundo segmentado com o modelo YIQ; (d) sobreposição do fundo segmentado com o modelo HSI

As imagens analisadas também podem possuir variações de luminosidade e/ou de sombreamento na lesão, na pele ou em ambas. Sendo assim, quando a luminosidade ou o sombreamento estão presentes na região de fronteira da lesão com a pele, na maioria dessas imagens, os contornos não são muito apropriados. Na figura (5.3a), o contorno é mais bem definido na região inferior e menos definido na parte superior da lesão, agregando partes da pele à lesão. Este fato ocorre devido à presença de maior luminosidade sobre a lesão na parte superior, tornando-a mais clara e semelhante na tonalidade aos *pixels* pertencentes à pele próximos da região de fronteira. Desta mesma forma acontece na figura (5.3b), na parte direita da lesão. Por outro lado, na figura (5.3c) há um sombreamento sobre toda a imagem, escurecendo a tonalidade da pele. Isso faz com que partes da lesão fiquem mais semelhantes à pele e no contorno definido não são agregados estes *pixels*. Estas imagens foram obtidas com o uso do filtro de difusão anisotrópica com 100 iterações precedido pela quantização de cores com 8 intervalos.




Figura 5.3: Influência da luminosidade e sombreamento na região de fronteira: (a) imagem com luminosidade; (b) imagem com luminosidade; (c) imagem com sombreamento

Apesar de a luminosidade não estar separada da cromaticidade no modelo RGB, há casos em que essa interferência não é tão crucial ao processo neste modelo de cor. Esta situação ocorre nos casos em que a luminosidade está em uma região, lesão ou pele, e está totalmente envolvida por ela. Na figura (5.4) são exibidas quatro lesões de pele que denotam esta situação. Nas imagens (5.4a) e (5.4b) a luminosidade está presente sobre uma parte específica da lesão, mas totalmente envolvida por ela. Nas imagens (5.4c) e (5.4d), a luminosidade está presente na pele e na lesão, mas a região de fronteira não está exposta a este fator, ficando intacta durante a segmentação. As imagens apresentadas na figura (5.4) também foram suavizadas utilizando quantização de cores com 8 intervalos e filtro de difusão anisotrópica com 100 iterações.




Figura 5.4: Luminosidade no modelo RGB: (a) na lesão; (b) na lesão; (c) na lesão e pele; (d) na lesão e pele

Assim como a luminosidade, o sombreamento não influencia a definição do contorno quando este não causa na pele um escurecimento ao ponto de deixá-la com

tonalidade próxima à da lesão. Nas imagens exibidas na figura (5.5), o sombreado existente sobre a pele não afetou a precisão do contorno da lesão, por causa da pele ainda permanecer com tonalidade bem distinta da tonalidade da lesão.




Figura 5.5: Sombreamento: (a) na parte esquerda e superior da imagem; (b) na parte direita e inferior da imagem; (c) na parte direita da imagem

Pelo fato de as lesões serem mais escuras que a pele na maioria dos casos, a luminosidade é mais fácil de ser tratada do que o sombreado nos modelos de cor. Sendo assim, quando há sombreado na imagem, a probabilidade dessa região ser acoplada à lesão é maior devido à semelhança dessas tonalidades no modelo RGB e por causa da distribuição homogênea das sombras por toda a imagem nos modelos YIQ e HSI. Este fato faz com que os valores dos *pixels* da pele fiquem mais próximos aos valores dos *pixels* da lesão, principalmente nas regiões de fronteira.

Adicionalmente, as lesões que possuem pápula mais elevada possuem maior probabilidade de terem luminosidade e sombreado por causa do ângulo da câmera no momento da aquisição da imagem. A luminosidade é maior nas lesões que possuem pápula com tonalidade predominantemente preta ou rosa devido ao reflexo, como mostrado na figura (5.4). E o sombreado, geralmente, estará presente no lado oposto ao da câmera, fazendo com que a própria pápula projete sua sombra na pele.

De forma geral, na metodologia proposta neste trabalho, no modelo de cor RGB foram alcançados os melhores resultados em todos os fluxos. A menor taxa de acerto para este modelo de cor foi com a utilização do filtro da média precedendo a quantização de cores com 8 intervalos. Neste conjunto de teste, a taxa de acerto ficou em 69,71%. Com o modelo de cor HSI, o conjunto que obteve o melhor resultado foi o que utilizou o filtro de difusão

anisotrópica com 100 iterações, precedido da quantização de cores com 8 intervalos, alcançando uma taxa de acerto de apenas 44,71%. O mesmo conjunto obteve uma taxa de acerto de 40,84% no modelo de cor YIQ. Portanto, o modelo de cor RGB sobressaiu-se aos modelos de cor YIQ e HSI em todas as combinações propostas para este banco de imagens.

Sendo assim, na tabela (5.1) são exibidas as taxas de acerto na definição dos contornos das lesões de pele dos três fluxos propostos para a etapa de pré-processamento utilizando quantização de cores com 8 intervalos e filtro de difusão anisotrópica com 100 iterações. A segmentação também se utilizou da aplicação da operação de fechamento da morfologia matemática antes da transformada imagem-floresta.

Tabela 5.1: Comparativo da taxa de acerto entre os modelos de cor RGB, YIQ e HSI utilizando quantização de cores com 8 intervalos antes do filtro de difusão anisotrópica com 100 iterações

Fluxo	RGB	YIQ	HSI
Somente Filtro	83,45%	38,38%	39,78%
Quantização + Filtro	95,42%	40,84%	44,71%
Filtro + Quantização	80,98%	38,02%	39,08%

Os resultados obtidos nos modelos de cor YIQ e HSI tiveram desempenho inferior ao modelo de cor RGB não devido somente à falha na segmentação da lesão, mas também por causa de muitos dos contornos obtidos serem considerados impróprios mesmo sendo próximos aos contornos ideais. O modelo HSI obteve levemente melhores resultados que o modelo YIQ nos três fluxos.

5.2 – Aplicação e omissão da quantização de cores e seus intervalos

A quantização de cores neste trabalho foi estudada nas imagens de lesão de pele em três modos: aplicação prévia em relação ao filtro escolhido, aplicação posterior ao filtro ou omissão desta técnica. Além disso, três definições de intervalos podem ser utilizadas, conforme descritas na subseção (4.2.2), agregando os *pixels* em 8, 16 ou 32 valores distintos

em cada componente do modelo de cor. Na tabela (5.2) são apresentadas as taxas de acerto na definição dos contornos das lesões com variação no momento de aplicação da quantização de cores com 8 intervalos e filtro de difusão anisotrópica com 100 iterações.

Tabela 5.2: Comparativo da taxa de acerto entre a omissão, aplicação prévia ou posterior da quantização de cores com 8 intervalos em relação ao filtro de difusão anisotrópica com 100 iterações

Modelagem Adotada	Omissão da Quantização	Aplicação Prévia da Quantização	Aplicação Posterior da Quantização
RGB e Filtro de Difusão Anisotrópica	83,45%	95,42%	80,98%
YIQ e Filtro de Difusão Anisotrópica	38,38%	40,84%	38,02%
HSI e Filtro de Difusão Anisotrópica	39,78%	44,71%	39,08%

Nos resultados obtidos é mostrado que a aplicação prévia da quantização de cores em relação ao filtro alcança melhor desempenho do que se aplicada após o filtro ou omitida, em qualquer modelo de cor estudado. Ainda analisando os dados da tabela (5.2), a omissão da quantização é mais eficiente do que a aplicação posterior, também em todos os modelos de cor. Na figura (5.6) são exibidas três imagens de uma mesma lesão de pele. A primeira imagem, figura (5.6a), foi suavizada com a aplicação prévia da quantização com 8 intervalos e, logo após, com o filtro de difusão anisotrópica com 100 iterações no modelo RGB. A lesão em (5.6b) teve a quantização omitida e seu contorno não foi muito bem definido devido a uma interferência na parte direita da lesão. E, na figura (5.6c), a suavização sofreu duas interferências quando a aplicação da quantização ocorreu após o filtro.




Figura 5.6: Quantização de cores: (a) aplicação prévia com 8 intervalos; (b) omissão; (c) aplicação posterior com 8 intervalos

Além do modo de aplicação da quantização de cores, as alterações no intervalo de agrupamento dos *pixels* também foram estudadas. O fluxo RGB, quantização de cores e filtro de difusão anisotrópica com 100 iterações foi escolhido como base para este teste por ter fornecido a melhor taxa de acertos para a suavização. Com isso, na tabela (5.3) são mostradas as taxas de acerto para a segmentação neste fluxo com alterações na definição do intervalo de agrupamento da quantização de cores.

