

PONTÍFICA UNIVERSIDADE CATÓLICA DO PARANÁ
Arlete Teresinha Beuren

SEGMENTAÇÃO DO MELANOMA USANDO MORFOLOGIA
MATEMÁTICA EM COR

CURITIBA
2011

**SEGMENTAÇÃO DO MELANOMA USANDO MORFOLOGIA
MATEMÁTICA EM COR**

CURITIBA
2011

Arlete Teresinha Beuren

**SEGMENTAÇÃO DO MELANOMA USANDO MORFOLOGIA
MATEMÁTICA EM COR**

Dissertação de Mestrado apresentada ao Curso de Pós Graduação em Informática Aplicada da Pontifícia Universidade Católica do Paraná, Campus de Curitiba, como requisito para obtenção do título de Mestre em Informática Aplicada.

Área de concentração: *Visão, Imagem e Robótica.*

Orientador: Prof. Dr. Jacques Facon
Co-orientador: Prof. Dr. Alceu de Souza Britto Junior

CURITIBA
2011

Beuren, Arlete Teresinha
SEGMENTAÇÃO DO MELANOMA USANDO MORFOLOGIA MATEMÁTICA EM
COR. Curitiba, 2011. 76p.

Dissertação de Mestrado. Pontifícia Universidade Católica do Paraná. Programa de Pós-Graduação em Informática Aplicada.

1. Processamento de imagens 2. Melanoma 3. Modelos de Cores. 4. Morfologia Matemática em Cor. Pontifícia Universidade Católica do Paraná. Centro de Ciências Exatas e Tecnologia. Programa de Pós-Graduação em Informática Aplicada.

AGRADECIMENTOS

Agradeço primeiramente a Deus pelas oportunidades que me foram dadas na vida, principalmente por ter conhecido pessoas e lugares interessantes, mas também por ter vivido fases difíceis, que foram matérias-primas de aprendizado.

Agradecimento especial aos meus familiares, pelo apoio, e por terem me fornecido condições para me tornar a profissional que sou.

Aos colegas Rodrigo e Neusa, que forneceram bons momentos de discussão sobre o tema a ser abordado, e material de pesquisa.

Ao meu orientador Dr. Jacques Facon pelas boas conversas que tivemos e por não permitir que eu desistisse nas dificuldades encontradas.

A todos só posso dizer: Muito Obrigada!

Sumário

Sumário	2
Lista de Figuras	4
Lista de Tabelas	5
Resumo	6
Abstract	7
Capítulo 1	8
Introdução	8
1.1 Definição do Problema.....	10
1.1.1 O melanoma de pele	10
1.2 Objetivo.....	14
1.2.1 Geral	14
1.2.2 Específico.....	14
1.3 Proposta	15
1.4 Contribuições.....	16
1.5 Estrutura do Trabalho	16
Capítulo 2	17
Fundamentação Teórica	17
2.1 Espaços de Cores	17
2.1.1 Espaço de cor RGB – <i>Red, Green, Blue</i>	18
2.1.2 Espaço de cor HSI - <i>Hue, Saturation, Intensity</i>	19
2.2 Morfologia Matemática em Cor.....	21
2.2.1 Tipos de Ordenação	23
Conclusões sobre a Morfologia Matemática em Cor	28
2.3 Classificador Fuzzy CMeans (FCM)	28
2.4 Conceitos de Segmentação.....	30
2.4.1 Limiarização Global.....	31
2.4.2 Limiarização Adaptativa	32
2.4.3 Limiarização Multinível	33
Capítulo 3	34
Estado da Arte	34
3.1 Métodos de Segmentação de Melanoma	34
3.1.1 Estudo de Métodos de Análise por Cheng.....	34
3.1.2 Avaliação de Métodos de Segmentação por Silveira	36
3.1.3 Algoritmos de Segmentação por Ganster	43
3.1.4 Métodos para Classificação de Lesões por Maglogiannis.....	44

3.1.5 Análise do Histograma por Stanley et. al.	44
3.1.6 Modelo de Segmentação Baseado em MRF por Tran	45
3.1.7 Algoritmo de Segmentação Não-supervisionado por Mollersen.....	45
3.1.8 Combinação de Segmentação Fuzzy CMeans e Segmentação Fuzzy por Zhou	46
3.1.9 Segmentação Baseado no Conceito Six Sigma por Sethumadhav	47
3.1.10 Avaliação de Algoritmos por Alcón.....	49
Capítulo 4.....	50
Método Proposto, Experimentos e Resultados Alcançados	50
4.1 Formação da Base de Dados	51
4.2 Formação das Bases Ground-truth.....	52
4.3 Filtragem Morfológica por Cor	52
4.4 Segmentação por Limiarização	53
4.5 Filtragem Morfológica Binária	53
4.6 Avaliação da Abordagem Morfológica Proposta	55
4.6.1 Resultados com a Base de Imagens Benignas.....	56
4.6.2 Resultados com a Base de Imagens Malignas	57
4.7 Morfologia Matemática em Cor.....	59
4.8 Classificador não supervisionado Fuzzy C-Means	60
4.9 Análise da Avaliação da Abordagem Morfológica.....	61
4.10 Exemplos de segmentação do melanoma mal sucedidos por Abordagem Morfológica e por Abordagem Fuzzy CMeans.....	64
4.11 Ferramentas Utilizadas para os Experimentos	65
Conclusão	66
Referências	68

Lista de Figuras

Figura 1.1: Imagem de um Melanoma em fase inicial [GBM07].	9
Figura 1.2: Nevo benigno [GBM07].	12
Figura 1.3: Melanoma maligno [GBM07].	13
Figura 1.4: Melanoma maligno [GBM07].	13
Figura 2.1: Prisma [SOB03].	18
Figura 2.2: Cubo RGB [BRA00].	19
Figura 2.3: Espaço de cor HSI [GON92].	20
Figura 2.4: Elemento estruturante – (a) cruz, (b) quadrado, (c) hexagonal [BAN94].	22
Figura 2.5: (a) Imagem original de um melanoma assimétrico (a) [GBM07], Imagem A erodida (b); Imagem original de um melanoma com borda irregular (c), Imagem C erodida (d).	27
Figura 2.6: Imagem original de um melanoma assimétrico (a) [GBM07], Imagem A dilatada (b); Imagem original de um melanoma com borda irregular (c), Imagem C dilatada (d).	27
Figura 3.1: Evolução do potencial adaptativo durante o processo de convergência [SIL09].	37
Figura 3.2: Contorno inicial usando C-LS e EM-LS para duas imagens [SIL09].	38
Figura 3.3: Histograma na região da lesão [SIL09].	39
Figura 3.4: Lesão de melanoma [SIL09].	39
Figura 4.1 – Metodologia proposta.	50
Figura 4.2 – (a) imagem original e (b) exemplos de imagens <i>ground-truth</i> .	51
Figura 4.3 - Exemplos de filtragem em cor: (a) Imagem original; (b) Abertura com EE Quadrado 3x3, (c) Abertura com EE Quadrado 5x5, (d) Abertura com EE Quadrado 7x7.	53
Figura 4.4 - Resultados da abordagem: (a) Imagem original com borda da região segmentada (b) Binarização (c) Filtragem morfológica binária (d) Segmentação ideal (<i>ground-truth</i>).	54
Figura 4.5: (a) imagem de melanoma maligno [GBM07]. (b) filtragem lexicográfica ISH. Imagem (c) filtragem lexicográfica HSI.	55
Figura 4.6: Exemplos de segmentação manual: (a) Imagem original;	56
(b) segmentação manual da lesão; (c) Contorno sobreposto à imagem original.	56
Figura 4.7: Exemplo de imagem complexa eliminada devido à dificuldade em enxergar os limites da lesão.	57
Figura 4.8 - Exemplos de segmentação manual: (a) Imagem original;	58
(b) segmentação manual da lesão; (c) Contorno sobreposto à imagem original.	58
Figura 4.9: Exemplos de segmentação: (a) Imagem original; (b) Filtragem morfológica; (c) Segmentação da lesão; (d) Contorno sobreposto à imagem original.	59
Figura 4.10: Exemplos de segmentação: (a) Imagem original; (b) Filtragem com <i>Fuzzy CMeans</i> canal L e centros; (c) Segmentação da lesão.	61

Lista de Tabelas

Tabela 3.1 – Resultados dos Métodos de Segmentação [SIL09].....	42
Tabela 4.1: Avaliação da abordagem proposta a partir das doze métricas (em %).....	64
Tabela 4.2: Avaliação da abordagem <i>Fuzzy C-Means</i> a partir das doze métricas (em %)....	64

Resumo

A presente Dissertação de Mestrado consiste em apresentar uma abordagem de segmentação automática do melanoma usando a morfologia matemática em cor. Usando a ordenação lexicográfica no espaço de cor HSI mostra-se que é possível detectar a lesão de melanoma com precisão. A pesquisa contempla a formação de uma base de dados a ser usada de 300 imagens, sendo esta, dividida em dois grupos: benigno e maligno. Os testes obtidos com a segmentação automática foram comparados com a segmentação ideal das lesões através da aplicação de doze métricas. Os resultados mostraram os aspectos promissores desta abordagem no que diz respeito à segmentação automática do melanoma tanto benigno quanto maligno.

Palavras-Chave: Segmentação, Melanoma, Morfologia Matemática em Cor.

Abstract

This Master Thesis presents an approach for automatic segmentation of melanoma using color mathematical morphology. The use of the lexicographic order from HSI color space shows that it is possible to detect the melanoma lesions with precision. The research involves the formation of a database, which is divided into two groups: 150 images of benign and 150 images of malignant. The results obtained from the morphological segmentation were compared with the ideal segmentation of the lesions (ground-truth) through the use of twelve indicators. The results show the promising aspects of this approach with regard to the automatic segmentation of both benign and malignant melanoma.

Keywords: Segmentation, Melanoma, Mathematical Morphology.

Capítulo 1

Introdução

A atividade médica consiste na busca incansável por um diagnóstico preciso, sendo assim, a equipe médica tem ao seu alcance uma variedade muito grande de técnicas de geração de imagens relacionada a sua especialidade como, por exemplo, métodos radiológicos, micrografias, endoscopias, fotografias, entre outros. É muito importante a forma como uma imagem é processada, pois é a partir dela que um determinado caso pode ser diagnosticado a tempo para uma possível cura [ALM98].

Um grande desafio no campo científico nos últimos anos é o câncer de pele. O aumento de incidência de câncer de pele vem da exposição excessiva ao sol, principalmente em indivíduos com a pele clara que, além de provocar envelhecimento precoce pode causar lesões pré-malignas e malignas. Dentre os diversos tipos de cânceres de pele o melanoma, figura 1.1, é o menos comum e ao mesmo tempo o mais preocupante pela sua capacidade de disseminar-se a outras partes do corpo, mesmo quando a lesão ainda é pequena [GBM07].



Figura 1.1: Imagem de um Melanoma em fase inicial [GBM07].

Segundo os dados do Grupo Brasileiro de Melanoma [GBM07], nos Estados Unidos, em 1935, a chance estatística de um indivíduo de pele clara adquirir um melanoma durante toda a vida era de 1 para 1.500. Em 1991, esta chance subiu para 1 para 105, e a previsão para este ano, é de 1 para 75. Apesar do aumento da incidência, a mortalidade está baixando. Segundo o Grupo Brasileiro de Melanoma, como não houve um desenvolvimento significativo no tratamento do melanoma metastático (um tipo de melanoma mais invasivo), conclui-se que a diminuição da mortalidade está relacionada ao diagnóstico precoce da doença.

Para tanto, é possível definir uma abordagem para esse tipo de câncer de pele através de técnicas de processamento digital de imagens que possibilitará confiabilidade e agilidade no diagnóstico para os especialistas na área. Já que as áreas de aplicações de processamento digital de imagens requerem, cada vez mais, métodos capazes de realçar as informações contidas nas imagens para interpretação e análise humana [ALM98].

1.1 Definição do Problema

1.1.1 O melanoma de pele

Em 2006, a estimativa foi de 2710 novos casos em homens e 3050 novos casos em mulheres, segundo as Estimativas de Incidência de Câncer no Brasil [EST06]. Já em 2011, estima-se um aumento excessivo do número de casos de câncer sendo que as maiores taxas encontram-se na região Sul, principalmente em populações de pele clara.

Quando esse tipo de câncer é detectado em estágios iniciais há uma grande possibilidade de cura. De acordo com o Grupo Brasileiro de Melanoma [GBM07], nos últimos anos, houve uma grande melhora na sobrevida dos pacientes com melanoma, principalmente quando detectado nos estágios iniciais. Nos países desenvolvidos a sobrevida média estimada em cinco anos é de 73%, enquanto que, para os países em desenvolvimento, a sobrevida média é de 56%. A média mundial estimada é de 69%. Embora só represente 4% dos tipos de câncer de pele, o melanoma é o mais grave devido à sua alta possibilidade de metástase.

Segundo dados do Grupo Brasileiro de Melanoma [GBM07], o melanoma maligno representa cerca de 4% das neoplasias malignas de pele, o epitelioma epidermóide, cerca de 16%, restando ao epitelioma basocelular (neoplasia maligna localizada), a incidência de 80%. No Brasil, estima-se a incidência de quatro casos para cada 100.000 habitantes.

Segundo o Dr. Abdiel Figueira Lima¹, as recentes notícias envolvendo vacinas para esse tipo de câncer devem ser vistas como experimentais, não encontrando ainda respaldo na literatura nacional e internacional. Elas representam projetos de pesquisas necessitando assim, maior amadurecimento.

O lentigo (pintas ou manchas) maligno é mais comum em áreas expostas em pessoas idosas. Não se desenvolve a forma amelanocítica e é mais sensível a RDT (radioterapia). Já o melanoma lentiginoso acral aparece em áreas expostas e não expostas, em pessoas jovens e pode apresentar a forma amelanocítica [GBM07].

¹ Diretor-tesoureiro da Sociedade Brasileira de Dermatologia (SBD) e Ex-Presidente da SBD-RJ.