Tabela 5.3: Comparativo da taxa de acerto entre os intervalos propostos para a quantização de cores no modelo RGB seguido de quantização e filtro de difusão anisotrópica com 100 iterações

Definição do Intervalo	Taxa de Acertos
Quantização com 32 intervalos	75,35%
Quantização com 16 intervalos	81,33%
Quantização com 8 intervalos	95,42%

Nos dados contidos na tabela (5.3) é comprovado que entre os três modos de agrupamento dos *pixels* definidos o que obteve o melhor resultado foi a quantização de cores com 8 intervalos. A quantização de cores é importante para reduzir a probabilidade de se ter a supersegmentação, mas quando ela é exercida com poucos intervalos os *pixels* próximos à região de fronteira tendem a agrupar-se e definir o contorno de forma errada. Este fato é mostrado com a quantização de cores com apenas 4 intervalos, na qual permite apenas 64 cores disponíveis, fazendo com que cores antes distintas sejam convertidas para um mesmo valor. Este tipo de agrupamento obteve o resultado mais inferior com apenas 57,04% na taxa de acerto dos contornos.

Nas figuras (5.7) e (5.8) são apresentadas uma mesma lesão de pele que foi suavizada pelo filtro de difusão anisotrópica com 100 iterações precedida pela quantização de cores no modelo RGB. A imagem quantizada por 8 intervalos é exibida na parte (a), por 16 intervalos na parte (b), por 32 intervalos na parte (c) e por 4 intervalos na parte (d). Ainda nessas figuras, as imagens em (e), (f), (g) e (h) mostram o contorno referente às imagens em (a), (b), (c) e (d), nesta ordem. Na figura (5.7) é possível observar que os contornos obtidos diferem muito entre si por causa da grande heterogeneidade nas cores que constituem a lesão. Por outro lado, na figura (5.8), os contornos são mais parecidos por causa da homogeneidade.




Figura 5.7: Heterogeneidade da lesão na diferenciação do intervalo na quantização: (a) suavização com 8 intervalos; (b) suavização com 16 intervalos; (c) suavização com 32 intervalos; (d) suavização com 4 intervalos; (e) contorno com 8 intervalos; (f) contorno com 16 intervalos; (g) contorno com 32 intervalos; (h) contorno com 4 intervalos




Figura 5.8: Homogeneidade da lesão na diferenciação do intervalo na quantização: (a) suavização com 8 intervalos; (b) suavização com 16 intervalos; (c) suavização com 32 intervalos; (d) suavização com 4 intervalos; (e) contorno com 8 intervalos; (f) contorno com 16 intervalos; (g) contorno com 32 intervalos; (h) contorno com 4 intervalos

As imagens e as taxas de acerto apresentadas nesta seção foram obtidas com a aplicação da operação de fechamento da morfologia matemática precedendo a transformada imagem-floresta logo após a suavização.

5.3 – Definição da quantidade de iterações no filtro de difusão anisotrópica

O filtro de difusão anisotrópica foi utilizado para suavizar as imagens de lesão de pele. Baseando-se nos valores definidos para os parâmetros e na equação de tempo ótimo de suavização, equação (3.40), este filtro foi projetado para executar 100 iterações em cada imagem. Por dados comparativos, além do filtro de difusão anisotrópica, o filtro da média e o filtro da mediana também foram implementados, conforme descrito na subseção (4.2.3).

Na tabela (5.4) são exibidas as taxas de acerto para cada fluxo estabelecido para a etapa de pré-processamento utilizando o modelo de cor RGB e morfologia matemática. Nesta tabela são mostrados os dados comparativos entre os três filtros disponíveis.

Tabela 5.4: Comparativo da taxa de acerto entre o filtro de difusão anisotrópica com 100 iterações, filtro da média e o filtro da mediana utilizando modelo de cor RGB e quantização de cores com 8 intervalos

Modelagem Adotada	Filtro de Difusão Anisotrópica	Filtro da Média	Filtro da Mediana
RGB + Filtro	83,45%	73,23%	74,29%
RGB + Filtro + Quantização	80,98%	69,71%	70,07%
RGB + Quantização + Filtro	95,42%	78,52%	71,12%

Analisando a tabela (5.4) verifica-se que no filtro da difusão anisotrópica são obtidos os melhores resultados nos três fluxos, sendo que o resultado menos eficiente deste filtro, quantização após a filtragem, é melhor do que todos os resultados do filtro da média e do filtro da mediana. Comparando somente os fluxos de execução entre o filtro da média e o filtro da mediana, na omissão da quantização e na aplicação posterior da quantização, o filtro da mediana se sobressai em relação ao filtro da média. Porém, o resultado mais eficiente entre

eles é a quantização precedendo o filtro da média com 78,52% na taxa de acerto.

Mesmo com a presença de pelos sobre a lesão, no filtro de difusão anisotrópica são alcançados resultados expressivos na definição dos contornos. Nas figuras em (5.9a), (5.9b) e (5.9c) são apresentadas três imagens que possuem a presença de pelos sobre a pele e sobre a lesão e, com a utilização do filtro de difusão anisotrópica com 100 iterações, obtiveram o contorno definido de modo aceitável. As mesmas lesões foram suavizadas no filtro da média e no filtro da mediana, mas apenas uma delas teve o contorno aceitável nos dois filtros, figuras (5.9d) e (5.9g). Essas imagens foram obtidas no modelo RGB com aplicação prévia da quantização de cores com 8 intervalos e operação de fechamento da morfologia matemática.




Figura 5.9: Definição de contornos com presença de pelos: (a) com filtro de difusão anisotrópica; (b) com filtro de difusão anisotrópica; (c) com filtro de difusão anisotrópica; (d) com filtro da média; (e) com filtro da média; (f) com filtro da média; (g) com filtro da mediana; (h) com filtro da mediana; (i) com filtro da mediana

Além da aplicação do filtro de difusão anisotrópica com 100 iterações fixas, neste trabalho foi proposta uma análise sobre a quantidade de iterações do filtro, comparando-se os *pixels* da imagem obtida na iteração atual com os *pixels* da imagem obtida na iteração anterior. O ponto de parada deste filtro consiste em obter uma imagem que não sofra mais alteração em relação à imagem anterior. No caso discreto em que se aplicou este processo, é aceitável uma margem de erro na diferença da intensidade dos *pixels* entre as imagens.

Na tabela (5.5) são mostrados os dados referentes à margem de erro na intensidade de três, cinco e sete dos *pixels* entre a imagem atual e sua imagem anterior. Quando a diferença é menor do que a margem de erro em todos os *pixels* da imagem, o filtro é interrompido. Para cada margem de erro é exibida a média de iterações necessárias com o total de imagens, a média de iterações somente com as imagens segmentadas com sucesso utilizando o filtro de difusão anisotrópica com 100 iterações, a taxa de acerto referente ao total de imagens e a taxa de acertos em relação somente às imagens segmentadas com sucesso quando o filtro foi executado com 100 iterações. Os valores dos parâmetros foram os mesmos da execução com iterações fixas.

Tabela 5.5: Definição da quantidade de iterações e taxa de acertos na utilização do filtro de difusão anisotrópica no modelo RGB precedido de quantização de cores com 8 intervalos e morfologia matemática

Filtro de Difusão Anisotrópica	100 iteraões	Diferença de intensidade		
		3	5	7
Média de iteraões com o total de imagens	100,00	86,81	76,28	58,12
Média de iteraões com imagens segmentadas	100,00	87,01	76,41	58,55
Taxa de acerto com o total de imagens	95,42%	88,73%	88,02%	82,39%
Taxa de acerto com imagens segmentadas	100,00%	92,98%	92,25%	86,34%

Os dados da tabela (5.5) são compostos da junção de todas as lesões (nevos não malignos, ceratoses seborréicas, lesões suspeitas e melanomas) pertencentes ao banco de imagens utilizadas neste trabalho. Baseando-se nestes dados, quanto maior a margem de erro na comparação da imagem atual com a imagem anterior menor é a quantidade de iteraões executadas no filtro e menor é a taxa de acerto na segmentação da lesão. Além desta constatação, verifica-se que a média de iteraões com o total de imagens e a média de iteraões somente com as imagens segmentadas são equivalentes. Ademais, a taxa de acerto

na segmentação para a margem de erro com diferença de intensidade de três e cinco nos *pixels* são praticamente iguais, diferenciando em aproximadamente dez iterações do filtro.