As “pintas” ou “sinais” são sinônimos de nevos² pigmentados [GBM07]. Nevos são um aumento no número de células na pele que podem ser pigmentadas ou não. Aparecem desde o nascimento (congenitos) ou durante a vida (adquiridos). Na maioria das vezes são benignos, pois não têm características de câncer. Algumas pintas e manchas (lentigos) são formadas por um acúmulo de células que, em alguma época da vida, podem sofrer transformação cancerígena. O câncer no qual elas podem se transformar é o melanoma.

A grande maioria das pintas aumenta de volume durante a vida. Isso não significa que elas irão transformar-se em melanoma. Por isso, é importante fazer um exame regular destas pintas consultando um dermatologista. Uma transformação maligna é indicada por alteração na cor, aumento do diâmetro ou irregularidade das bordas.

Dois tipos de nevos merecem atenção especial [GBM07], pelo seu maior risco de evolução para câncer de pele. São eles:

- Nevos Melanocíticos Congênitos Gigantes que são nevos pigmentados (melanocíticos), que nascem com o indivíduo (congenitos) e que têm um tamanho maior que 20 cm. Esses nevos podem ou não apresentar pêlos. Há de 5 a 10% de risco de desenvolvimento de melanoma, probabilidade bem maior que a do nevo melanocítico congênito pequeno.
- Nevos Atípicos são geralmente maiores que os nevos comuns (6 mm), podem ter bordas irregulares, limites imprecisos, várias tonalidades de marrom, castanho e vermelho. Localizam-se, freqüentemente, na parte superior do tronco, nos braços e coxas. Seu potencial de transformação para o melanoma pode ser de 10 à 15%.

As lesões benignas geralmente têm a forma arredondada ou oval com um contorno regular e cor uniforme. A figura 1.2 mostra um típico nevo benigno.

² Nevo vem do termo grego *nevus*, que significa defeito, é usado para designar as lesões pigmentadas da pele. Em português, o termo correto é “nevo” e significa “tumor benigno de células embrionárias”.



Figura 1.2: Nevo benigno [GBM07].

Os tumores cutâneos são acúmulos anormais de diferentes tipos de células [GBM07]. Quando o crescimento é controlado e as células não se disseminam para outras partes do corpo, os tumores cutâneos são benignos. Quando o crescimento é descontrolado e as células invadem o tecido normal e chegam mesmo a disseminar-se (produz metástases) a outras partes do corpo, os tumores são malignos.

O melanoma maligno é descrito como uma lesão grande e com diversas cores. Além disso, as bordas tendem a ser irregulares e assimétricas, como mostra a figura 1.3. A formação de uma lesão maligna geralmente começa com melanócitos danificados pela radiação ultravioleta [GBM07]. O desenvolvimento adiantado de melanócitos é geralmente estabilizado pelas defesas do organismo. Somente quando todas as defesas do organismo são atingidas, as células malignas se expandem e formam um câncer maligno que tende a proliferar.

Neste estágio, a lesão é muito difícil de ser detectada. Examinado com um microscópio é detectado um grupo de células com uma grande divisão celular. Durante um certo tempo, com o aumento desordenado, algumas células novas aparecem com formas anormais. Clinicamente, a lesão é chamada de nevo atípico³. O aumento de desordem genética é refletido pela variação de cor e forma irregular. A lesão geralmente é maior que 6 mm de diâmetro. Embora um nevo atípico possua marcas de melanoma, muitos permanecem clinicamente estáveis e nunca progridem a ponto de se tornarem melanomas. Porém, com muitas mutações de gene, alguns

³ Os nevos atípicos (molas displásicas) são tumores cutâneos escuros, achatados ou elevados, mas maiores que os nevos comuns (diâmetro maior que 1,5 cm) e não são necessariamente redondos.

nevos atípicos desenvolvem-se continuamente com células anormais. Neste estágio, a lesão é chamada de câncer *in-situ*, quando a lesão está completamente na epiderme. O melanoma *in-situ* é uma lesão plana que pode entrar em um período de crescimento horizontal. Esse tipo de melanoma não é um câncer invasivo em seu estágio inicial, o qual pode permanecer dessa forma indefinidamente [GBM07].



Figura 1.3: Melanoma maligno [GBM07].

O melanoma maligno nada mais é do que um tumor de etiologia desconhecida [GBM07]. Vários fatores estão relacionados, envolvendo genética, exposição ao sol e lesões traumáticas recidivantes. Estudos mais recentes têm encontrado a presença de partículas virais em alguns tumores. Entretanto, a importância maior é a exposição ao sol, pois aqueles que se expõem desde a infância têm maior chance na idade adulta de desenvolver o melanoma. Os nevos melanocíticos congênitos frequentemente estão relacionados ao desenvolvimento do melanoma, sobretudo nos pacientes mais jovens.



Figura 1.4: Melanoma maligno [GBM07].

Sinais ou manchas escuras que começam a adquirir características como mostra a figura 1.9 podem estar se transformando em um melanoma, principalmente se estiverem em áreas de exposição ao sol. A radiação ultravioleta do sol pode estimular a transformação de nevos pigmentados em melanomas. A proteção solar é a melhor forma de prevenir o surgimento do melanoma maligno.

Além disso, qualquer alteração em sinais antigos, como: mudança da cor para mais escuro ou mais claro, aumento de tamanho, sangramento, coceira, inflamação ou surgimento de áreas pigmentadas ao redor do sinal justifica uma consulta ao dermatologista para avaliação.

Outras formas de apresentação são o melanoma nodular primário [GBM07], que tem crescimento em profundidade mais rápido e o lentigo maligno melanoma, tumor plano que ocorre mais freqüentemente em pessoas acima de 60 anos de idade e aparece em áreas de grande exposição solar, principalmente a face.

O melanoma acral [GBM07] é uma forma de apresentação na qual a localização do tumor é nos pés ou nas mãos. Uma apresentação mais rara é o melanoma amelanótico, quando o tumor não tem a coloração escura, o que dificulta bastante o diagnóstico clínico.

1.2 Objetivo

1.2.1 Geral

O objetivo desse trabalho é desenvolver uma abordagem de segmentação automática do melanoma usando a morfologia matemática em cor com ordenação lexicográfica no espaço de cor HSI.

1.2.2 Específico

Os objetivos específicos desse trabalho contemplam:

- Formação de bases de imagens: criar duas bases de imagens de melanoma benigno e melanoma maligno, cada uma de 150 imagens.

- Geração de imagens *ground-truth*: definir para cada imagem das duas bases de imagens, a segmentação ideal da região da lesão.
- Filtragem: desenvolver ferramentas de filtragem da lesão do melanoma baseadas na morfologia matemática em cor usando a ordenação lexicográfica no espaço de cor HSI.
- Segmentação e extração das lesões: definir uma seqüência de processos permitindo enfatizar as cores da lesão do melanoma no sentido de realçar a sua geometria perante o fundo, respeitando o seu formato sem deformá-la e extraí-la de seu contexto.
- Avaliação da eficiência da abordagem: definir indicadores de qualidade da segmentação do melanoma e aplicá-los por comparação das imagens de melanoma benigno e maligno segmentadas automaticamente pela abordagem proposta com as imagens *ground-truth*.

1.3 Proposta

Obter-se-á as bases de imagem necessárias para o estudo através do site francês [TVI07] sobre o melanoma que descreve e apresenta diferentes tipos de lesões benignas e malignas, como também, através de contatos com dermatologistas fornecendo assim, imagens que completarão a base de imagens necessária.

Geração de imagens *ground-truth*: definir para cada imagem das duas bases de imagens, a segmentação ideal da região da lesão.

Com o uso da morfologia matemática em cor pode-se aprimorar o contraste entre o fundo e a lesão, aprimorar a nitidez da lesão, remover ruídos e separar a lesão do fundo.

A partir do uso da morfologia matemática em cor avaliar a eficiência da abordagem definindo indicadores de qualidade da segmentação do melanoma e aplicá-los por comparação das imagens de melanoma benigno e maligno segmentadas automaticamente pela abordagem proposta com as imagens *ground-truth*.

1.4 Contribuições

As contribuições da proposta anteriormente descrita referem-se principalmente ao processamento de imagens com modelos de cores diferentes como HSV, HSI, como também, o uso da morfologia matemática em cor para obter uma melhor nitidez da lesão, Remoção de ruídos, eliminação de fundo, etc., que é um aspecto bastante inovador.

As técnicas de limiarização de Reny e Otsu obtêm um resultado mais adequado a imagens de lesões de melanoma.

Conforme a estratégia usada nas publicações internacionais, as bases *ground-truth* são de suma importância para todas as pesquisas e/ou ser disponibilizadas para outros pesquisadores. O termo “base *ground-truth*” significa neste contexto gerar a solução ideal da segmentação da lesão da região do melanoma para todas as imagens usadas nos testes de treino e validação.

1.5 Estrutura do Trabalho

A presente dissertação de mestrado estrutura-se da seguinte forma: o capítulo 2 apresenta a fundamentação teórica, no capítulo 3 é apresentado o estado da arte, o capítulo 4 apresenta a metodologia proposta para a pesquisa, o protocolo experimental e os resultados obtidos.

Capítulo 2

Fundamentação Teórica

Este capítulo apresenta os modelos de cores relacionados ao processamento digital de imagens, a morfologia matemática em cor e segmentação de imagens, como também, o classificador *Fuzzy C-Means*.

2.1 Espaços de Cores

Esta seção explica os conceitos de alguns espaços de cores que podem ser utilizados no estudo de regularidade e de forma para identificação de lesões do melanoma. Espaços de cores são entendidos como modelos que representam as cores de diferentes maneiras.

No processamento de imagens coloridas a cor é um poderoso descritor que simplifica a identificação e extração de objetos de uma cena. Milhares de cores podem ser identificados aos olhos humanos, mas apenas duas dezenas de tonalidades de cinza. O processamento de imagens coloridas divide-se em duas áreas. A primeira, denominada cor completa em que as imagens são adquiridas por sensores que produzem imagens coloridas e a segunda denominada pseudo-cor onde os níveis de cinza de uma imagem são convertidos em cores para posterior processamento ou visualização [SOB03].

Uma experiência simples com um prisma, como mostra a figura 2.1, pode demonstrar que a luz branca é obtida pela combinação de luzes de cores diferentes.



Figura 2.1: Prisma [SOB03].

Existem três quantidades básicas que são utilizadas para descrever a qualidade de uma fonte de luz cromática [SOB03]:

- Radiância: quantidade de energia que flui da fonte de luz (medida em Watts).
- Luminância: quantidade de energia que um observador percebe (medida em lúmens). Raios infravermelhos podem possuir alta radiância, mas baixa luminância.
- Brilho: noção acromática de intensidade da luz.

Ao olho humano, os bastonetes percebem intensidade e os cones, por sua vez, percebem cor e ocorrem nas seguintes proporções: 65% são sensíveis à luz vermelha; 33% são sensíveis à luz verde e 2% sensíveis à luz azul. Por essa característica do olho humano, as cores são vistas como combinações das cores primárias R (red), G (green) e B (blue).

2.1.1 Espaço de cor RGB – *Red, Green, Blue*

O espaço de cor RGB é um dos espaços de cores mais utilizados no processamento e armazenamento de dados digitais de imagens [BRA00]. Ele é formado por três cores primárias (vermelho, verde e azul). Como muitos objetos do mundo real possuem essas três cores misturadas o percentual significativo de não-uniformidade e a mistura dos dados de crominância e luminância fazem do RGB (figura 2.1) uma escolha não muito favorável para análise de cores e algoritmos baseados em reconhecimento de cores.




Figura 2.2: Cubo RGB [BRA00].

2.1.2 Espaço de cor HSI - *Hue, Saturation, Intensity*

O modo clássico para obter imagens coloridas é usando a representação RGB. Porém, esse tipo de representação possui algumas desvantagens, já que os componentes RGB são altamente correlatos e então, não é ajustada alguma informação cromática diretamente para o uso [GON92].

O modelo HSI é muito usado na manipulação de cores em processamento de imagens. Através do sistema de representação de cor HSI (matiz, saturação e intensidade) é possível obter os valores para o matiz, saturação e intensidade separadamente. Enquanto o matiz H representa a cor dominante percebida por um observador (vermelha, verde, azul), a saturação S está relacionada com a pureza, o quanto a cor (H) é diluída pela luz branca e a intensidade I é a representação de intensidade de luz (brilho presentes na cor). Cores puras do espectro são completamente saturadas. O modelo HSI traz dois aspectos principais: A componente I é não acoplada com a informação de cor (matiz e saturação), ainda, as componentes de matiz e saturação estão intimamente relacionadas com a percepção humana de cor [GON92].

No modelo HSI as componentes são definidas em um triângulo de cor como mostrado na Figura 2.3.b. A componente H do ponto de cor P é o ângulo do vetor mostrado com relação ao eixo de vermelho. Assim, se este ângulo é nulo, tem-se vermelho, se for 60° tem-se amarelo. A componente S é proporcional à distância de P ao centro do triângulo. Quanto mais distante do centro, mais saturada é a cor. A

componente I é medida por uma linha passando perpendicularmente pelo centro do triângulo, veja-se Figura 2.3.a e b.




Figura 2.3: Espaço de cor HSI [GON92].

Em [GON92] são deduzidas as equações para a conversão de cores entre os espaços RGB e HSI. Assumindo que os valores de R, G e B são normalizados na faixa [0, 1], a conversão do modelo RGB para HSI segue a seguinte equação:

$$\theta = \arccos \left\{ \frac{\frac{1}{2}[(R-G) + (R-B)]}{[(R-G) + (R-B)(G-B)]^{1/2}} \right\}$$

$$H = \begin{cases} \theta \rightarrow se B \leq G \\ 360^\circ - \theta \rightarrow se B > G \end{cases} \quad (2.1)$$

$$S = 1 - \frac{3}{R+G+B} [\min(R, G, B)]$$

$$I = \frac{R+G+B}{3}$$

Quando os valores de R = G = B qualquer valor de H pode ser assumido. Uma possível solução nesse caso é verificar a vizinhança do ponto para estimar um valor adequado. Abaixo é apresentada a equação de HSI para RGB.

$$I = \frac{R+G+B}{3 \times 255} \quad (2.2)$$

$$S = 1 - \frac{3}{(R+G+B)} \text{Min}(R, G, B)$$

$$H = \arctan\left(\sqrt{\frac{255x(R-G)(R-B)}{(R-G)^2 + (R-G)(G-B)}}\right)$$

2.2 Morfologia Matemática em Cor

O princípio básico da morfologia matemática quer que seja binária, ou em níveis de cinza ou ainda em cor, consiste em extrair informações relativas à geometria e à topologia do conteúdo de uma imagem. A morfologia matemática quantifica a intuição do pesquisador, analisando as estruturas geométricas da imagem a partir de um conjunto perfeitamente definido e conhecido (forma e tamanho) chamado de: “*Elemento Estruturante*”. O resultado dessa transformação permite gerar novas imagens e avaliar o conteúdo das mesmas [FAC96].

A morfologia matemática disponibiliza uma grande gama de operadores de filtragem, segmentação, detecção de bordas, esqueletização, afinamento, análise de formas, compressão, etc. [FAC96].

A morfologia matemática, originalmente desenvolvida para imagens binárias em meados dos anos 60, foi estendida para imagens em níveis de cinza. E as pesquisas atuais se concentram em imagens coloridas [FAC96].

Os pilares da morfologia matemática são duas operações básicas, a *erosão* e a *dilatação*, a partir das quais, por composição, é possível realizar muitos outros operadores poderosos [FAC96].

A erosão em níveis de cinza pode ser definida através de um sinal f por um elemento estruturante g [FAC96].

$$\in^s (f(x)) = \text{Min}\{f(x) - g(x - y) : y \in E\} \quad 2.3$$

Sendo que Min e E representam respectivamente o mínimo entre valores e o domínio do elemento estruturante. O operador Min pode ser ainda representado pelo operador “^”.

A erosão é uma transformação não comutativa apresentando várias propriedades interessantes como [FAC96]:

- Diminuir as partículas;
- Eliminar conjuntos de tonalidade clara de tamanho inferior ao tamanho do elemento estruturante;
- Aumentar os buracos;
- Separar conjuntos próximos.

A dilatação em níveis de cinza pode ser definida através de um sinal f por um elemento estruturante g [FAC96].

$$\delta^g(f(x)) = \text{Max}\{f(y) + g(x - y) : y \in E\} \quad 2.4$$

Sendo que Max e E representam respectivamente o máximo entre valores e o domínio do elemento estruturante. O operador Max pode ser ainda representado pelo operador “V”.

A dilatação é uma transformação comutativa, cujos efeitos interessantes são [FAC96]:

- Engordar partículas;
- Eliminar conjuntos de tonalidade escura de tamanho inferior ao tamanho do elemento estruturante;
- Preencher pequenos buracos;
- Conectar conjuntos próximos.

Os operadores de Morfologia matemática apóiam-se no uso de elementos estruturantes [BAN94], os quais são caracterizados como conjuntos definidos e conhecidos (forma e tamanho), que são comparados ao conjunto desconhecido da imagem. Alguns exemplos de elementos estruturantes (3x3), com origem no centro do elemento são apresentados abaixo através da figura 2.4:




Figura 2.4: Elemento estruturante – (a) cruz, (b) quadrado, (c) hexagonal [BAN94].

Recentemente foram estudados e propostos operadores de morfologia para imagens coloridas. Infelizmente, foi demonstrado que a extensão dos conceitos da morfologia em níveis de cinza para imagens coloridas não é direta e nem fácil [LOU01]. Na morfologia em níveis de cinza apresentada anteriormente, os operadores baseiam-se nos conceitos de mínimo e máximo de níveis de cinza. Conceitos que não apresentam nenhuma dificuldade teórica e/ou matemática. Por exemplo, procurar o mínimo ou o máximo entre dois níveis de cinza, 100 e 110 não apresenta nenhuma dificuldade computacional.

Mas como definir o mínimo ou o máximo entre, por exemplo, a cor verde e a cor azul? Uma alternativa, de modo a abordar o problema da morfologia em cor é tratar as cores dos pixels como vetores e ordená-los. A morfologia matemática em cores apresenta, portanto dois desafios principais, a escolha da ordenação e a escolha do espaço de cor.

A morfologia matemática em cores apresenta muitos desafios, o principal sendo a escolha do espaço de cor e da ordenação. Existem vários tipos de ordenação, reduzida, marginal e lexicográfica. Segundo [TOB07], quando a ordenação do tipo total ordenação lexicográfica é utilizada, o aparecimento de falsas cores após o processamento é evitado.

2.2.1 Tipos de Ordenação

Existem vários tipos de ordenação, marginal, reduzida, parcial, condicional e lexicográfica. Estas técnicas são geralmente classificadas em [PLA00]:

- ordenação marginal (M-ordenação), em que as amostras multivariadas são ordenadas de acordo com cada dimensão de forma independente;
- ordenação reduzida (R-ordenação), em que cada observação multivariada é reduzida a um valor escalar de acordo com uma métrica de distância;
- ordenação parcial (P-ordenação), sendo que os dados de entrada são divididos em grupos menores que são então ordenados;
- ordenação condicional (C-ordenação), sendo que as amostras são ordenadas em um de seus conjuntos marginais de observações;
- Ordenação lexicográfica, em que a ordem baseia-se no produto cartesiano das amostras multivariadas.

2.2.1.1 Ordenação lexicográfica

Segundo [TOB07], quando a ordenação do tipo total ordenação lexicográfica é utilizada, o aparecimento de falsas cores após o processamento é evitado.

Dado um espaço de cor C representado por três canais $C \subset \mathfrak{R}^3$ uma ordenação lexicográfica consiste basicamente em definir uma ordem para o processamento de cada pixel. Seja um pixel $P(x_1, y_1, z_1)$ de coordenadas x_1, y_1, z_1 e um pixel vizinho $P_{vizinho}(x_2, y_2, z_2)$ de coordenadas (x_2, y_2, z_2) . A seguir a equação 2.9 apresenta a ordenação geral proposta por [TOB07] no caso da busca do mínimo entre duas cores entre $P(x_1, y_1, z_1)$ e $P_{vizinho}(x_2, y_2, z_2)$.

$$P(x_1, y_1, z_1) < P_{vizinho}(x_2, y_2, z_2) \Leftrightarrow \begin{cases} x_1 < x_2 \\ \text{ou} \\ y_1 < y_2 \text{ caso } x_1 = x_2 \\ \text{ou} \\ z_1 < z_2 \text{ caso } y_1 = y_2 \text{ e caso } x_1 = x_2 \end{cases} \quad 2.5$$

a) Espaço de cor na ordenação lexicográfica

Além da forma de ordenar cores, o modelo de cor adotado para o processamento também é importante, uma vez que imagens coloridas podem ser representadas por vários modelos de cores [TRA92]. O modelo mais comum é o RGB (vermelho, verde, azul). Entretanto, é aconselhável usar os modelos HSI ou HSV ou HLS, uma vez que estes modelos se aproximam da interpretação humana de cores. Os três componentes destes modelos de cores são: matiz (ou cor), saturação e intensidade (ou brilho). Destes, a intensidade é o melhor atributo para o processamento de imagens coloridas.

O estudo realizado por Ortiz *et al.* [ORT02], para a análise de imagens neurais utilizando Morfologia Matemática em Cor, foi baseado no modelo de cor HSV (matiz, saturação, valor).

Devido à forma específica do modelo de cor HSI, surge um problema com o método de ordenação lexicográfico. A saturação e a intensidade são conjuntos totalmente ordenáveis, mas o matiz não é. O matiz é um ângulo de valor $H(X,Y) \in [0,2\pi]$. Além disso, não é possível ordenar cores de valores mais baixos para valores mais altos, uma vez que não faz sentido dizer que o azul é maior ou menor que o vermelho. Para solucionar este problema, Hanbury [HAN01] e Peters [PET97] ordenaram as cores usando uma função da estrutura do valor da cor. As cores são ordenadas de acordo com o valor absoluto da função distância (Equação 2.10) entre a cor da imagem (H_i) e uma cor de referência (H_{ref}). A cor de referência é o ângulo da cor que se deseja destacar na imagem, ou seja, se o usuário está procurando objetos vermelhos na imagem, deve-se passar o ângulo 0° . Para isso, é necessário que usuário conheça o espectro de cores, sabendo qual o ângulo da cor que quer destacar.

$$d(H_i, H_{ref}) = \begin{cases} |H_i - H_{ref}| & \text{if } |H_i - H_{ref}| \leq \pi \\ 2\pi - |H_i - H_{ref}| & \text{if } |H_i - H_{ref}| > \pi \end{cases} \quad (2.6)$$

A ordenação lexicográfica com HSV proposta por Ortiz *et al* [ORT02], inicia pelo matiz (H), seguida pelo valor (V) e então pela saturação (S). Para uma imagem f e dois vetores de pixels $f(x_i, y_i) = P_i$ e $f(x_j, y_j) = P_j$, sendo que o índice i denota o pixel central e o índice j denota a vizinhança do pixel central, tem-se:

$$P_i < P_j \Rightarrow Se \begin{cases} d(H_i, H_{ref}) < d(H_j, H_{ref}) \\ d(H_i, H_{ref}) = d(H_j, H_{ref}) e V_i < V_j \\ d(H_i, H_{ref}) = d(H_j, H_{ref}) e V_i = V_j e \\ S_i < S_j \end{cases} \quad (2.7)$$

Com isto, foram definidas as operações morfológicas básicas (erosão ε_v e dilatação δ_v) usando a ordenação O_{lex} .

Assim, a erosão em cor é definida como a seleção do valor da cor da imagem com menor distância absoluta (diferença de cor), ou seja, a erosão de uma imagem f por um elemento estruturante K é definida como:

$$\varepsilon_{\nu}k(f)(x, y) = \min_{O_{lex}} f(x+s, y+t)(s, t) \in k \quad (2.8)$$

É importante ressaltar que o elemento estruturante, utilizado em todas operações morfológicas implementadas, é do tipo quadrado, de tamanho 3×3.

A dilatação em cor é definida como a seleção do valor da cor da imagem com maior distância absoluta, ou seja, a dilatação de uma imagem f por um elemento estruturante K é definida como:

$$\delta_{\nu K}(f)(x, y) = \max_{O_{lex}} f(x-s, y-t)(s, t) \in k \quad (2.9)$$

A nova definição de mínimo e máximo é importante, pois são operações vetoriais. Eles são calculados pela equação abaixo:

$$P_i \wedge_{\nu} P_j = \begin{cases} P_i \Rightarrow \text{if } P_i \leq P_j \\ P_j \Rightarrow \text{if } P_i > P_j \end{cases} \quad (2.10)$$

$$P_i \vee_{\nu} P_j = \begin{cases} P_i \Rightarrow \text{if } P_i \geq P_j \\ P_j \Rightarrow \text{if } P_i < P_j \end{cases} \quad (2.15)$$

O máximo é representado pelo operador “V” e o mínimo representado por “v”.

b) Exemplos de operações morfológicas por ordenação lexicográfica ISH

Abaixo se pode visualizar um exemplo de erosão e dilatação de duas imagens coloridas a partir da implementação do modelo de cor HSI com ordenação lexicográfica ISH.

Na figura 2.5 são mostrados os resultados de uma imagem erodida 2.5-(b) a partir da imagem de um melanoma assimétrico 2.5-(a) com 2 iterações e elemento estruturante 3x3. Uma imagem original do melanoma com borda irregular 2.5-(c) e a imagem erodida 2.5-(d) com 2 iterações e elemento estruturante 3x3.




Figura 2.5: (a) Imagem original de um melanoma assimétrico (a) [GBM07], Imagem A erodida (b); Imagem original de um melanoma com borda irregular (c), Imagem C erodida (d).




Figura 2.6: Imagem original de um melanoma assimétrico (a) [GBM07], Imagem A dilatada (b); Imagem original de um melanoma com borda irregular (c), Imagem C dilatada (d).

Na figura 2.6 são mostrados os resultados da dilatação das mesmas imagens: imagem original do melanoma assimétrico 2.6(a) e imagem dilatada 2.6(b) com 2 iterações e elemento estruturante 3x3; imagem original do melanoma com borda irregular 2.6(c) e a imagem dilatada 2.6(d) com 2 iterações e elemento estruturante 3x3, pode ser observada na figura abaixo:

Conclusões sobre a Morfologia Matemática em Cor

A escolha do espaço de cor a ser usado vem a ser crucial para a Morfologia Matemática em Cor. A grande dúvida surge quando se pergunta se há um melhor espaço de cores para identificação de lesões do melanoma.

No caso de imagens coloridas, a imagem processada através da ordenação lexicográfica HSI e lexicográfica ISH geram um problema referente à interpretação visual. Como não é habitual fazer análise em imagens coloridas, percebe-se o quanto é difícil interpretar o resultado [SOI99].

Por outro lado, nota-se que as operações morfológicas em cores evitam a perda de informações, o que ocorre quando imagens coloridas são transformadas em imagem binárias ou em níveis de cinza [COM99].

Com base em estudos realizados ([PNN01], [MOT01]) que não adotam o uso da morfologia matemática em cor no processamento de imagens de melanoma propõe-se a sua utilização pela possibilidade de se obter resultados aceitáveis e mais eficientes através dos modelos de cores HSI.

2.3 Classificador *Fuzzy CMeans* (FCM)

O classificador *Fuzzy CMeans* é um método iterativo de classificação não supervisionada sendo um conjunto de dados a ser classificados $X = \{x_1, \dots, x_k, \dots, x_n\}$ é particionado em c classes ao redor de c centróides [YON04].

Do ponto de vista teórico, o agrupamento dos dados em c classes deve minimizar uma função de erro $J^q(X, V)$

$$J^q(X, V) = \sum_{k=1}^n \sum_{i=1}^c (u_{ik})^q d^2(x_k, v_i) \quad (2.16)$$

Sendo a variável n representa o número de dados, a variável c o número de classes com $2 \leq c < n$, a variável u_{ik} a função de pertinência do dado x_k à i -ésima classe, a variável q o expoente ponderador da função de pertinência *fuzzy*, a variável v_i o centróide da classe i . Por fim $d_{ik} = d(x_k - v_i)$ representa a medida de distância euclidiana entre o dado x_k e o centróide v_i da classe i [YON04].