Na tabela (5.6) são exibidas as médias de iterações e o total de cada tipo de lesão segmentada de forma correta utilizando margem de erro na quantidade de iterações do filtro de difusão anisotrópica. Assim como na tabela (5.5), estes resultados foram obtidos com margem de erro de intensidade nos *pixels* para 3, 5 e 7.

Tabela 5.6: Definição da quantidade de iterações e total de acertos na utilização do filtro de difusão anisotrópica no modelo RGB precedido de quantização de cores com 8 intervalos e morfologia matemática por tipo de lesão

Filtro de Difusão Anisotrópica		100 iteraões	Diferença de intensidade		
			3	5	7
Nevos não Malignos (73 imagens)	Média de iteraões	100,00	88,92	83,37	66,32
	Total de Acertos	72	71	71	69
Ceratoses Seborréicas (33 imagens)	Média de iteraões	100,00	85,30	74,52	54,64
	Total de Acertos	31	29	29	29
Nevos Suspeitos (36 imagens)	Média de iteraões	100,00	93,36	86,28	73,00
	Total de Acertos	35	34	34	34
Melanomas (142 imagens)	Média de iteraões	100,00	84,41	70,51	50,94
	Total de Acertos	133	118	116	102

Analisando-se por categoria os dados da tabela (5.6), percebe-se que no grupo da ceratose seborréica e no grupo dos nevos suspeitos a quantidade de imagens segmentadas corretamente é a mesma utilizando-se todas as margens de erro testadas. Por outro lado, a maior diferença entre essas taxas ocorreu nas lesões do tipo melanoma. Outro fator é que as taxas de acerto mais baixas entre as execuções com margens de erro, considerando os quatro tipos de lesão testados, foram com a ceratose seborréica e com o melanoma. Essas lesões, de forma geral, apresentam maior heterogeneidade na tonalidade. Este fato faz com que o resultado geral da classificação com margem de erro decaia quando se comparado com a execução do filtro com 100 iteraões. Considerando somente os nevos não malignos e os nevos suspeitos, a taxa de acerto para a margem de erro com diferença de 3 na intensidade ficou em 96,33% e 90,38 iteraões em média. Com a execução de 100 iteraões a taxa de

acerto foi de 98,16%. Para a margem de erro com diferença de intensidade de 7, a taxa de acerto ficou em 94,49% com média de 68,52 iterações.

5.4 – Associação da morfologia matemática à transformada imagem-floresta

Na etapa de segmentação deste trabalho foi utilizada a operação de fechamento da morfologia matemática e a transformada imagem-floresta com estimativa de peso nos arcos. A morfologia matemática, como apresentado na figura (4.6), pode ser omitida no fluxo de execução ou preceder a transformada. Todos os resultados apresentados neste trabalho para o modelo de cor, quantização de cores e filtros, seções de (5.1) a (5.3), foram obtidos com a aplicação prévia da operação de fechamento da morfologia matemática e duas sementes na transformada imagem-floresta, uma para a região interna e outra para a região externa.

Na tabela (5.7) são apresentados os resultados referentes à utilização e omissão da operação de fechamento da morfologia matemática neste trabalho. As taxas de acerto exibidas foram calculadas com o uso do modelo de cor RGB e o filtro de difusão anisotrópica com 100 iterações precedido de quantização de cores com 8 intervalos. A aplicação da operação de fechamento trouxe um aumento na taxa de acerto na segmentação. Com a omissão da morfologia matemática, há um decréscimo de 22,89% na taxa de acerto.

Tabela 5.7: Taxa de acerto na segmentação referente à operação de fechamento da morfologia matemática no modelo RGB seguido de quantização de cores com 8 intervalos e filtro de difusão anisotrópica com 100 iterações

Operação de Fechamento da Morfologia Matemática	Taxa de Acerto
Com aplicação	95,42%
Com omissão	72,53%

Na figura (5.10) são exibidos quatro contornos definidos para duas lesões de pele. Nas partes (a) e (c) foi aplicado a operação fechamento da morfologia matemática antes da transformada imagem-floresta e nas partes (b) e (d) a morfologia matemática foi omitida no processo. Na primeira lesão, a operação de fechamento não teve interferência na segmentação, pois tanto na sua aplicação quanto na sua omissão, o contorno obtido é aceitável, figuras

(5.10a) e (5.10b). Por outro lado, a aplicação da morfologia foi necessária no caso da segunda lesão, pois não há fronteira definida em torno da lesão quando a morfologia matemática é omitida, imagem (5.10d).




Figura 5.10: Aplicação e omissão da operação de fechamento da morfologia matemática: (a) com aplicação; (b) com omissão; (c) com aplicação; (d) com omissão

Quando se utilizam apenas duas sementes para realizar a segmentação é necessário observar alguns aspectos da imagem. Se não houver sombreamento na região da semente externa, a marcação da semente interna deverá estar sobre o ponto mais claro da lesão, pois, desta forma, os *pixels* da lesão sendo mais escuros estarão mais próximos em termos de tonalidade da semente interna do que da semente externa. Neste caso, a exceção deste caso acontece quando a lesão possui regiões em cores bem claras, como presença de regiões brancas ou rosas. Caso haja algum tipo de luminosidade na lesão e esta região esteja envolvida com tonalidade mais escura da própria lesão, a marcação deve ser externa a essa região mais iluminada. Se a marcação se posicionar sobre a luminosidade, a probabilidade de a região ser agregada à pele é maior.

Nos nevus halos, a marcação da semente interna deve estar sobre a região do halo e não sobre a região do nevo em si. Isso acontece devido à causa da mais homogeneidade da tonalidade do halo com o fundo da pele do que com o nevo. Nos casos em que a semente estava posicionada no nevo, a região do halo passou a ser considerada como fundo da pele por ter mais similaridade com o fundo do que com a lesão. Com a marcação no halo, o nevo fica envolvido e, tanto o halo quanto o nevo, passam a ser segmentados juntos.

Na figura (5.11) são exibidas quatro lesões classificadas como nevus halos. Quando a marcação do nó semente interno ocorre sobre o nevo, o contorno definido

desconsidera a área do halo, figuras (5.11a) e (5.11b). E, quando a marcação é sobre o halo, as duas regiões se juntam para formar a lesão, como apresentado nas figuras (5.11c) e (5.11d).




Figura 5.11: Segmentação de nevos halos: (a) marcação no nevo; (b) marcação no nevo; (c) marcação no halo; (d) marcação no nevo

5.5 - Classificação das imagens por meio da floresta de caminhos ótimos

A classificação das lesões de pele neste trabalho foi realizada com a execução da floresta de caminhos ótimos com aprendizado supervisionado. Nesta técnica é necessária a definição do grafo que será utilizado, grafo completo ou grafo K-NN, e do percentual de imagens que irão compor o conjunto de treinamento. Desta forma, o grafo completo foi escolhido por apresentar melhores resultados. Na tabela (5.8) são exibidos os resultados da taxa de acerto na classificação por malignidade de lesões não malignas (nevos não malignos e ceratose seborréica), lesões suspeitas (nevos congênitos e nevos displásicos) e lesões malignas (melanomas) com a definição do percentual de imagens que formaram o conjunto de treinamento.

Tabela 5.8: Taxa de acerto na classificação das lesões de pele na floresta de caminhos ótimos

Conjunto de Treinamento	Taxa de Acerto
5%	57,91%
10%	63,26%
15%	57,75%
20%	54,58%

Com base nas informações da tabela (5.8) é evidenciado que a floresta de caminhos ótimos por grafo completo teve maior acerto quando o conjunto de treinamento foi formado por 10% das imagens, alcançando um desempenho de 63,26%.

As características utilizadas na classificação foram definidas de forma pontuais, ou seja, para cada conjunto de análise formado há uma diferenciação na escolha dos atributos. Os atributos foram testados em diversas combinações, primeiramente, dentro de seu próprio grupo (assimetria, borda, cor e estruturas diferenciais) e, logo após, de forma conjunta. Além disso, o porcentual de treinamento também foi modificado. Essas alterações foram aplicadas de modo a obter o melhor aproveitamento dos extratores de características implementados.

Nos dados apresentados na tabela (5.8), o melhor conjunto encontrado para o parâmetro da assimetria foi com 25% das imagens no conjunto de treinamento e uso de três características: desvio padrão de vinte e cinquenta retas e o proporcional da menor área. Neste agrupamento a taxa de acerto foi de 51,21%. Para a borda, o melhor resultado ocorreu com o uso de somente um valor, produto vetorial de pequenos vales. Este resultado foi de 45,87% com partição de 20% para o treinamento. Para a cor foi necessário 20% das imagens para a etapa de treinamento e o uso de cinco parâmetros, entre os quais a variância do canal R, os desvios padrão dos canais G e B, o desvio padrão em nível de cinza e a homogeneidade em cinza. Neste conjunto de características, a taxa de acerto na classificação foi de 53,21%. E na textura, a dimensão fractal do objeto e a média das dimensões das 16 regiões foram suficientes, com acerto em 47,80% do conjunto de teste formado por 75% das imagens.