A minimização de $J^q(X, V)$ pode ser obtida pelo processo iterativo a seguir:

1. Definir o número de classes c , o valor de q e a taxa de erro de agrupamento ϵ .
2. Na iteração $b = 0$, inicializar a partição da matriz.
3. Na iteração b , calcular os centróides das c classes v_i^b :

$$v_i^b = \frac{\sum_{k=1}^n (u_{ik}^b)^q x_k}{\sum_{k=1}^n (u_{ik}^b)^q} \quad (2.11)$$

4. Atualizar na iteração $(b+1)$ a função de pertinência u_{ik} do dado x_k à i -ésima classe. Para cada dado x_k , para k variando de 1 até n , definir os seguintes conjuntos:

$$I_k = \{i \mid 1 \leq i \leq c, d_{ik} = d(x_k - v_i) = 0\}$$

e

$$\tilde{I}_k = \{1, 2, \dots, c\} - I_k$$

- a) Se $I_k = \emptyset$, então a função de pertinência $u_{ik}^{(b+1)}$ na iteração $(b+1)$ é :

$$u_{ik}^{(b+1)} = \frac{1}{\sum_{j=1}^c \left(\frac{d_{ik}}{d_{jk}}\right)^{2/(q-1)}} \quad (2.12)$$

b) Caso $I_k \neq \emptyset$, então a função de pertinência $u_{ik}^{(b+1)}$ na iteração $(b+1)$ é nula

para todo $i \in \tilde{I}_k$ e $\sum_{i \in I_k} u_{ik}^{(b+1)} = 1$;

c) Repetir o processo para o próximo k (próximo dado x_k).

5. Comparar os centróides das c classes v_i^b e v_i^{b+1} obtidas nas iterações (b) e $(b+1)$ respectivamente.

a) Se $d(v_i^b - v_i^{(b+1)}) < \varepsilon$, significa que o processo de agrupamento convergiu (condicionado ao valor a taxa de erro de agrupamento ε).

b) Caso contrário, $b = b + 1$ e volte ao passo 3.

Vale a pena frisar que durante o processo de classificação *Fuzzy*, o dado não necessariamente pertence a apenas uma classe. O grau de pertinência u_{ik}^b na iteração b permite ao dado de não ficar vinculado a uma classe exclusivamente. O classificador *Fuzzy CMeans* atualiza o grau de pertinência u_{ik}^b das classes, agrupando cada dado apresentando o maior grau de pertinência, u_{ik}^b , ao centróide i da respectiva classe v_i^b .

2.4 Conceitos de Segmentação

O objetivo da segmentação é obter um conjunto de primitivas que definem a informação relativa à imagem. Essas primitivas referem-se à geometria da imagem, sua forma, topologia, textura, cor ou brilho. A etapa de segmentação de imagens é considerada um dos maiores desafios do processamento e análise de imagens pela grande variedade de primitivas em conter informações semânticas [FAC06].

O princípio da segmentação consiste em separar o primeiro e segundo plano gerando uma imagem preto-branca apresentando duas classes. Em alguns casos, dependendo do conteúdo de uma imagem, se ela for particionada em duas classes acarreta uma grande perda de informação. Neste caso, busca-se dividir a imagem

em mais que duas classes chamando a limiarização pelo termo de multi-limiarização [FAC06].

2.4.1 Limiarização Global

Essa técnica de limiarização é utilizada para isolar o fundo do objetos. Suponha que uma imagem contenha objetos escuros em um fundo mais claro, ignorando a influência de ruído ou iluminação. Assume-se para este caso que a maioria de pixels que pertencem aos objetos terão um nível de cinza baixo, e os pixels do fundo terão um nível de cinza (preto é representado pelo nível de cinza 0, e branco pelo nível de cinza 255) [MAT99].

Os pixels de uma imagem são divididos em dois grupos em relação ao seu nível de cinza e são esses níveis de cinza distinguem a imagem do fundo. Quando a imagem possui bordas suavizadas, ela não é uma imagem puramente branca e preta impossibilitando a detecção de dois níveis de cinza diferentes. Isso se agrava com a existência de ruído na imagem.

Uma solução pode ser a seleção um nível de cinza T entre esses dois níveis dominantes que servirá como um limiar para distinguir as classes objetos e fundo. O valor marcado como T é uma escolha para um limiar através de um método não supervisionado descrito em [OTS79]. Baseado nesse limiar, uma nova imagem binária pode ser produzida, sendo que os objetos são pintados completamente em preto, e os pixels restantes são brancos. Considerando $f(x, y)$ a imagem original, então o produto da limiarização é alcançado esquadrihando-se a imagem original, pixel a pixel, e testando-se cada pixel contra o limiar selecionado: se $f(x,y) > T$, então o pixel é classificado como sendo um pixel de fundo, caso contrário o pixel é classificado como um pixel de lesão, por exemplo. Isto pode ser resumido na equação 2.19 que se segue, sendo $b(x, y)$ denota o limiar binário:

$$b(x, y) = \begin{cases} 255, & \text{se } f(x,y) > T \\ 0, & \text{se } f(x,y) \leq T \end{cases} \quad (2.13)$$

A limiarização global é uma técnica que apresenta excelentes resultados para casos em que no histograma são representados objetos e fundo [OTS79].

2.4.2 Limiarização Adaptativa

A limiarização global usa um limiar fixo para todos os pixels na imagem e, por esta razão, resultados realmente satisfatórios serão obtidos quando o histograma de distribuição de níveis de cinza contém cumes distintos e separados que correspondem aos objetos e ao fundo. Isto conduz a conclusão que um limiar mais local deve ser usado. O mecanismo de funcionamento é simples, e pode ser sumarizado como tendo os seguintes passos [MIL98]:

- A imagem original é dividida em sub-imagens;
- Um limiar é determinado independentemente para cada sub-imagem;
- Se um limiar não puder ser determinado para alguma sub-imagem, ele pode ser interpolado à partir dos limiares determinados nas sub-imagens vizinhas;
- Cada sub-imagem é então processada utilizando seu limiar local.

Uma definição de um limiar para técnicas adaptativas pode ser denotada como sendo:

$$T = T[x, y, p(x, y), f(x, y)] \quad (2.14)$$

Sendo $f(x,y)$ é o nível de cinza do ponto (x,y) na imagem original, e $p(x,y)$ é alguma propriedade local deste ponto. Percebe-se que o limiar T não depende apenas do nível de cinza do ponto. É necessária atenção especial ao fator $p(x,y)$ que é descrito como uma propriedade do ponto e que é, um dos mais importantes componentes no cálculo do limiar para um certo ponto [MIL98]. Para que a influência de ruído ou iluminação possa ser levada em conta, o cálculo dessa propriedade é baseado no ambiente em que o ponto em questão está inserido. Um exemplo de propriedade é a média dos níveis de cinza em uma vizinhança pré-estabelecida, na qual o centro é o ponto em análise. Este método produzirá os resultados desejados

se os objetos forem relativamente pequenos e não estiverem muito próximos uns dos outros [MIL98].

2.4.3 Limiarização Multinível

A limiarização multinível é usada quando se tem vários objetos que se distinguem do fundo. A presença desses faz com que o histograma de distribuição de níveis de cinza seja multimodal. O limiar é encontrado pela localização dos vales que separam os objetos [SAH97]. A limiarização multinível pode ser então entendida como sendo uma extensão dos métodos de segmentação em dois níveis, com a diferença que possibilita a segmentação em múltiplas classes.

Uma técnica de limiarização multinível deve ser capaz de segmentar a imagem digitalizada para os diferentes objetos que apresentam propriedades similares [SAH97].

Capítulo 3

Estado da Arte

3.1 Métodos de Segmentação de Melanoma

3.1.1 Estudo de Métodos de Análise por Cheng

Cheng [CHE05] apresenta em seu artigo métodos de análise e diagnóstico de imagens clínicas baseado em cores e algoritmos de reconhecimento de padrões. O diagnóstico foi feito sobre imagens contendo áreas lesionadas por câncer de melanoma. O estudo utiliza a aplicação CVIPtools (*Computer Vision and Image Processing tools*) para fazer a análise das imagens. O estudo trata ainda de conceitos de segmentação das imagens baseado em cor, extração de características de cor e determinação do formato do tumor para resultados estatísticos. São utilizados algoritmos de reconhecimento de padrões supervisionados com uma base de imagens com o tumor de câncer de pele Melanoma.

O processo de classificação e análise das imagens consiste em cinco passos de processamento de imagens:

- Criação de imagens coloridas relativas;
- Segmentação e filtragem morfológica: é usada para reduzir o número de objetos na imagem segmentada. A extração de características de cor relativas a cor é necessária para simplificar os dados brutos da imagem em um nível superior, com informações relevantes. O vetor de características é usado em classificação e reconhecimento de padrões, em que cada objeto é definido por

um grupo de atributos no espaço de características. No total 17 características coloridas e binárias foram utilizadas usando a ferramenta CVIPtools. Das 17 características extraídas temos.

Características binárias:

$$\text{Área: } Area = \sum_r \sum_c I(r,c)$$

$$\text{Thinness (estreitamento): } Thinness = 4\pi \left(\frac{Area}{Perimeter^2} \right)$$

Características do histograma dos canais RGB:

$$\text{Média (mean): } Mean = \sum_r \sum_c \frac{I(r,c)}{M}$$

$$\text{Desvio Padrão: } \sigma_g = \sqrt{\sum_{g=0}^{L-1} (g - \bar{g})^2 P(g)}$$

$$\text{Skewness: } Skewness = \frac{1}{\sigma_g^3} \sum_{g=0}^{L-1} (g - \bar{g})^3 P(g)$$

$$\text{Energia: } Energy = \sum_{g=0}^{L-1} [P(g)]^2$$

$$\text{Entropia: } Entropy = -\sum_{g=0}^{L-1} P(g) \log_2 [P(g)]$$

- Determinação do espaço de características de tumor e do espaço de características do objeto: O espaço de características do tumor utiliza 277 vetores de características correspondentes a 277 imagens de tumor na pele, cada vetor possui 51 elementos de características que é 3 vezes o total de 17 características cada um dos três maiores objetos dentro de um mesmo tumor. O espaço de características do objeto utiliza 842 vetores de características correspondentes a 842 objetos da imagem, cada vetor possui 17 elementos de características, que foram as características binárias e coloridas mencionadas anteriormente.
- Determinação dos modelos estatísticos a partir das características de cor: Estabelecendo os modelos estatísticos, os dois espaços de características servem como dois modelos de dados para maximizar a possibilidade de sucesso. Dois modelos de classificação foram utilizados, análise discriminante e *multi-layer perceptron*, desenvolvidos em modelos de dados.

O *multi-layer perceptron* utilizou as melhores características, sendo o primeiro dos três componentes dos dados do projeto PCA. Com tais parâmetros foram obtidos 77% de sucesso na identificação do melanoma e 68% de sucesso para os nevos. Este método foi aplicado ao espaço de características do tumor.

No espaço de características dos objetos, a análise discriminante proveu resultados satisfatórios, em que obteve 80% de sucesso na identificação do melanoma dentre outros tumores na pele e outros. Já o *multi-layer perceptron* (MLP) usou uma combinação de 5 saídas e 12 saídas ocultas para obter melhores resultados (executou o método *Leave One Out*). Houve uma taxa de sucesso de 86% na classificação do melanoma, assim considerado mais consistente.

3.1.2 Avaliação de Métodos de Segmentação por Silveira

O estudo realizado por Silveira et. al. [SIL09], propôs a avaliação de seis métodos para segmentação de lesões de pele aplicado em 100 imagens dermatoscópicas e avaliada com quatro diferentes métricas, usando o resultado da segmentação obtida por um experiente dermatologista como a verdade. O estudo baseia-se nas técnicas de GVT (Fluxo do vetor gradiente) e o nível de definição do método de Cheng et. al. (C-LS). Este conjunto de métodos desenvolvidos pelos próprios autores foi adaptado para a aplicação em específico. Os autores propuseram a comparação de seis diferentes métodos de segmentação dos três tipos: limiarização, baseada no conhecimento, baseado em região.

Os métodos são:

- limiarização adaptativa (AT): em que a segmentação da lesão pode ser obtida através da comparação da cor de cada pixel com um limite (fronteira). O pixel é classificado como ativo (lesão) se ele é mais escuro do que o limite. A saída desta etapa é uma imagem binária. A morfologia matemática é aplicada no pós-processamento para preencher os buracos e selecionar o maior componente da imagem binária. O limite é calculado automaticamente a partir do histograma do componente de cor selecionado;
- O fluxo do vetor gradiente (GVF): O GVF é um algoritmo bem conhecido proposto que tem sido usado com sucesso em muitos problemas de imagens

médicas. O limite do objeto é aproximado por um contorno que é inicializado no domínio da imagem pelo usuário ou por critérios heurísticos. A inicialização do GVF é automático. Um círculo com um determinado raio é colocado na imagem. O centro do círculo é dada pelo centro da região segmentada obtida pelo método de segmentação adaptativa;

- Falso adaptativo (AS): aqui os contornos são muitas vezes atraídos por bordas falsas, que não pertencem ao limite da lesão. Estes normalmente aparecem em imagens dermatoscópicas devido a artefatos como pelo, reflexos especulares ou mesmo a partir de variações na textura da pele. Por isso, tem-se a necessidade de métodos robustos que sejam capazes de descartar esses ruídos. Primeiro, o método detecta segmentos de contorno (AVC) na imagem baseado no algoritmo de maximização EM. Detecção de curso é feito em duas etapas. Primeiro, detectar a intensidade de transições ao longo de um conjunto de direções radiais em relação ao valor de saturação baseado no espaço de cor HSV. A borda é formada adotando continuidade de critérios, para isso, há a necessidade de intervenção do usuário para selecionar as regiões utilizadas para calcular as estatísticas de cor, como mostra a tabela abaixo;
- A figura (figura 3.1) abaixo mostra a evolução do potencial adaptativo durante o processo de convergência.




Figura 3.1: Evolução do potencial adaptativo durante o processo de convergência [SIL09].

- Definir o método de Chan et al. (C-LS): Assume-se que a imagem i é formada por duas regiões de intensidade constante $C1$ e $C2$, separados por uma curva, como mostra a figura 3.2.