Realizando as combinações entre os quatro parâmetros da Regra ABCD, somente as características pertencentes à textura não foram necessárias. No conjunto final utilizaram-se os desvios padrão de vinte e cinquenta retas da assimetria, as médias de pequenos vales e grandes retas entre o produto vetorial e o ponto de inflexão da borda e os desvios padrão das componentes G e B e a variância do canal R.

5.6 – Análise comparativa com outros trabalhos

Este trabalho também tem por objetivo comparar os resultados alcançados com outras metodologias desenvolvidas. Devido à falta de acesso aos bancos de imagens e

algoritmos utilizados nos outros trabalhos, esta comparação ocorreu somente em termos de números. Sendo assim, não foi possível testar a metodologia deste trabalho com as imagens das referências ou aplicar o banco de imagens deste trabalho nos algoritmos das referências.

Na tabela (5.9) são listadas três metodologias diferentes para a segmentação de lesões de pele. Com a aplicação de limiarização e *level set* [4], os contornos foram definidos como apropriados em 87,50% das imagens. Mantendo a utilização de *level set*, recentemente, em conjunto com *fuzzy c mean*, Masood e Al-Jumaily [76] conseguiram uma taxa de acerto de 92,66% nos contornos. No trabalho de Oliveira [15] utilizou-se o modelo Chan-Vese com binarização e alcançou-se 94,36% de contornos corretos. No modelo de segmentação aqui proposto, morfologia matemática com transformada imagem-floresta, foi obtida uma taxa de acerto de 95,42%, sobressaindo-se aos demais modelos citados. É importante ressaltar que a taxa de acerto foi obtida com a identificação de apenas uma semente para a região interna e outra para a região externa, pelo foco de minimizar a quantidade de sementes necessárias.

Tabela 5.9: Comparativo da segmentação do modelo proposto com outros trabalhos similares

Referência	Ano	Metodologia de Segmentação	Taxa de Acerto
Modelo Proposto	2016	Quantização de Cores, Filtro de Difusão Anisotrópica, Morfologia Matemática e Transformada Imagem-Floresta	95,42%
[4]	2014	Filtro Gaussiano, Morfologia Matemática, Limiarização e <i>Level Set</i>	87,50%
[76]	2013	<i>Fuzzy C Mean Thresholding</i> e <i>Level Set</i>	92,66%
[15]	2012	Filtro de Difusão Anisotrópica, Modelo Chan-Vese e Binarização	94,36%

Comparando-se as taxas de acerto por tipo de lesão, este modelo sobressaiu-se em relação ao trabalho de Oliveira [15] no nevo não maligno e na ceratose seborréica, porém a diferença entre esses percentuais foi pequena. No caso do nevo não maligno, este modelo teve um ganho de quase 2% na corretude do contorno. Nestas comparações, apenas o melanoma teve um resultado inferior, mas praticamente irrisório. O nevo suspeito não foi considerado no trabalho de Oliveira [15], entretanto, nesta metodologia a taxa de corretude das fronteiras deste tipo de lesão foi de 97,22%. Na tabela (5.10) essas informações são apresentadas.

Tabela 5.10: Comparativo da segmentação do modelo proposto com outro trabalho da área por tipo de lesão

Metodologia de Segmentação	Nevo Não Maligno	Ceratose Seborréica	Nevo Suspeito	Melanoma
Quantização de Cores, Filtro de Difusão Anisotrópica, Morfologia Matemática e Transformada Imagem-Floresta	98,63%	93,93%	97,22%	93,66%
Filtro de Difusão Anisotrópica, Chan-Vese, Binarização e Filtros Morfológicos [15]	96,77%	93,02%	*	94,23%

Na comparação da classificação das imagens por categoria, na tabela (5.11) são apresentados os resultados de três análises distintas considerando o grafo completo na floresta de caminhos ótimos: nevo não maligno com ceratose seborréica, nevo não maligno com melanoma e ceratose seborréica com melanoma.

Tabela 5.11: Comparativo da taxa de acerto da classificação do modelo proposto com outros trabalhos da área por categorias

Referência	Ano	Classificador	Nevo não maligno e ceratose	Nevo não maligno e melanoma	Ceratose e melanoma
Modelo Proposto	2016	Floresta de Caminhos Ótimos	79,51%	76,36%	85,10%
[77]	2015	Redes Neurais	*	81,25%	*
[78]	2014	KM <i>Clustering</i>	*	71,72%	*
[15]	2012	Máquina de Vetor de Suporte	79,01%	74,36%	74,33%

Entre os nevos não malignos e a ceratose seborréica, este modelo foi comparado com o trabalho de Oliveira [15], que alcançou 79,01% na taxa de acerto. No modelo proposto houve um ganho de apenas 0,5%, mas com diminuição na quantidade de características

utilizadas. No modelo proposto, a melhor combinação encontrada dos extratores foi com o produto vetorial e o ponto de inflexão de pequenas retas da borda, a média da componente G pertencente à cor e a energia de sete resoluções na textura com 20% das imagens formando o conjunto de treinamento. As características de assimetria se mostraram irrelevantes nesta análise.

A comparação entre os nevos não malignos e os melanomas ocorreu com outros três trabalhos. A metodologia empregada aqui utilizou somente os valores da variância RGB e em níveis de cinza com 20% das imagens formando o conjunto de treinamento, conseguindo acerto em 76,36% das imagens do conjunto de testes. A agregação dos valores de assimetria, borda e textura fizeram o resultado decair, assim como os outros dados de cor. O trabalho de Oliveira [15] alcançou 74,36% de acerto com o uso de 45 valores distintos e o trabalho de Celebi e Zornberg [78] obteve 71,72% de classificação correta. Em relação ao trabalho de Alsaeed e Reddy [77], a taxa de acerto foi 4,89% menor. Porém, neste trabalho foram utilizadas somente 72 imagens, ou seja, a quantidade de imagens consideradas foi de apenas 35,12% da quantidade do total deste trabalho.

O grande percentual de ganho foi na comparação entre ceratoses seborréicas e melanomas. Em relação ao trabalho de Oliveira [15], o ganho foi de quase 11% na taxa de acerto com o uso de apenas sete características e 15% das imagens formando o conjunto de treinamento. As características utilizadas da assimetria foram o menor proporcional da área e a maior razão na divisão da diagonal em 10 perpendiculares. Para a borda foi necessário o ponto de inflexão de pequenos picos e a média de pequenas retas entre o ponto de inflexão e o produto vetorial. Somente a variância do canal B da cor foi agregada ao conjunto de características. E por fim, da textura foi necessário o desvio padrão entre as 16 regiões obtidas e a décima primeira maior dimensão fractal.

Adicionalmente às comparações exibidas na tabela (5.11), neste trabalho também foram realizadas outras análises de classificação, como as que estão apresentadas na tabela (5.12). Com o uso do grafo completo na floresta de caminhos ótimos, nesta tabela são exibidos os dados referentes à classificação dos nevos suspeitos com os outros três tipos de lesões considerados neste trabalho: nevos não malignos, ceratoses seborréicas e melanomas.

Tabela 5.12: Taxa de acerto na classificação de outras categorias

Modelo	Taxa de Acerto
Nevos Suspeitos e Nevos Não Malignos	74,41%
Nevos Suspeitos e Ceratoses Seborréicas	79,41%
Nevos Suspeitos e Melanomas	83,52%

Na análise em conjunto dos nevos suspeitos com os nevos não malignos, a taxa de classificação correta ficou em 74,41%. Neste processo utilizaram-se somente quatro características e 20% das imagens formaram o conjunto de treinamento. As características consideradas foram o ponto de inflexão para grandes retas, a média de grandes picos e retas entre o ponto de inflexão e o produto vetorial e a diferença entre a maior dimensão fractal e a menor. Os valores da assimetria e da cor não foram necessários nesta análise.

Classificando os nevos suspeitos com as ceratoses seborréicas foram necessárias somente as informações de textura. Neste caso, a resolução de onze níveis de energia, a segunda e terceira maior dimensão fractal e a segunda menor dimensão fractal foram suficientes. Nesta comparação, a taxa de acerto foi de 79,41% com 50% das imagens no conjunto de treinamento.

E por fim, quando os nevos suspeitos foram analisados juntamente com os melanomas, a corretude na classificação das imagens ficou em 83,52%. Nesta comparação também foi necessário 50% das imagens formando o conjunto de treinamento e somente duas características de textura para a classificação: a dimensão fractal do objeto e a sétima maior dimensão obtida entre as regiões. Neste caso, o uso dos valores calculados para a assimetria, a borda e a cor fizeram diminuir a taxa de acerto.

6 - CONCLUSÕES

Neste trabalho foram propostos alguns estudos comparativos entre as técnicas utilizadas para a análise de imagens de lesão de pele. Entre esses estudos estão a comparação entre modelos de cor, modo de aplicação da quantização de cores, definição da quantidade de iterações do filtro de difusão anisotrópica e a aplicação em conjunto da morfologia matemática com a transformada imagem-floresta. Adicionalmente, os resultados obtidos na segmentação e na classificação das imagens foram comparados com outros trabalhos publicados na área. Neste capítulo é apresentado o modelo ideal entre as técnicas apresentadas e as conclusões finais a respeito dos resultados obtidos.

6.1 – O modelo ideal encontrado

Entre os três fluxos propostos para a etapa de pré-processamento, o fluxo que obteve maior precisão ocorreu quando a quantização de cores foi aplicada previamente ao filtro. Neste fluxo, a maior taxa de acerto ocorreu com o modelo de cor RGB, quantização de cores com oito intervalos e filtro de difusão anisotrópica com cem iterações. Dando continuidade ao processo, na segmentação a operação de fechamento da morfologia matemática se mostrou imprescindível no tratamento da imagem suavizada antes da transformada imagem-floresta. Na extração de características, para cada agrupamento de imagens foi definido um conjunto ideal de características para ser utilizado na etapa de

classificação com a floresta de caminhos ótimos por grafo completo.

Sendo assim, o modelo ideal proposto neste trabalho começa com a manutenção do modelo de cor RGB, aplicação da quantização de cores com oito intervalos, filtro de difusão anisotrópica com cem iterações, operação de fechamento da morfologia matemática, transformada imagem-floresta e floresta de caminhos ótimos por grafo completo.

6.2 - Análise dos resultados obtidos

Como apresentado no capítulo (5), o modelo ideal proporcionou uma taxa de 95,42% na corretude da definição do contorno. Este valor foi alcançado com o modelo de cor RGB, aplicação prévia da quantização de cores com oito intervalos, filtro de difusão anisotrópica com cem iterações, processamento da operação de fechamento da morfologia matemática e transformada imagem-floresta com estimativa de peso nos arcos com apenas duas sementes definidas, uma para a lesão e outra para a pele. A classificação das lesões de pele considerando o grau de malignidade obteve 63,26% de acerto com o uso de sete características extraídas e floresta de caminhos ótimos com grafo completo.

Em relação aos modelos de cor, mesmo aplicando a equalização no canal de luminosidade nos modelos YIQ e HSI, no modelo RGB se obteve os melhores resultados. Quanto à quantização de cores, a omissão desta técnica se sobressai à aplicação posterior ao filtro. Mas, mesmo assim, quando comparado com a aplicação prévia, a diferença nos resultados fica em quase 12%. Em relação aos intervalos definidos da quantização, percebe-se que quando se aumenta a quantidade de intervalos diminui-se a taxa de acerto. O mesmo ocorre quando a quantidade de intervalos é demasiadamente pequena. Neste caso, a quantidade de cores disponíveis faz com que regiões antes distintas sejam agrupadas em conjunto. Para a quantização de cores, a quantidade de oito intervalos foi definida como o valor ideal nesta metodologia.

Para o filtro de difusão anisotrópica foi proposta uma maneira alternativa de definir a quantidade de iterações. Observando as imagens analisadas, quando há homogeneidade nas imagens é possível aplicar o filtro de difusão anisotrópica com margem de erro de modo a alcançar resultados expressivos, diminuindo o tempo de execução. Porém,

quando a heterogeneidade é muito grande, a diminuição das iterações proporciona menos suavização nas imagens. Este fato é comprovado quando se analisa a corretude do contorno por tipo de lesão. É evidente que a taxa de acerto é menor entre os melanomas, nos quais a variedade de cores é maior do que nos outros tipos de lesão.

Com a etapa de pré-processamento finalizada, a segmentação dá continuidade ao processo. Nesta etapa do modelo proposto, a operação de morfologia se mostrou necessária para eliminar pelos e linhas que ainda permaneceram da etapa anterior. A possibilidade de se omitir esta técnica durante a segmentação proporcionou uma diminuição de quase 23% na precisão do contorno.

A diferenciação dos diversos conjuntos de características utilizadas na análise das imagens para a classificação fez com que a quantidade de valores necessários diminuísse. Sendo assim, a dificuldade desta etapa residiu em definir quais características seriam necessárias e quais seriam dispensáveis para cada tipo de análise. Nesta perspectiva ficou evidenciada a importância de alguns extratores e a irrelevância de outros. Quando todos os extratores são empregados em conjunto para todas as análises, os valores irrelevantes fazem com que a taxa de acerto seja diminuída. A diminuição na quantidade de características evidencia que a classificação pode ser realizada com menos processamento e maior velocidade de resposta. Neste ritmo, podemos usar o exemplo da classificação entre ceratoses seborréicas e melanomas em que se utilizaram somente sete valores e alcançou 85,10% de acerto, ou, o caso da análise das imagens entre nevos suspeitos e melanomas, cuja taxa de acerto ficou em 83,52% com apenas duas características.

Especificamente sobre os resultados alcançados, a metodologia proposta alcançou resultados expressivos em relação aos trabalhos comparados em todas as análises: nevos não malignos com ceratoses seborréicas, 79,51%, nevos não malignos com melanomas, 76,36% e ceratoses seborréicas com melanomas, 85,10%. Além desses resultados, foram apresentados resultados expressivos em comparações não encontradas em outros trabalhos da área como nevos suspeitos com nevos não malignos, 74,41%, nevos suspeitos com ceratoses seborréicas, 79,41% e nevos suspeitos com melanomas, 83,52%.

7 - TRABALHOS FUTUROS

Neste capítulo são descritas possíveis complementações ao trabalho realizado. Esses complementos indicam modificações, aprimoramento ou testes adicionais para que o estudo seja aprofundado e possua maior extensão e aplicabilidade. Para cada etapa constituinte do processamento de imagens empregado há uma seção inerente com detalhes.

Especificamente a respeito das imagens analisadas, neste trabalho elas são formadas por uma lesão no centro e com o fundo categorizando a região da pele. Portanto, as imagens com lesão descontínua não foram analisadas e este tipo de lesão é um dos fatores de aprimoramento. Outro aspecto relevante seria a análise das imagens de lesão de pele que contém ruídos impulsivos. Precisamente a respeito do câncer de pele, o estudo em imagens geradas por biopsias é um segmento de grande pertinência.

7.1 - Pré-processamento

Na etapa de pré-processamento é possível implementar outros modelos de cores existentes para a realização de testes, como o HSV e o HSL. Além deste fato, outra opção seria trabalhar com as componentes do modelo de cor de forma separada, ou seja, eliminando a necessidade do processamento com os três canais juntos.

Outro aspecto que tem uma grande relevância é a quantização de cores, na qual é permissível agregar uma maior diversidade de intervalos. Uma possibilidade de obtenção dos

intervalos se dá pelo fracionamento empregando valores diferentes da potência de dois, utilizado neste trabalho, mesmo que estes não sejam uniformes.

Além dos modelos de cores e da quantização de cores, o cálculo do desvio padrão de ruído no filtro de difusão anisotrópica para encontrar o tempo ótimo de suavização deve ser estudado a fim de ser definido de maneira mais precisa, pois permitirá maior eficiência na aplicação do filtro. Desta maneira, a quantidade de iterações será de acordo com a imagem selecionada e o tempo ótimo será equivalente à quantidade de ruído existente na imagem. Além do desvio padrão de ruído, os parâmetros da função gaussiana e suavização e a evolução temporal também precisam de uma definição matemática, o que proporcionaria maior desempenho e garantiria a eficiência do filtro para qualquer imagem analisada.

Ainda no filtro de difusão anisotrópica ficou evidenciada a necessidade de mais testes para o uso da proposta de diminuição da quantidade de iterações em imagens homogêneas, não somente com imagens de lesões de pele, mas também em outras aplicações.

Outra vertente do filtro de difusão anisotrópica poderia ser implementada para as imagens de lesão de pele. Na difusão anisotrópica robusta, métodos estatísticos são utilizados para encontrar a imagem sem o ruído gaussiano. Com essa vertente, os resultados seriam comparados com a implementação adotada neste trabalho.