Figura 3.2: Contorno inicial usando C-LS e EM-LS para duas imagens [SIL09].

Contornos iniciais utilizados pelos métodos LS-C e EM-LS para duas das imagens do conjunto de dados utilizado no estudo.

Neste experimento foi feita a inicialização usando um retângulo colocado pelo usuário na região da lesão. A inicialização não precisa ser muito próximo do limite da imagem. A figura 3.2 mostra algumas das inicializações usado nos experimentos.

- Maximização Expectation-Método Level Set (EM-LS): este método é a prorrogação do método citado anteriormente. Propõe uma abordagem mais flexível e pressupõe que as intensidades das regiões c dentro e fora são modeladas por funções probabilísticas $p1$ e $p2$, respectivamente.

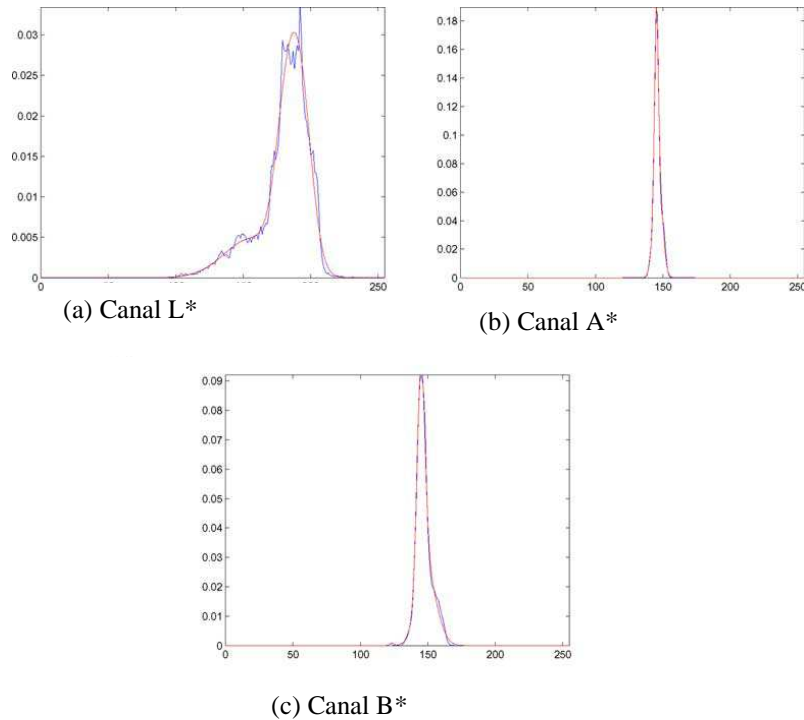


Figura 3.3: Histograma na região da lesão [SIL09].



Figura 3.4: Lesão de melanoma [SIL09].

A figura 3.3 compara o histograma de valores de intensidade de regiões da lesão com os PDF's estimadas através do algoritmo EM para a três canais de cor (L^* , a^* e b^*) a partir da imagem da figura 3.4. O histograma é mostrado em azul e o pdf é mostrado em vermelho. Pode ser visto que as duas curvas estão muito próximas, portanto, o modelo apresenta uma boa aproximação. O método de inicialização segue a descrição do CLS já mencionado.

Fuzzy baseado no algoritmo split-and-merge (FBSM): O sexto método utilizado no estudo é o fuzzy baseado no algoritmo dividir e mesclar. O algoritmo inicialmente visa segmentação perceptiva não supervisionada de imagens com cores naturais. Como o algoritmo tem a vantagem significativa para interromper o processo

com o número especificado das regiões segmentadas, é aplicável à segmentação de imagens dermatoscópicas. Primeiro, o algoritmo FBSM extrai as características de cor e textura de uma imagem original. Os valores de L^* , a^* e b^* são usados como elementos de cor, e as características geométricas são usadas como textura. Em seguida, o algoritmo split-and-merge é executado em quatro etapas: simples cisão, fusão local, global fusão e refinamento de fronteira. Durante as três últimas etapas, a semelhança de qualquer lado regiões foi estimado usando a homogeneidade fuzzy baseados na medida que combina a similaridade de características de cor e textura características com diferentes graus de importância. A adoção de uma medida de homogeneidade fuzzy baseado simplifica o complexo mecanismo de integração de características diferentes, por meio da simbólica representações.




Figura 3.5: Fuzzy - HO representa que é homogênea, NHO não é homogênea, PHO é provavelmente homogênea, e PNHO provavelmente não é homogênea [SIL09].

As seguintes regras *fuzzy* são usados, e cada regra tem uma função de adesão correspondente:

- 1) Regra 1: Se a diferença SGF é pequeno, então HOMOGENEOS (HO); NOT_ Else homogêneos (NHO);
- 2) Regra 2: Se L^* a^* b^* diferença é pequena, então PROBABLY_Homogêneos (PHO); PROBABLY_ Else NOT_ homogêneos (PNHO).

Após essas duas regras, o método convencional de defuzzificação centróide é aplicada. Suponha-se que o limite de homogeneidade é definido como 0,5. Então, se

a medida de homogeneidade inferido é superior a 0,5, as duas regiões testadas são consideradas homogêneas e são mescladas.

A implementação do algoritmo FBSM é totalmente automático, porque os parâmetros exigidos pelo algoritmo são automaticamente sintonizada com base nas informações extraídas do imagem.

Na avaliação dos resultados, quatro diferentes métricas foram usadas para quantificar as diferenças de fronteira. A distância Hammoude (HM), a detecção da taxa de positivos (TDR) e a taxa de falsos positivos (FPR) são métricas baseadas na superfície. Além disso, utilizou-se a distância de Hausdorff (DH), que mede a distância entre os limites em pixels.

As métricas são calculadas como se segue:

- Distância Hammoude (HM): esta métrica faz uma comparação pixel por pixel dos pixels delimitada pelas duas fronteiras (equação 3.1):

$$HM(SR,GT) = \frac{\#(SR \cup GT) - \#(SR \cap GT)}{\#(SR \cup GT)} \quad 3.1$$

O HM leva em conta dois tipos de erro; pixels classificado como lesão pelo médico especialista que não foram classificados como tal pela segmentação automática e pixels classificados como lesão pela segmentação automática que não foram classificados como tal pelo médico especialista. A Distância Hammoude dá a mesma importância para ambos tipos de erro. No entanto, do ponto de vista clínico, o primeiro tipo de erro é mais importante, pois os pixels da lesão nunca deve ser desperdiçada.

- taxa de detecção True (TDR): essa métrica mede o índice de pixels classificados como lesão tanto pela segmentação automática como pelo médico (equação 3.2):

$$TDR(SR,GT) = \frac{\#(SR \cap GT)}{\#(GT)} \quad 3.2$$

Esta métrica é também uma medida indireta do falso negativo Taxa (FNR), desde $FNR = 1 - TDR$. O FNR mede a taxa de pixels classificados como lesão pelo

médico que não foram classificados como lesão pela segmentação automática. Clinicamente, este é pior dos dois tipos de erro.

- taxa de falsos positivos (FPR): essa métrica mede o índice de pixels classificados como lesão pela segmentação automática que não foram classificados como lesão pelo médico especialista (equação 3.3):

$$FPR(SR, GT) = \frac{\#(SR \cap GT)}{\#(GT)} \quad 3.3$$

- Distância de Hausdorff (DH): a distância de Hausdorff encontra a maior distância entre os pontos de fronteira. Esta métrica, como a distância Hammoude, não faz distinção entre a distância de dentro ou de fora do curva de referência.

Os parâmetros utilizados por cada método foram os mesmas em todos os experimentos. Os resultados dos métodos de segmentação calculados para as 100 imagens e os valores em negrito correspondem aos melhores desempenhos (tabela 3.1):

Tabela 3.1 – Resultados dos Métodos de Segmentação citados por Silveira [SIL09].

Método	HM (%)	TDR (%)	FPR (%)	HD (pixels)	Erros (%)
AT	16.20	91.30	4.08	54.67	19
GVF	19.98	90.89	8.67	48.80	16
AS	12.63	95.47	6.36	36.90	8
C-LS	19.09	83.39	2.55	57.01	22
EM-LS	15.06	95.20	6.17	49.67	11
FBSM	14.73	93.67	3.73	47.04	18

Os resultados experimentais são divididos em duas partes. Primeiro, avaliar os algoritmos usando os dados de todo o conjunto de imagens. Em seguida, avaliar o desempenho dos métodos de segmentação.

O banco de dados de 100 imagens foram processadas utilizando todos os métodos em avaliação. Os resultados da segmentação foram comparados com as imagens de referência (*ground-truth*) e os erros de segmentação foram avaliadas por quatro métricas já descritas. A tabela acima mostra as pontuações para cada método. O melhor método de acordo com a distancia Hammoude é a AS com uma pontuação de 12,63%. A melhor taxa de verdadeiro é alcançado pela AS e de EM

(95,47% e 95,20%, respectivamente). As melhores taxas de falso positivo foi obtido pela LS-C (2,55%). A distancia Hausdorff se comporta de forma semelhante à distância Hammoude. A taxa de detecção de pixels verdadeiros é especialmente importante, pois mede a fração de pixels da lesão que são detectados em todas as imagens.

3.1.3 Algoritmos de Segmentação por Ganster

O estudo realizado por Ganster et. al. [GAN01], obtém a imagem binária da lesão através de diversos algoritmos de segmentação. A ferramenta ELM desenvolvida pelos autores tem provado ser uma ferramenta importante na detecção do melanoma maligno. Em ELM, uma luz é projetada sobre o objeto tornando a superfície translúcida e tornando visíveis as estruturas da superfície.

Segundo os autores, a segmentação da lesão é obtida pela fusão de vários algoritmos simples de segmentação (*thresholding* e agrupamento de cores). O conceito de fusão permite a prorrogação do modulo de segmentação por integração de outros métodos (análise de textura e cor). Na aplicação da pesquisa, os autores notaram que as lesões apresentam grandes variações de tamanho, cor e contraste. A fim de não perder nenhuma característica importante da lesão, a morfologia em escala de cinza foi usada para obter a segmentação. Em fases posteriores, a informação foi obtida a partir da imagem original.

Resultados obtidos na etapa de segmentação: as bordas das lesões foram comparadas com as bordas das lesões marcadas por um dermatologista especialista e as diferenças encontradas foram avaliadas em três etapas. Primeiro, um conjunto de 150 imagens foi selecionado e as bordas da lesão foram marcadas manualmente por um especialista. Vários recursos como área, perímetro, forma, foram calculados para ambos os conjuntos de lesões (marcação manual de um dermatologista especialista e a extração automática pelo sistema) e avaliados estatisticamente. A comparação das áreas das lesões sofreu uma diferença média em pixels de 4.183 pixels com um desvio padrão de 6.771 pixels. O tamanho médio da lesão foi de 53.217 pixels na segmentação manual. Na segunda etapa da avaliação, as máscaras de um conjunto de 400 imagens de lesões foram inspecionadas por quatro

dermatologistas experientes e, segundo eles, a segmentação foi dita correta sobre os limites da lesão (fronteira). O restante das imagens (4.000 imagens) foi avaliado visualmente por um único especialista.

De um total de 4.000 imagens, o algoritmo de segmentação não foi capaz de detectar qualquer lesão em 19 casos, o que equivale a 0,48%. Em 140 casos (3,5%), a segmentação das lesões não foi satisfatória. De forma geral, 159 imagens foram rejeitadas devido a falhas na segmentação. O desempenho alcançado é de cerca de 96% de correta segmentação das imagens.

3.1.4 Métodos para Classificação de Lesões por Maglogiannis

O estudo realizado por Maglogiannis [MAG10], apresenta características visuais utilizadas para a classificação das lesões e métodos para defini-los. Os recursos empregados na definição de características para a detecção do melanoma são de alta sensibilidade e probabilidade de resposta Verdadeiro Positivo. As características devem ter probabilidade de resposta Falso Positivo. Embora no paradigma de classificação ambos os fatores são considerados importantes no caso do melanoma maligno, o aumento dos verdadeiros positivos são mais importantes. Em relação as características, a ênfase tem sido na avaliação do tamanho da lesão, forma, cor e textura. Após a extração, as características foram testadas com vários classificadores e o SVM mostrou-se mais eficiente.

3.1.5 Análise do Histograma por Stanley et. al.

O estudo realizado por Stanley et. al. [STA07] apresenta uma abordagem utilizando a cor como elemento para a detecção do melanoma maligno. As cores características do melanoma foram determinadas através da análise do histograma de cores. Os resultados experimentais indicam que os recursos de cores estão localizados no interior da lesão excluindo os 10% da região mais central.

3.1.6 Modelo de Segmentação Baseado em MRF por Tran

Tran [TRA10], apresenta em seu estudo os modelos clássicos de segmentação de imagens e a implementação do modelo de segmentação baseado em MRF a fim de produzir resultados melhores. O estudo mostra que os algoritmos de segmentação MRF são melhores do que os métodos clássicos. Uma forte característica do modelo MRF é a remoção de ruídos. A desvantagem da abordagem MRF é que é muito mais lenta do que os outros métodos clássicos de segmentação.

3.1.7 Algoritmo de Segmentação Não-supervisionado por Mollersen

A dissertação de mestrado apresentada por Mollersen [MOL08] propõe um algoritmo não-supervisionado de segmentação de lesão e de pré-processamento (filtragem, correção de iluminação). O algoritmo é eficaz na remoção de ruídos, baseado em operações morfológicas binárias. O algoritmo de segmentação é baseado em limiarização global e análise do histograma a partir da imagem RGB.

Após a limiarização global, o pós-processamento é aplicado para identificar a lesão. As imagens dermatoscópicas foram divididas em dois grupos: conjunto de treinamento e teste. O conjunto de treinamento consiste em 68 imagens e o conjunto de testes em 156 imagens. 80 das imagens do conjunto de testes foram avaliadas por um dermatologista especialista. Isso significa que os parâmetros utilizados no algoritmo de segmentação são escolhidos de forma independente das 80 imagens que são avaliadas.