7.2 - Segmentação

Neste trabalho utilizou-se a transformada imagem-floresta diferencial com política de desempate FIFO e relação de adjacência com quatro vizinhos. Diferentes implementações desta técnica poderão ser testadas juntamente às imagens de lesão de pele. Sendo assim, a política de desempate LIFO pode substituir a FIFO no mesmo algoritmo e, além disso, a relação de adjacência adotada poderia ser modificada. Outro aspecto é realizar testes do modelo proposto de segmentação com imagens de outros segmentos.

Ademais, diferentes versões da transformada imagem-floresta podem ser empregadas em imagens de lesão de pele como a transformada imagem-floresta orientada. Nesta versão, funções de custo de caminhos não suaves, baseadas em medidas de corte em

energia ou em pesos adaptativos, são utilizadas segundo outros critérios de otimalidade.

Adicionalmente, as imagens processadas pela transformada imagem-floresta diferencial e pela morfologia matemática neste estudo foram convertidas previamente em níveis de cinza. A implementação destes algoritmos para serem utilizados em qualquer modelo de cor pode trazer resultados expressivos.

7.3 - Extração de características

A regra ABCD foi utilizada aqui para realizar a extração de características das lesões de pele. Há diversas metodologias empregadas para extrair características de assimetria, borda, cor e textura. Estas outras metodologias podem ser implementadas para verificação e análise juntamente às demais técnicas aqui utilizadas.

A inclusão do parâmetro E na regra ABCD, denominando-se regra ABCDE, passou a considerar a evolução da lesão. Para considerar este fator é necessário fazer o acompanhamento da evolução da lesão, armazenando dados de cada análise efetuada e as comparações entre elas. É uma área de grande complexidade e que deve ser explorada.

Além do *box counting*, a dimensão fractal pode ser aplicada por outros métodos, como descrito na seção (3.7). Com isso, pode-se aplicar um estudo das técnicas de dimensão fractal na classificação das lesões de pele.

A extração de características pela regra ABCD proporciona resultados muito confiáveis, porém também é grande o interesse no desenvolvimento da aplicabilidade do método dos sete pontos. As sete características analisadas deste método ainda não possuem uma definição muito clara de execução. Entretanto, alguns trabalhos já utilizam esse método e um estudo mais aprofundado com esta técnica seria muito relevante.

7.4 - Classificação das imagens

Neste trabalho, na fase de classificação foi utilizado o aprendizado supervisionado por grafo completo da floresta de caminhos ótimos. Além dessa versão, outras vertentes desta técnica que podem ser acopladas a este trabalho é a versão com aprendizado supervisionado por grafo K-NN e a versão com aprendizado não supervisionado. Sendo assim, ter-se-ia um estudo mais abrangente sobre o desempenho da floresta de caminhos ótimos em relação ao conjunto das outras técnicas aplicadas e no tocante às imagens de lesão de pele.

REFERÊNCIAS

- [1] MINISTÉRIO DA SAÚDE DO BRASIL. Instituto Nacional de Câncer José Alencar Gomes da Silva, INCA. **Estimativa 2016: incidência de câncer no Brasil**. Rio de Janeiro, Brasil, 2015.
- [2] AUSTRALIAN GOVERNMENT. Australian Institute of Health and Welfare. **Cancer in Australia: an overview 2014**. Canberra, Austrália, 2014.
- [3] AMERICAN CANCER SOCIETY. **Cancer Facts & Figures 2016**. Atlanta, Estados Unidos, 2016.
- [4] MESSADI, M.; CHERIFI, H.; BESSAID, A. Segmentation and ABCD rule extraction for skin tumors classification. **Journal of Convergence Information Technology**, v.9, n.2, p.21-34, Mar 2014.
- [5] EL ABBADI, N. K.; MIRY, A. H. Automatic segmentation of skin lesions using histogram thresholding. **Journal of Computer Science**, v.4, n.10, p.632-639, Dez 2014.
- [6] RAZAZZADEH, N.; KHALILI, M. Automatic DWT2 thresholding based segmentation of the pigmented skin lesions in dermatoscopic imagens. **International Journal of Engineering & Technology**, v.4, n.3, p.529-534, Nov 2014.
- [7] JOHN, J. M.; SAMUEL, S. S.; JOHN, N. M. Segmentation of skin lesions from digital images using texture distinctiveness with neural network. **International Journal of Advanced Research in Computer and Communication Engineering**, v.3, n.6, p.7777-7780, Ago 2014.
- [8] SOOD, H.; SHUKLA, M. Segmentation of skin lesions from digital images using an optimized approach: genetic algorithm. **International Journal of Computer Science and Information Technologies**, v.5, n.5, p.6831-6837, Out 2014.
- [9] AL-ABAYECHI, A. A. A.; GUO, X.; TAN W.-H.; JALAB, H. A. Automatic skin lesion segmentation with optimal colour channel from dermoscopic images. **Science Asia**, v.40S, n.1, p.1-7, Fev 2014.

- [10] MASOOD, A.; AL-JUMAILY, A. SA-SVM based automated diagnostic system for skin cancer. In: **6th International Conference on Graphic and Image Processing**, Pequim, China, 2014.
- [11] R, S.; SUHIL, M.; GURU, D. S. Segmentation and classification of skin lesions for disease diagnosis. **Procedia Computer Science**, v.45, p.76-85, Mar 2015.
- [12] JENIVA, S.; SANTHI, C. An efficient skin lesion segmentation analysis using statistical texture distinctiveness. **International Journal of Advanced Research Trends in Engineering and Technology**, v.2, n.8, p.111-116, Fev 2015.
- [13] SHIMIZU, K.; IYATOMI, H.; CELEBI, M. E.; NORTON, K.-A.; TANAKA, M. Four-class classification of skin with task decomposition strategy. **IEEE Transactions on Biomedical Engineering**, v.62, n.1, p.274-283, Jan 2015.
- [14] RASTGOO, M.; GARCIA, R.; MOREL, O.; MARZANI, F. Automatic differentiation of melanoma from dysplastic nevi. **Computerized Medical Imaging and Graphics**, v.43, p.44-52, Fev 2015.
- [15] OLIVEIRA, R. B. **Método de detecção e classificação de lesões de pele em imagens digitais a partir do modelo Chan-Vese e máquina de vetor de suporte**. 2012. 136f. Dissertação (Mestrado) – Instituto de Biociências, Letras e Ciências Exatas, Universidade Estadual Paulista “Júlio de Mesquita Filho”, 2012.
- [16] 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. 154f. Tese (Doutorado), Universidade Federal do Rio Grande do Norte, 2008.
- [17] DERMATOLOGIA.NET. **Estética: melanose solar (“mancha senil”)**. Disponível em: <http://www.dermatologia.net/novo/base/estetica/melanose_solar.shtml>. Acesso em 2015.
- [18] DOUTOR FERNANDO FREITAS. **Cloasmas: como tratar as manchas que aparecem na gravidez**. Disponível em: <<http://www.drfernandofreitas.com.br/2013/03/cloasmas-como-tratar-as-manchas-que-aparecem-na-gravidez/>>. Acesso em 2015.
- [19] DERMIS. **Dermatology Information System**. Disponível em: <<http://www.dermis.net/dermisroot/en/home/index.htm>>. Acesso em 2016.

- [20] DERMATLAS. **DermAtlas**. Disponível em: <<http://dermatlas.med.jhmi.edu/derm/>>. Acesso em 2016.
- [21] REZZE, G. G.; DUPRAT, J. Nevo displásico (Nevo atípico). **Anais Brasileiros de Dermatologia**, v.85, n.6, p 863-871, Jun 2010.
- [22] ANTONIAZZI, R. L. **Processamento digital de fotografias a curta distância, na diferenciação quantitativa de manchas de pele**. 2010. 75f. Dissertação (Mestrado), Universidade Federal de Santa Maria, 2010.
- [23] JANKE FILHO, A. C. **Análise de imagens para detecção de lesões cutâneas através da regra ABCD**. 2012. 52f. Trabalho de Conclusão de Curso (Graduação), Universidade Regional de Blumenau, 2012.
- [24] DERMATOLOGY ATLAS. **Dermatology Atlas**. Disponível em: <<http://www.atlasdermatologico.com.br/browse.jsf>>. Acesso em 2016.
- [25] ROSADO, L. F. C. M. G. **Sistema automático para diagnóstico de lesões cutâneas baseado em imagens dermoscópicas**. 2009. 82f. Dissertação (Mestrado), Universidade Técnica de Lisboa, 2009.
- [26] DI LEO, G.; FABBROCINI, G.; LIGUORI, C.; PIETROSANTO, A.; SCLAVENZI, M. ELM image processing for melanocytic skin lesion diagnosis based on 7-point checklist a preliminary discussion. In: **13th Symposium on Measurements for Research and Industrial Applications**, Atenas, Grécia, 2004.
- [27] ZANOTTO, M. **Visual description of skin lesions**. 2010. 75f. Dissertação (Mestrado), University of Edinburgh, 2010.
- [28] SOBIERANSKI, A. C.; COSER, L.; COMUNELO, E.; WANGENHEIM, A. V. V. Metodologia computacional para aplicação da regra ABCD na avaliação de lesões pigmentadas. In: **VII Workshop de Informática Médica**, Porto de Galinhas, Brasil, 2007, p.67-76.
- [29] DA SILVA, J. F. **Sistema de armazenamento de imagens comprimidas através da transformada wavelet**. 2008. 100f. Dissertação (Mestrado) – Faculdade de Engenharia, Universidade Estadual Paulista “Júlio de Mesquita Filho”, 2008.

- [30] DE ALMEIDA, C. S. **Aplicação de medidas de rugosidade para a caracterização de imagens de microscopia**. 2013. 45f. Trabalho de Conclusão de Curso (Graduação), Universidade Estadual de Feira de Santana, 2013.
- [31] MARQUES FILHO, O.; VIEIRA NETO, H. **Processamento digital de imagens**. Rio de Janeiro: Editora Brasport, 1999.
- [32] GONZALEZ, R. C.; WOODS, R. E. **Processamento de imagens digitais**. Tradução Roberto Marcondes Cesar Júnior, Luciano da Fontoura Costa. São Paulo: Editora Edgard Blücher, 2000.
- [33] NEVES, S. R. **Algoritmos para segmentação de imagens infravermelhas**. 2003. 131f. Tese (Doutorado), Universidade Federal do Rio de Janeiro, 2003.
- [34] LEÃO, A. C. **Gerenciamento de cores para imagens digitais**. 2005. 135f. Dissertação (Mestrado), Universidade Federal de Minas Gerais, 2005.
- [35] DE ARAÚJO, A. F. **Método para extração e caracterização de lesões de pele usando difusão anisotrópica, crescimento de regiões, watersheds e contornos ativos**. 2010. 115f. Dissertação (Mestrado) – Instituto de Biociências, Letras e Ciências Exatas, Universidade Estadual Paulista “Júlio de Mesquita Filho”, 2010.
- [36] MIRANDA, J. I.; CAMARGO NETO, J. Detecção de bordas com o modelo de difusão anisotrópica. In: **Anais XIII Simpósio Brasileiro de Sensoriamento Remoto**, Florianópolis, Brasil, 2007, p.5957-5964.
- [37] SILVA JÚNIOR, E. C. **Um novo modelo de difusão não linear com preservação de bordas para segmentação e eliminação de ruídos em imagens e análise comparativa com modelos correlatos**. 2002. 107f. Dissertação (Mestrado) - Instituto de Biociências, Letras e Ciências Exatas, Universidade Estadual Paulista “Júlio de Mesquita Filho”, 2002.
- [38] BUHR, K. P. P. E. P. D. **Um estudo comparativo de implementações do filtro de difusão anisotrópico para unidades de processamento CPU e GPU**. 2010. 87f. Dissertação (Mestrado), Universidade do Vale do Itajaí, 2010.
- [39] WEICKERT, J. **Anisotropic diffusion in image processing**. Copenhagen, 2008.

- [40] PERONA, P.; MALIK, J. Scale-space and edge detection using anisotropic diffusion. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v.12, n.7, p.629-639, Jul 1990.
- [41] ALVAREZ, L.; LIONS, P.-L.; MOREL, J.-M. Image selective smoothing and edge detection by nonlinear diffusion. **Society for Industrial and Applied Mathematics**, v.29, n.3, p.845-866, Jun 1992.
- [42] NORDSTRÖM, K. N. Biased anisotropic diffusion: a unified regularization and diffusion approach to edge detection. **Proceedings of The First European Conference on Computer Vision**, p.18-27, Mai 1990.
- [43] 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, Jul 2003.
- [44] OLIVEIRA, R. B.; DE ARAÚJO, A. F.; TAVARES, J. M. R. S.; MARRANGHELLO, N.; ROSSETTI, R. B.; PEREIRA, A. S. Extração de contornos de lesões de pele utilizando difusão anisotrópica e modelos de contorno ativo sem borda. In: **10th World Congresso and Computacional Mechanics**, São Paulo, Brasil, 2012.
- [45] FALCÃO, A. X.; STOLFI, J.; LOTUFO, R. DE A. The image foresting transform: theory, algorithms and applications. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v.26, n.1, p.19-29, Jan 2004.
- [46] DIJKSTRA, E. W. A note on two problems in connexion with graphs. **Numerische Mathematik**, v.1, p.269-271, Jun 1959.
- [47] PAPA, J. P. **Classificação supervisionada de padrões utilizando floresta de caminhos ótimos**. 2008. 75f. Tese (Doutorado), Universidade Estadual de Campinas, 2008.
- [48] FALGUERA, J. R. **Reconhecimento semi-automático de sinus frontais para identificação humana forense baseada na transformada imagem-floresta e no contexto da forma**. 2008. 108f. Dissertação (Mestrado) – Instituto de Biociências, Letras e Ciências Exatas, Universidade Estadual Paulista “Júlio de Mesquita Filho”, 2008.
- [49] DE MIRANDA, P. A. V. **Segmentação de imagens pela transformada imagem-floresta**. 2006. 86f. Dissertação (Mestrado), Universidade Estadual de Campinas, 2006.

- [50] MANSILLA, L. A. C. **Transformada imagem-floresta com funções de conexidade não suaves: pesos adaptativos, polaridade de borda e restrições de forma**. 2014. 123f. Dissertação (Mestrado) – Instituto de Matemática e Estatística, Universidade de São Paulo, 2014.
- [51] FALCÃO, A. X.; BERGO, F. P. G. Interactive volume segmentation with differential image foresting transforms. **IEEE Transactions on Medical Imaging**, v.23, n.9, p.1100-1108, Set 2004.
- [52] BERGO, F. P. G. **Segmentação interativa de volumes baseada em regiões**. 2004. 98f. Dissertação (Mestrado), Universidade Estadual de Campinas, 2004.
- [53] SPINA, T. V.; DE MIRANDA, P. A. V.; FALCÃO, A. X. Intelligent understanding of user interaction in image segmentation. **International Journal of Pattern Recognition and Artificial Intelligence**, v.26, n.2, Ago 2012.
- [54] ROCHA, L. M.; FALCÃO, A. X.; MELONI, L. G. P. A robust extension of the mean shift algorithm using optimum path forest. In: **VIII International Workshop on Combinatorial Image Analysis**, Buffalo, Estados Unidos, 2008, p.29-38.
- [55] AFONSO, L. C. S. **Composição de dicionários visuais utilizando agrupamento de dados por floresta de caminhos ótimos**. 2013. 68f. Dissertação (Mestrado) – Instituto de Biociências, Letras e Ciências Exatas, Universidade Estadual Paulista “Júlio de Mesquita Filho”, 2013.
- [56] OSAKU, D. **Caracterização de impressões faciais termais utilizando a transformada imagem floresta**. 2011. 69f. Dissertação (Mestrado) – Instituto de Biociências, Letras e Ciências Exatas, Universidade Estadual Paulista “Júlio de Mesquita Filho”, 2011.
- [57] SHI, J.; MALIK, J. Normalized cuts and image segmentation. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v.22, n.8, p.888-905, Ago 2000.
- [58] DA SILVA, M. S. **Aglomerção de pixels pela transformada imagem floresta e sua aplicação em segmentação de fundo de imagens naturais**. 2011. 88f. Dissertação (Mestrado), Universidade Estadual de Campinas, 2011.