O algoritmo proposto é simples e eficiente. Especificamente apresentam-se dois algoritmos: um para a remoção de ruídos e outro para a segmentação da lesão. O algoritmo de segmentação se baseia na análise do histograma e limiarização global. Na análise do histograma os únicos parâmetros analisados são o número de bits no histograma e o mínimo local. Os valores desses parâmetros são ajustados para amostras de imagens com resolução ou tamanho diferente.

Das 80 imagens, uma foi excluída, e das 79 imagens restantes 87% a classificação foi boa/aceitável, 9% das imagens a classificação foi ruim e 4% receberam o conceito de aceitável para um dermatologista e ruim para o outro.

3.1.8 Combinação de Segmentação Fuzzy CMeans e Segmentação Fuzzy por Zhou

ZHOU et. Al. [ZHO09], propõe uma nova abordagem que combina a segmentação *fuzzy CMeans* que utiliza um algoritmo de deslocamento anisotrópico médio junto com a segmentação *fuzzy*. O algoritmo clássico *fuzzy CMeans* baseia-se na idéia de encontrar centros de clusters ajustando suas posições. Na abordagem proposta, os pontos de coleta em uma área definida são tratados como membros do mesmo segmento. Para determinar a composição de um ponto de uma imagem, o cálculo de similaridade deve ser alcançado entre este ponto e o centro do segmento. Além disso, a coerência entre esse ponto e os pontos ao seu redor precisa ser descoberto (por exemplo: cor, consistência ou intensidade) para que possa ser usado para remover qualquer inconsistência como, por exemplo, ruídos.

O algoritmo de segmentação proposto foi avaliado em um conjunto de 100 imagens (30 imagens de melanoma maligno e 70 imagens benignas). Alguns algoritmos convencionais são comparados com a nova abordagem, são eles: FCM, EnFCM e ESFCM. Numa fase final, a transformação morfológica foi utilizada para analisar os resultados da segmentação, especialmente as bordas das imagens e remoção de pequenas áreas isoladas. Observa-se, como mostra a figura abaixo, que as segmentações produzidas por FCM clássico e FSFCM são menos suaves que aqueles por EnFCM e AMSFCM. Isso porque RSFCM usa FCM na segunda fase, ambos têm características aproximadas. E EnFCM e AMSFCM leva em consideração os pixels da imagens para que seus resultados sejam suavizados na fase FCM.




Figura 3.6: a) imagem original; b) imagem *ground truth*; c) FCM; d) RSFCM; e) EnFCM e f) AMSFCM [ZHO09].

Percebe-se que os algoritmos convencionais geram resultados semelhantes, enquanto que, o algoritmo AMSFCM proposto possui claramente os melhores resultados para as bordas da lesão.

Para a segmentação foi registrado o número de TP, FP, FN e TN das imagens. Através desse registro pode-se observar que a abordagem proposta AMSFCM possui um melhor desempenho com sensibilidade de cerca de 78% enquanto os outros algoritmos apenas 74%, oferecendo uma segmentação superior a outras abordagens *fuzzy c-means*.

3.1.9 Segmentação Baseado no Conceito Six Sigma por Sethumadhav

O estudo realizado por Sethumadhav [SET09] apresenta um método para analisar as lesões cutâneas usando o processo de segmentação baseado no conceito Six Sigma. Esse conceito apresenta uma análise mais aprofundada sobre a incidência e propagação do câncer. É baseado nos princípios de Gráficos de

Controle, que incide sobre o fato de que a variabilidade existe em todos os processos repetitivos. A variação heterogênea das cores da pele é considerada uma causa assinalável. Estas variações possuem maior magnitude quanto comparado com as variações encontradas em pele normal. Na abordagem proposta, a imagem é dividida em sub-regiões retangulares pequenas. Então, baseado na metodologia de controle de gráfico as regiões significativas são identificadas, trazendo uma segmentação efetiva das regiões de alto contraste de cores.

Para a limiarização de imagens com Six Sigma o plano de cor RGB é utilizado na representação de valores de cor de pixels para a análise. A imagem de tamanho $M \times N$ é cortada em pequenas sub regiões de tamanho $m \times n$. Para traças os gráficos de controle, limites de mais ou menos 3 sigma são calculados e denominados limites de controle.

A variação de propagação de cor é analisada considerando as sub regiões fora do limite de controle. O método proposto foi testado para um grupo de 35 lesões malignas e os resultados da segmentação em relação ao RGB, de 9 lesões são mostrados na figura 3.7.




Figura 3.7: Número de pixels para as janelas (4x4); (4x5); (5x4) e (5x5). a) vermelho, b) verde, c) azul e d) cor média [ZHO09].

Os resultados obtidos com essa abordagem são muito promissores, segundo os autores, mas pode não ter um bom desempenho em imagens com grande quantidade de ruídos (pelos) e um pré-processamento é necessário para eliminar esses ruídos para obter melhores resultados.

3.1.10 Avaliação de Algoritmos por Alcón

Alcón et. al. [ALC09] descreve um sistema de controle automático de lesões e diagnóstico de melanoma. O sistema inclui um componente de apoio à decisão, que combina o resultado da classificação de imagens com o conhecimento de contexto, tais como o tipo de pele, idade, sexo, parte do corpo afetada. Para a avaliação dos algoritmos foi usadas um conjunto de 152 imagens (45 benignas e 107 malignas). O sistema tem uma precisão de 86%.

Os algoritmos de segmentação são usados para separar a lesão do fundo. Dentre os algoritmos testados, a limiarização foi usada como método de segmentação das lesões. Para a implementação do método de limiarização, o algoritmo de limiarização de Otsu foi usado como exemplo. Após a segmentação da lesão pigmentada, as características essenciais são extraídas para decidir se a imagem é benigna ou maligna.

Capítulo 4

Método Proposto, Experimentos e Resultados Alcançados

A metodologia proposta tem como ênfase extrair a lesão de seu contexto, ou seja, separá-la do restante da imagem sem prejudicar suas cores, sua geometria e seu formato. A metodologia consiste nos tópicos apresentados na figura 4.1.

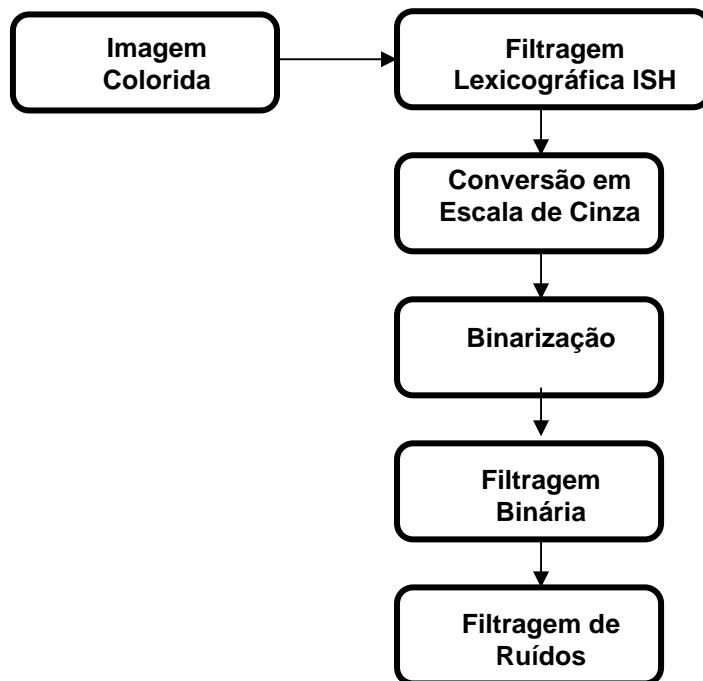


Figura 4.1 – Metodologia proposta.

4.1 Formação da Base de Dados

A formação da base de dados consiste em imagens coletadas de diversas fontes (sites distintos de imagens de melanoma), diferentemente do previsto inicialmente que citava somente imagens do site francês. Durante a formação da base, não houve acesso a informação sobre meios de captura. Portanto, são bases com diferentes tipos de resolução, iluminação, etc., por isso, algumas imagens com difícil identificação foram descartadas. A base de dados consiste em 300 imagens dividida em dois grupos: 150 imagens de melanoma benignas e 150 imagens de melanoma malignas. A partir da base de dados, 60% das imagens serão usadas para treinamento, 20% para testes e 20% para validação.




Figura 4.2 – (a) imagem original e (b) exemplos de imagens *ground-truth*.

4.2 Formação das Bases *Ground-truth*

O termo “base *ground-truth*” significa neste contexto gerar a solução ideal da segmentação da lesão da região do melanoma para todas as imagens usadas nos testes de treino e validação. A formação da base *ground-truth* foi totalmente manual e não teve participação de dermatologistas para avaliação. A segmentação ideal foi obtida seguindo uma lógica de profissionais da área de processamento de imagens. A figura 4.2 mostra exemplos de imagens *ground-truth*.

4.3 Filtragem Morfológica por Cor

Através da filtragem morfológica por cor, objetiva-se aprimorar as cores da lesão no sentido de realçar a sua geometria perante o fundo, respeitando o seu formato sem deformá-la. Nenhuma técnica específica de remoção de pelos foi aplicada. Tanto a eliminação de pêlos quanto do ruído é implicitamente embutida nesta etapa. O processo morfológico adotado foi de abertura (erosão seguida de dilatação).

A figura 4.3 ilustra os resultados da abertura por ordenação lexicográfica HSI com elemento estruturante (EE) quadrado 3x3, 5x5 e 7x7. Testes exaustivos permitiram definir como melhor seqüência de filtragem o uso da abertura com elemento estruturante (EE) quadrado 3x3.




Figura 4.3 - Exemplos de filtragem em cor: (a) Imagem original; (b) Abertura com EE Quadrado 3x3, (c) Abertura com EE Quadrado 5x5, (d) Abertura com EE Quadrado 7x7.

4.4 Segmentação por Limiarização

A extração da região lesada faz-se por segmentação por limiarização global. Inicialmente as imagens filtradas coloridas são transformadas em imagens em níveis de cinza. Após ter testado vários métodos de binarização disponíveis na literatura, a limiarização global de Renyi [SAH97] mostrou-se a mais eficiente no que diz respeito “ao resgate” das lesões sem prejudicar a geometria e o formato e sem adicionar ou remover partes das mesmas.

Através dos resultados da segmentação por limiarização mostrados na Figura 4.4, é possível observar alguns dos benefícios da filtragem morfológica por cor. Sem filtragem, as regiões segmentadas são imperfeitas. A abertura morfológica por cor propiciou a remoção do ruído colorido e dos brilhos excessivos preservando a geometria e forma das lesões. Resultando em regiões segmentadas mais perfeitas.

4.5 Filtragem Morfológica Binária

Esta etapa consiste no preenchimento de lacunas na região segmentada do melanoma e na remoção do ruído. O preenchimento foi realizado por reconstrução morfológica binária [FAC96]. A remoção do ruído busca eliminar mínimos e máximos locais inferiores a um dado tamanho sem afetar as estruturas da região segmentada do melanoma. Essa etapa foi realizada por abertura binária com elemento estruturante quadrado 7x7. A Figura 4.4 ilustra resultados obtidos com imagens apresentando grandes variações de cor, de bordas e de forma. Percebe-se a eficiência da abordagem proposta quando se compara as imagens obtidas pela abordagem proposta (Figura 4.4-(c)) com as imagens da segmentação ideal (*ground-truth*) da Figura 4.4-(d).




Figura 4.4 - Resultados da abordagem: (a) Imagem original com borda da região segmentada (b) Binarização (c) Filtragem morfológica binária (d) Segmentação ideal (*ground-truth*).

Diferentemente do que existe na literatura [PNN01], [MOT01], aqui serão aplicadas operações morfológicas em cores por ordenação lexicográfica ISH enfatizando aprimorar o contraste da lesão [FIB04]. Exemplos podem ser observados na figura 4.5. A partir da imagem original 4.5-(a), a imagem 4.5-(b) mostra um exemplo de filtragem por abertura morfológica em cores por ordenação lexicográfica ISH com 10 iterações. A imagem 4.5-(c) apresenta um exemplo de filtragem por abertura morfológica em cores por ordenação lexicográfica HSI com 10 iterações.




Figura 4.5: (a) imagem de melanoma maligno [GBM07]. (b) filtragem lexicográfica ISH. Imagem (c) filtragem lexicográfica HSI.

4.6 Avaliação da Abordagem Morfológica Proposta

A avaliação da eficiência da abordagem morfológica proposta de extração automática da região lesada do melanoma não pode ser unicamente visual, mas deve obrigatoriamente passar por uma análise numérica. Isto significa comparar a segmentação obtida com a segmentação ideal esperada.

Conforme a estratégia usada nas publicações internacionais, tal comparação é realizada a partir de bases *ground-truth*. O termo “base *ground-truth*” significa neste contexto gerar a solução ideal da segmentação da lesão da região do melanoma para todas as imagens usadas nos testes de treino e validação.

A formação da base *ground-truth* não teve participação de dermatologistas para avaliação dessa base. A segmentação ideal foi obtida seguindo uma lógica de profissionais da área de processamento de imagens.

Para analisar a abordagem proposta, dois procedimentos foram realizados. O primeiro procedimento consistiu numa avaliação numérica com doze métricas a partir de 2 bases de imagens de melanoma benigno e maligno, cada uma contabilizando 150 imagens. As imagens foram coletadas através do site francês [TVI07] que descreve e apresenta diferentes tipos de lesões benignas e malignas. Para cada imagem foi gerada, manualmente por um especialista em processamento

de imagens, a imagem da segmentação ideal (*ground-truth*) [BEF10] e [BEF10], como mostra a Figura 4.6-(b).