- [59] PAPA, J. P.; FALCÃO, A. X.; MIRANDA, P. A. V.; SUZUKI, C. T. N.; MASCARENHAS, N. D. A. Design of robust pattern classifiers on optimum-path forests. In: **8th International Symposium on Mathematical Morphology**, Rio de Janeiro, Brasil, 2007, p.337-348.
- [60] PAPA, J. P.; FALCÃO, A. X.; SUZUKI, C. T. N.; MASCARENHAS, N. D. A. A discrete approach for supervised pattern recognition. In: **12th International Workshop on Combinatorial Image Analysis**, Berlin/Heidelberg, Alemanha, 2008, p.136-147.
- [61] PAPA, J. P.; FALCÃO, A. X. A new variant of the optimum-path forest classifier. In: **4th International Symposium on Visual Computing**, Berlin, Alemanha, 2008, p.935-944.
- [62] MANDELBROT, B. B. **Fractals: form, chance and dimension**. W. H. Freeman and Company, San Francisco, Estados Unidos, 1977.
- [63] BACKES, A. R.; BRUNO, O. M. Técnicas de estimativa da dimensão fractal: um estudo comparativo. **INFOCOMP Journal of Computer Science**, v.4, n.3, p.50-58, Jul 2005.
- [64] FUZZO, R. A.; REZENDE, V.; DOS SANTOS, T. S. Fractais: algumas características e propriedades. In: **IV Encontro de Produção Científica e Tecnológica**, Campo Mourão, Brasil, 2009.
- [65] NUNES, R. S. R. **Geometria fractal e aplicações**. 2006. 78f. Dissertação (Mestrado) – Faculdade de Ciências, Universidade do Porto, 2006.
- [66] BACKES, A. R. **Implementação e comparação de métodos de estimativa da dimensão fractal e sua aplicação à análise e processamento de imagens**. 2006. 107f. Dissertação (Mestrado) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, 2006.
- [67] OPEN CV – **Open Source Computer Vision**. Disponível em: <<http://opencv.org/downloads.html>>. Acesso em 2016.
- [68] LOYOLA UNIVERSITY CHICAGO – Loyola University Dermatology Medical Education Website. **Dermatology Atlas – Alphabetized Index**. Disponível em: <<http://www.lumen.luc.edu/lumen/MedEd/medicine/dermatology/melton/atlas.htm>>. Acesso em 2016.
- [69] YSP DERMATOLOGY IMAGE DATABASE. **YSP Dermatology Image Database**. Disponível em: <<http://homepage1.nifty.com/ysh/indexe.htm>>. Acesso em 2016.

- [70] DERMOSCOPY ATLAS. **Dermoscopy Atlas**. Disponível em: <<http://www.dermoscopyatlas.com/index.cfm>>. Acesso em 2016.
- [71] MATH WORKS. **Math Works Documentation**. Disponível em: <<http://www.mathworks.com/help/matlab/ref/rgb2gray.html?searchHighlight=rgb2gray>>. Acesso em 2016.
- [72] CONCI, A.; AZEVEDO, E.; LETA, F. R. **Computação Gráfica – Teoria e Prática**. Rio de Janeiro: Editora Elsevier, v.2, 2008.
- [73] FALCÃO, A. X.; SPINA, T. V. **IFT DEMO - Biblioteca Image-Foresting Transform**. Disponível em: <<https://code.google.com/p/ift-demo/>>. Acesso em 2016.
- [74] GUIDO, R. C. A tutorial on signal energy and its applications. **Neurocomputing Elsevier**, v.179, p.264-282, 2016.
- [75] PAPA, J. P.; FALCÃO, A. X.; SUZUKI, C. T. N. **LIB OPF - Biblioteca Optimum Path Forest**. Disponível em: <<http://www.ic.unicamp.br/~afalcao/libopf/index.html>>. Acesso em 2016.
- [76] MASOOD, A.; AL-JUMAILY, A. A. Fuzzy C mean thresholding based level set for automated segmentation of skin lesions. **Journal of Signal and Information Processing**, n. 4, p. 66-71, 2013.
- [77] ALSAEED, M. N. F.; REDDY, E.S. Skin lesions detection by using multilevel wavelet transform. **International Journal of Inventions in Computer Science and Engineering**, v.2, n.5, p.1-11, Mai 2015.
- [78] CELEBI, M. E.; ZORNBERG, A. Automated quantification of clinically significant colors in dermoscopy images and its application to skin lesion classification. **IEEE Systems Journal**, v. 8, n. 3, p. 980-984, Set 2014.

APÊNDICE: Funções de visualização de imagens

Durante o desenvolvimento deste trabalho algumas funções foram implementadas somente com o objetivo de proporcionar a visualização das imagens e, assim, comprovar a correte funcional de alguns métodos da extração de características. Essas funcionalidades foram divididas em três categorias: sobreposição de imagens, desenho de marcações na imagem e análise de objeto.

Entre as funcionalidades de sobreposição de imagens foram desenvolvidos dois métodos: sobreposição do objeto segmentado e sobreposição do fundo segmentado. Na sobreposição do objeto segmentado há uma junção do fundo da imagem original com o objeto identificado na imagem segmentada. O contrário acontece na sobreposição do fundo segmentado, junção do objeto da imagem original com o fundo extraído na segmentação. Na imagem exibida em (APÊNDICE 1) é ilustrado o resultado destas sobreposições com o resultado destas duas funções em (c) e (d), respectivamente.




Figura APÊNDICE 1: Sobreposição de imagens: (a) imagem original em RGB [19]; (b) imagem obtida com a segmentação; (c) sobreposição do objeto segmentado; (d) sobreposição do fundo segmentado

O segundo grupo de funcionalidades, desenho de marcações na imagem, é utilizado para desenhar contornos, linhas ou preenchimento de cores em uma imagem. Sendo assim, cinco funções foram criadas: desenho da fronteira no objeto, desenho da maior diagonal no objeto, preenchimento das áreas particionadas no objeto, desenho das perpendiculares no objeto e desenho da grade do método *Box Counting*.

O desenho da fronteira constitui-se em uma linha branca traçada sobre a borda do objeto e a metodologia para encontrar a diagonal está descrita na subseção (4.4.1). Nestes dois métodos é demonstrado graficamente que a identificação dos pontos pertencentes à fronteira e à diagonal do objeto foi realizada de modo correto. No método que realiza o preenchimento do objeto em duas regiões distintas é comprovado que todos os *pixels* da região interna são considerados na análise das áreas durante a extração de características da assimetria. Um exemplo destas marcações é exibido na figura (APÊNDICE 2) com o contorno da fronteira, parte (b), com o traço da diagonal no objeto segmentado, parte (c), e com o preenchimento das áreas com cores diferentes representando a distinção entre as regiões separadas pela diagonal dentro do objeto segmentado, parte (d).




Figura APÊNDICE 2: Desenho das marcações em uma imagem: (a) imagem original em RGB [19]; (b) desenho da fronteira no objeto segmentado; (c) desenho da diagonal no objeto segmentado; (d) identificação das regiões separadas pela diagonal no objeto segmentado

O quarto método desta categoria trata a respeito do desenho das perpendiculares em relação à maior diagonal encontrada. As perpendiculares formam um ângulo de 90° com a diagonal e, por causa do tamanho desta diagonal, a distância entre as perpendiculares consideradas deve ser controlada. Esta metodologia está descrita na subseção (4.4.1). Na figura (APÊNDICE 3), após a identificação do contorno e da maior diagonal, representada na parte (b), as perpendiculares podem ser traçadas. Sendo assim, na parte (c) desta figura, há o traço de dez retas para a formação do primeiro vetor de características da assimetria. E, na parte (d), há o traço dos vinte segmentos que serão utilizados no segundo vetor da assimetria. O método desenvolvido pode ser executado com qualquer número desejado de perpendiculares, inclusive com valores não utilizados na extração de características.




Figura APÊNDICE 3: Desenho das perpendiculares no objeto: (a) imagem original em RGB [19]; (b) desenho da maior diagonal no objeto; (c) objeto segmentado com 10 perpendiculares; (d) objeto segmentado com 20 perpendiculares

O desenho da grade do método *Box Counting* é um método desenvolvido para visualizar a localização das linhas e colunas traçadas na divisão das regiões formadas para o cálculo da dimensão fractal. Conforme descrito na subseção (4.4.4), a imagem em níveis de cinza foi dividida em dezesseis regiões. Na figura (APÊNDICE 4c) são exibidas as dezesseis regiões formadas com a sobreposição da grade obtida no método *Box Counting*.




Figura APÊNDICE 4: Desenho da grade do método *Box Counting* de dimensão fractal: (a) imagem original em RGB [19]; (b) imagem convertida em níveis de cinza; (c) traço das linhas e colunas que identificam as 16 regiões para o cálculo da dimensão fractal

Para a categoria de análise do objeto foi desenvolvido um método para extrair a representação da assinatura do objeto, conforme ilustrado na figura (4.13b). A assinatura do contorno é utilizada pelo produto vetorial e pelo ponto de inflexão para calcular o grau de regularidade da borda do objeto segmentado, descrito na subseção (4.4.2).