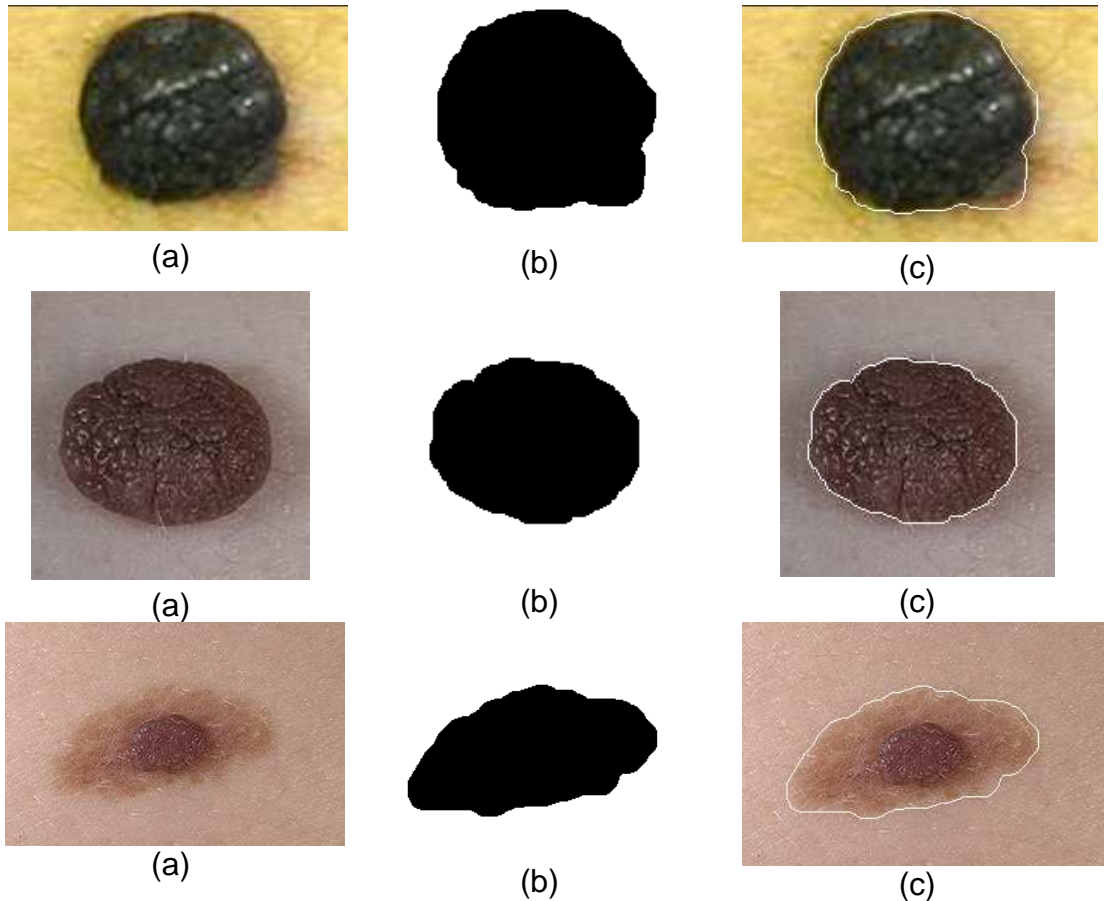


Figura 4.6: Exemplos de segmentação manual: (a) Imagem original; (b) segmentação manual da lesão; (c) Contorno sobreposto à imagem original.

4.6.1 Resultados com a Base de Imagens Benignas

Os resultados obtidos na elaboração da base *ground-truth* consistem em uma base de 150 imagens de lesões benignas do melanoma.

A base de benignas consiste em uma primeira etapa em selecionar ou rejeitar imagens da base inicial em função da dificuldade visual em se localizar com exatidão a região lesada do melanoma. E numa segunda etapa em segmentar manualmente a região lesada das imagens selecionadas.

Da base inicial de 160 imagens de lesões benignas do melanoma, 10 imagens foram eliminadas, devido à dificuldade visual em se localizar com exatidão

a região lesada do melanoma. Portanto, a base diminuiu para 150 imagens. A partir da base de 150 imagens, a região lesada de cada imagem foi segmentada manualmente. A figura 4.6 ilustra exemplos de imagens segmentadas.

4.6.2 Resultados com a Base de Imagens Malignas

Da mesma forma que realizado com a base de benignas, a base de malignas apresenta alguns dos resultados obtidos na elaboração da base *ground-truth* no caso de 150 imagens de lesões malignas do melanoma.

A metodologia proposta consistiu, numa primeira etapa em selecionar ou rejeitar imagens da base inicial em função da dificuldade visual em se localizar com exatidão a região lesada do melanoma. E numa segunda etapa em segmentar manualmente a região lesada das imagens selecionadas.

Da base inicial de 180 imagens de lesões malignas do melanoma, 30 imagens foram eliminadas, devido à dificuldade visual em se localizar com exatidão a região lesada do melanoma. Portanto, a base diminuiu para 150 imagens. A figura 4.7 mostra um exemplo de imagem complexa eliminada.



Figura 4.7: Exemplo de imagem complexa eliminada devido à dificuldade em enxergar os limites da lesão.

A partir da base de 150 imagens, a região lesada de cada imagem foi segmentada manualmente. A figura 4.8 ilustra exemplos de imagens segmentadas. Nesta figura é possível verificar a grande variabilidade de formatos e cores das regiões lesadas do melanoma.




Figura 4.8 - Exemplos de segmentação manual: (a) Imagem original; (b) segmentação manual da lesão; (c) Contorno sobreposto à imagem original.

Estas bases *ground-truth* são de suma importância na avaliação da eficiência da abordagem morfológica proposta segundo os padrões usados nas publicações internacionais.

4.7 Morfologia Matemática em Cor

Testes exaustivos permitiram definir como melhor seqüência de filtragem o uso de erosão com 3 iterações seguidas de dilatação com 3 iterações. A figura 4.9 ilustra exemplo de filtragem e segmentação de lesões benignas e malignas de coloração e formato diversos. Nesta etapa, usou-se a limiarização de Renyi para as bases de benignas e malignas. Para facilitar a comparação visual, o contorno da lesão foi sobreposto à imagem original.




Figura 4.9: Exemplos de segmentação: (a) Imagem original; (b) Filtragem morfológica; (c) Segmentação da lesão; (d) Contorno sobreposto à imagem original.

A filtragem morfológica em cores por ordenação lexicográfica HSI, assim como Ortiz *et al.* [ORT02], a ordenação lexicográfica (denotada por O_{lex}), foi

determinante para extrair eficientemente a lesão respeitando a sua geometria, evitando que a presença de pelos gere distorções. De acordo com a base de dados de 300 imagens pode-se afirmar que, em 90% das imagens (benignas e malignas), a lesão foi extraída de forma que não prejudicou sua geometria e formato, como mostra a figura 4.9.

4.8 Classificador não supervisionado *Fuzzy C-Means*

O classificador não supervisionado *Fuzzy CMeans* foi o segundo procedimento usado para comparar a metodologia proposta com a abordagem de segmentação do melanoma de Cheng e Umbaugh [CHE05] que foi modificada e aprimorada. Neste procedimento substituiu-se o espaço de cor *RGB* pelo espaço de cor *TSL* considerado por Vezhnevets et al [VEZ03] como o espaço de cor mais apropriado para processar imagens de pele humana. O número de características foi reduzido de sete para cinco (média, desvio padrão, skewness e kurtosis) para cada um dos três canais Tintura, Saturação e Luminância do espaço *TSL*. Reduzindo assim o vetor de características em 12 características no lugar de 17 na abordagem original de Cheng e Umbaugh [CHE05]. Por fim, o classificador multi-layer perceptron (*MLP*) foi substituído pelo classificador *Fuzzy CMeans* [YON04].

As mesmas métricas e bases de imagens de melanoma acima citadas foram utilizadas para avaliar a abordagem modificada *Fuzzy C-means*. As tabelas 1 e 2 ilustram, através das doze métricas, os resultados das avaliações numéricas da abordagem proposta e da abordagem modificada *Fuzzy CMeans* para as duas bases. A imagem 4.10-(b) mostra a filtragem com *Fuzzy CMeans* canal L e 2 centros e a imagem 4.10-(c) a segmentação da lesão.




Figura 4.10: Exemplos de segmentação: (a) Imagem original; (b) Filtragem com *Fuzzy CMeans* canal L e centros; (c) Segmentação da lesão.

4.9 Análise da Avaliação da Abordagem Morfológica

A abordagem modificada a partir da abordagem original de Cheng e Umbaugh [CHE05] que obteve 78% de sucesso na segmentação do melanoma para uma base de 160 imagens coloridas de tumores [BIM99], obteve uma maior taxa de segmentação com taxas de verdadeiros positivos TP ($86,69 \pm 18,80$)% e ($89,33 \pm 18,14$)% para as bases de melanoma benigno e maligno, respectivamente.

A abordagem morfológica proposta superou a abordagem modificada com taxas bem superiores de TP ($95,67 \pm 06,17$)% e ($97,22 \pm 04,96$)% para as bases de melanoma benigno e maligno. Essa maior eficiência se reflete não somente em relação às taxas de verdadeiros positivos TP , mas também aos valores das métricas ME , RAE , TN , FP , FN , P , A , R , ER , e também em relação às taxas de desvio padrão. Em seguida, a descrição das métricas de avaliação:

- No caso do melanoma um pixel Verdadeiro Positivo TP é um pixel que é PRETO na imagem ideal da segmentação e também PRETO na

abordagem de segmentação proposta; um pixel Falso Positivo FP é um pixel que é BRANCO (fundo) na imagem ideal da segmentação e que virou PRETO (considerado como da região lesada) na segmentação proposta; um pixel Verdadeiro Positivo FN é um pixel que é BRANCO na imagem ideal da segmentação e também BRANCO (fundo) na segmentação proposta; um pixel Falso Positivo FN é um pixel que é PRETO na imagem ideal da segmentação e que virou BRANCO (fundo) na segmentação proposta.

- Erro de classificação – ME: retorna 0 no caso de segmentação perfeita e 1 no caso de má segmentação. Pode ser descrita pela equação 4.1 onde (B_g, F_g) e (B_s, F_s) representam o fundo e o primeiro plano da imagem *ground-truth* e a segmentação obtida pelo método proposto, respectivamente, sendo “|” a cardinalidade:

$$ME = 1 - \frac{|B_g \cap B_s| + |F_g \cap F_s|}{|B_g| + |F_g|} \quad 4.1$$

- Erro Relativo ao Primeiro Plano – RAE: retorna 0 no caso de segmentação perfeita e 1 no caso de má segmentação. Pode ser descrita pela equação 4.2 onde F_g e F_s representam o fundo da imagem *ground-truth* e a segmentação obtida pelo método proposto, respectivamente, sendo “|” a cardinalidade:

$$RAE = \begin{cases} \frac{|F_g| - |F_s|}{|F_g|} & \text{if } |F_g| > |F_s| \\ or \\ \frac{|F_s| - |F_g|}{|F_s|} & \text{if } |F_g| < |F_s| \end{cases} \quad 4.2$$

- Precisão – P: retorna 1 no caso de segmentação perfeita e pode ser descrita pela equação 4.3:

$$P = \frac{TP}{TP + FP} \quad 4.3$$

- Acurácia – A: retorna 1 no caso de segmentação perfeita e pode ser descrita pela equação 4.4:

$$A = \frac{TP + TN}{TP + TN + FP + FN} \quad 4.4$$

- Revocação – R: retorna 1 no caso de segmentação perfeita. Pode ser descrita pela equação 4.5.

$$R = \frac{TP}{TP + FN} \quad 4.5$$

- Taxa de Erro – ER: retorna 0 no caso de segmentação perfeita. Pode ser descrita pela equação 4.6.

$$ER = \frac{FP}{TP + FN} \quad 4.6$$

- A medida FM: retorna 1 no caso de segmentação perfeita. Pode ser descrita pela equação 4.7.

$$FM = \frac{2 * P * R}{P + R} \quad 4.7$$

- Taxa negativa – NRM: retorna 0 no caso de segmentação perfeita. Pode ser descrita pela equação 4.8.

$$NRM = \frac{NR_{FN} + NR_{FP}}{2} \quad \text{onde} \quad NR_{FN} = \frac{FN}{TP + FN}, \quad NR_{FP} = \frac{FP}{TP + FN} \quad 4.8$$

Pode-se ainda enfatizar que as taxas *FM* e *NRM*, consideradas por [GAT09] como sendo as mais representativas em termos de eficiência, são de (95,22±03,88)% e (04,79±03,79)% para a base de melanoma benigno e de (94,65±03,78)% e (05,56 ± 03,96)% para a base de melanoma maligno. Pode ainda

perceber ainda que os valores de desvio padrão são aproximadamente quatro vezes inferiores aos valores de desvio padrão das mesmas taxas para a abordagem modificada *Fuzzy C-means*. O que demonstra a eficiência da metodologia proposta.

Tabela 4.1: Avaliação da abordagem proposta a partir das doze métricas (em %).

	ME	RAE	TP	TN	FP	FN	P	A	R	ER	FM	NRM
Benignas	04,35	12,37	95,67	94,75	05,25	04,33	95,26	95,21	95,67	04,79	95,22	04,79
Benignas Desvio Padrão	04,00	13,87	06,17	06,67	06,67	06,17	05,57	03,79	06,17	03,79	03,88	03,79
Malignas	05,84	12,30	97,22	91,66	08,34	02,78	92,62	94,44	97,22	05,56	94,65	05,56
Malignas Desvio Padrão	04,46	09,10	04,96	07,75	07,75	04,96	06,24	03,96	04,96	03,96	03,78	03,96

Tabela 4.2: Avaliação da abordagem *Fuzzy CMeans* a partir das doze métricas (em %).

	ME	RAE	TP	TN	FP	FN	P	A	R	ER	FM	NRM
Benignas	08,00	17,25	86,69	92,63	07,15	13,26	93,41	89,78	86,73	10,22	88,33	10,20
Benignas Desvio Padrão	08,00	17,37	18,80	09,22	09,15	18,81	07,27	09,12	18,81	09,12	12,52	09,12
Malignas	10,40	18,45	89,33	88,43	11,57	10,67	89,79	88,88	89,33	11,12	87,82	11,12
Malignas Desvio Padrão	07,04	16,24	18,14	10,73	10,73	18,14	07,86	08,84	18,14	08,84	13,33	08,84

4.10 Exemplos de *segmentação do melanoma* mal sucedidos por Abordagem Morfológica e por Abordagem *Fuzzy CMeans*

No exemplo da figura 4.11 o resultado não foi como o esperado pelo fato da imagem original apresentar um desequilíbrio de contraste e brilho entre os lados esquerdo e direito.



Figura 4.11 – Imagem original (a); Imagem segmentada incorretamente (b).

Outro exemplo que ilustra a dificuldade da abordagem *Fuzzy Cmeans* em segmentar a lesão e o caso da figura 4.12 em que pode ser visto o brilho excessivo no meio da mancha. O processo de limiarização não conseguiu interpretar e segmentar as duas regiões pele e mancha.



Figura 4.12 – Imagem original (a); Imagem segmentada incorretamente (b).

4.11 Ferramentas Utilizadas para os Experimentos

A implementação dos algoritmos em estudo foi executada na linguagem Microsoft Visual Studio C++ versão 6. Computador Dual Core, 3 GB de RAM com sistema operacional Windows XP.

Conclusão

Uma abordagem de segmentação automática do melanoma baseada em ferramentas morfológicas foi apresentada neste trabalho.

A partir da formação de duas bases (benigno e maligno) gerou-se a base *ground-truth* que nada mais é do que gerar a segmentação ideal da região da lesão para cada imagem que compõe as duas bases.

Para cada uma das bases de imagens (benigno e maligno) a filtragem morfológica em cor foi usada baseada na ordenação lexicográfica no espaço de cor HSI. Testes exaustivos permitiram definir como melhor seqüência de filtragem o uso de erosão com 3 iterações seguidas de dilatação com 3 iterações com ordenação lexicográfica ISH.

Após a filtragem das imagens definiu-se uma seqüência de processos que enfatizam as cores da lesão do melanoma a fim de realçar a sua geometria perante o fundo, etapa de segmentação e extração de lesões. Para essa etapa, vários testes permitiram definir a limiarização de Renyi a fim de obter melhores resultados para as duas bases de imagens. De acordo com a base de dados de 300 imagens pode-se afirmar que, em 90% das imagens (benignas e malignas), a lesão foi extraída de forma que não prejudicou sua geometria e formato.

Para avaliar a eficiência da abordagem proposta com a abordagem de [CHE05] 12 métricas foram aplicadas para as duas bases de imagens. Concluindo, a abordagem morfológica proposta superou a abordagem modificada com taxas bem superiores de TP ($95,67 \pm 06,17$)% e ($97,22 \pm 04,96$)% para as bases de melanoma benigno e maligno. Essa maior eficiência se reflete não somente em relação às taxas de verdadeiros positivos TP , mas também aos valores das métricas ME , RAE , TN , FP , FN , P , A , R , ER , e também em relação às taxas de desvio padrão.

Este estudo mostra como o uso de operadores morfológicos em cores, tons de cinza e binárias podem eficientemente detectar lesões melanoma. Nota-se que as operações morfológicas em cores evitam a perda de informações. A escolha de operadores morfológicos em cor com base na ordem lexicográfica HSI foi

determinante para filtrar e melhorar as cores do melanoma. A escolha do processo de binarização pela entropia Renyi tem sido importante para melhor detectar a lesão de melanoma.

A presente pesquisa contribuiu principalmente ao processamento de imagens com modelos de cores diferentes como HSI, como também, o uso da morfologia matemática em cor ainda pouco conhecida e aplicada na prática.

Outra contribuição da pesquisa é a geração de imagens *ground-truth*, definidas para cada imagem das duas bases de imagens, a segmentação ideal da região da lesão. No contexto desta pesquisa, a base *ground-truth* consiste em gerar a solução ideal da segmentação da lesão da região do melanoma para todas as imagens usadas nos testes de treino e validação.

Como trabalho futuro sugere-se usar bases internacionais para confrontar com a metodologia proposta na presente pesquisa. Como também, desenvolver técnicas de reconhecimento do melanoma maligno e benigno.

Referências

- [ALC09] J. F. Alcón, C. Ciuhu, W. Kate, A. Heinrich, N. Uzunbajakava, G. Krekels, D. Siem, G. Haan. Automatic Imaging System With Decision Support for Inspection of Pigmented Skin Lesions and Melanoma Diagnosis. *IEEE Journal of Selected Topics in Signal Processing*, Vol. 3, No. 1, February, 2009.
- [ALM98] A. B. Almeida. Usando o Computador para Processamento de Imagens Médicas. *Informática Médica*, v. 1, n. 6, nov/dez. 1998.
- [ART02] A.O. Artero, A. M. G. Tommaselli. A method for edge pixel connection and straight-line segmentation in digital images. *Curitiba*, v.8, n.1, 2002, p. 71-94.
- [BAN94] G. J. F. Banon; J. Barrera. Bases da Morfologia Matemática para a Análise de Imagens Binárias. UFPe. Recife, 1994.
- [BEF10-a] A. T. Beuren, J. Facon, “Segmentação automática do Melanoma benigno: Criação da base ground-truth”, relatório técnico, PPGIa Pontifícia Universidade Católica do Paraná, 2010.
- [BEF10-b] A. T. Beuren, J. Facon, “Segmentação automática do Melanoma maligno: Criação da base ground-truth”, relatório técnico, PPGIa Pontifícia Universidade Católica do Paraná, 2010.
- [BIN95] M. Binder, M. Schwarz, A. Winkler, A. Steiner, A. Kaider, K. Wolff, H. Pehamberger. Epiluminescence microscopy, a useful tool for the diagnosis of pigmented skin lesions for formally trained dermatologists. *Arch Dermatol*, 1995.
- [BIM99] D. A. Bimbo. *Visual Information Retrieval*, Morgan Kaufmann, 1999.
- [BRA00] J. Brand, J. Mason. A comparative assessment of three approaches to pixel-level human skin detection. In *Proc. of the International Conference on Pattern Recognition*, 2000, 1: 1056-1059.
- [BRO01] D. Brown, I. Craw, J. Lewthwaite. A som based approach to skin detection with application in real time systems. In *Proc. of the British Machine Vision Conference*, 2001.
- [CHE05] Y. Cheng. S. Umbaugh. Color-based diagnosis: Clinical Images. *Computer Vision and Image Processing Research Lab@ECE Dept.*, SIUE, <https://www.ee.siue.edu/CVIPtools>, 2005.
- [CHE99] Dchetverikov, Dmitry, Szabó, Zsolt. “A Simple and Efficient Algorithm for Detection of High Curvatures in Planar Curves”, Technical Report, 1999.

- [COM99] M. Comer, E. Delp. "Morphological Operations for Colour Image Processing", *Journal of Electronic Imaging*, Vol. 8, 1999, pp. 279–289.
- [DOU73] D. Douglas, T. Peucker. Algorithms for the reduction of the number of points required to represent a digitized or its caricature. *The Canadian Cartographer* 10(2), 1973, p. 112-122.
- [EST06] Estimativa 2006 - Incidência de Câncer no Brasil. Disponível em: <http://www.inca.gov.br/estimativa/2006/>. Acesso em 10 de nov. 2006.
- [FAC96] J. Facon. "Morfologia Matemática: Teoria e Exemplos". Editor Jacques Facon, Curitiba, 1996.
- [FAC05] J. Facon. *Processamento e Análise de Imagens*. Pontifícia Universidade Católica do Paraná – Curso de Mestrado em Informática aplicada. Agosto, 2005.
- [FAC06] J. Facon. *Técnicas de Processamento Digital de Imagens Aplicadas à Área da Saúde*. XIII Escola Regional de Informática da SBC – Paraná, 2006.
- [FIB04] R. S. Fibiger. *Estudo Comparativo de Técnicas de Visão Computacional para Detecção de Pele Humana*. Campo Grande, 2004. 68 p. Relatório Parcial (Engenharia de Computação) – Centro de Ciências Exatas e Tecnológicas – UCDB, Universidade Católica Dom Bosco, 1994.
- [FRE74] H. Freeman. Computer processing of line-drawing images. *Computing Surveys (CSUR)*, v.6, n. 1, p. 57-97, março, 1974.
- [GAN01] H. Ganster, A. Pinz, R. Röhner, E. Wildling, M. Binder. H. Kittler. Automated Melanoma Recognition. *IEEE Transactions on Medical Imaging*, VOL. 20, NO. 3, MARCH 2001.
- [GAT09] B. Gatos, K. Ntirogiannis, I. Pratikakis. ICDAR 2009 Document Image Binarization Contest (DIBCO 2009). *International Conference on Document Analysis and Recognition*, 2009, 1375–1382.
- [GBM07] GBM - Grupo Brasileiro Multidisciplinar e Multicêntrico de Estudo do Melanoma. Disponível em: <http://www.gbm.org.br/gbm/>. Acesso em 31 jan. 2007.
- [GON92] R.G. Gonzalez, R. Woods. *Digital Image Processing*, Addison Wesley, 1992.
- [HAN01] A. Hanbury. "Lexicographical Order in the HLS Colour Space", Technical Report N-04/01/MM, Centre de Morphologie Mathématique, École des Mines de Paris, 2001.
- [LEE01] T. K. Lee. "Measuring Border Irregularity And Shape Of Cutaneous Melanocytic Lesions", SIMON FRASER UNIVERSITY, 2001.
- [LIU90] H. Liu, M. D. Srinath. Corner detection for chain-code, *Pattern Recognition*, 1990, 23:51-68.

- [LOU01] G. Louverdis, M. Vardavoulia, I. Andreadis, P. Tsalides. A New Approach to Morphological Color Image Processing. *Pattern Recognition*, 2002, 1733-1741, jul. 2001.
- [MAG10] I. Maglogiannis, D. I. Kosmopoulo. Computational vision systems for the detection of malignant melanoma. University of the Aegean, Dept. of Information and Communication Systems Engineering, 83200 Karlovasi, Greece.
- [MAR07] P. R. Martins. Segmentação de Histogramas Multimodais: Simulações, Implementações e Aplicação em Cheques Bancários Brasileiros. Curitiba, 2007. 58p. Dissertação de Mestrado (PPGIA) – Programa de Pós-graduação em Informática Aplicada – PUCPR, Pontifícia Universidade Católica do Paraná, 2007.
- [MAT99] M. F. Mattana, J. Facon. Avaliação por Reconhecimento da Qualidade da Segmentação por Binarização de Cheques Bancários. Curitiba: PUC PR, 1999. 101 p.
- [MIL98] N. Milstein. *Image Segmentation by Adaptative Thersholding*. Technion – Israel Institute of Technology, 1998, 33 p.
- [MOL08] K. Mollersen. Unsupervised Segmentation of Skin Lesions. Department of Mathematics and Statistics University of Tromsø: Tese de mestrado. Novembro, 2008.
- [MOT01] M. Motta, A. L. Amaral, M. N. Pons, E. C. Ferreira, H. Vivier, M. Mota. “Estudo por Análise de Imagem do Comportamento de uma Estação de Tratamento de Efluentes sob Condições Transientes”. *Energías Renovables y Medio Ambiente*, 2001Vol. 9, pp. 49 - 55, , Impreso en la Argentina. ISSN 0328-932X.
- [ORT02] F. Ortiz, F. Torres, E. Juan, N. Cuenca. “Colour Mathematical Morphology for Neural Image Analysis”, *Real-Time Imaging*, 2002, Vol. 8, pp. 455-465.
- [ORT00] F. Ortiz, F. Torres, S. Puente, F. Candelas, P. Gil. “Use of the Hue / Saturation / Intensity Colour Spaces to the Morphological Processing of Colour Images”, In: *Proceedings of the 1st International Conference in Graphics and Image Processing*, Saint-Etienne, France, 2000, pp. 219–224.
- [OTS79] N. Otsu. *A Threshold Selection Method from Gray-level Histogram*, *IEEE Transactions*, 1979, p. 62-66.
- [PET97] A. Peters. “Mathematical Morphology for Anglevalued Images”, In: *Proceedings of SPIE, Non-Linear Image Processing VIII*, 1997, Vol. 3026, pp. 84–94.
- [PLA00] K. N. Plataniotis, A. N. Venetsanopoulos. *Color Image Processing and Applications*. Springer Verlag, Berlin, ISBN 3-540-66953-1, August 2000.

- [PNN01] D. Drzewiecki. Probabilistic NeuralNetworkFramework For Detection of Malignant Melanoma. Dept. of Mathematical Modelling, build. 321, Technical University of Denmark, SK-2800 Lyngby, Denmark, 2001.
- [PON97] M. N. Pons. H. Vivier, J. A. Dodds. Particle shape characterization using morphological descriptors, Part.Syst. Charact., 1997, 14, 272-277.
- [RIC01] D. Richard, P. Hart, D. Stork. Pattern Classification, 2nd Ed., Wiley, 2001, ISBN: 0-471-05669-3.
- [ROB65] L. G. Roberts. Machine Perception of the three-dimensional solids, In: Optical and Electro-optical Information Processing, MIT Press, 1965.
- [RUS95] J. C. Russ. The image processing handbook. 2e édition, CRC Press, Boca Raton, 1995.
- [SAN98] S. Sangwine, R. Horne. The Colour Image Processing Handbook. London: Chapman & Hall, 1998.
- [SAH97] P. Sahoo, C. Wilkins, J. Yeager. "Threshold Selection Using Renyi's Entropy", Pattern Recognition Vol 30, No 1, Pp 71-84 (1997).
- [SAN01] B. Sankur, M. Sezgin. Selection of Thresholding methods for non-destructive testing applications. Istanbul Technical University, Maslak, Istanbul, Turkey. 2001.
- [SER88] J. Serra. Mathematical Morphology: Theoretical Advances. New York: Academic Press, 1988, Vol. 2.
- [SET09] G. Sethumadhav, S. Sankaran. Segmentation using Six Sigma Threshold on Spectral Bands of Malignant Melanoma. Proceedings of the International MultiConference of Engineers and Computer Scientists 2009 Vol I IMECS 2009, March 18 - 20, 2009, Hong Kong.
- [SIL09] M. Silveira et. al. Comparison of Segmentation Methods for Melanoma: Diagnosis in Dermoscopy Images. IEEE JOURNAL OF SELECTED TOPICS IN SIGNAL PROCESSING, VOL. 3, NO. 1, FEBRUARY 2009.
- [SOB03] J. L. Sobral. Visão por computador: Processamento de imagens a cores, 2003.
- [SOL05] C. D. O. Solana. Reconstrução Digital de Documentos por Aproximação Poligonal. Curitiba, 2005. 107p. Dissertação de Mestrado (PPGIA) – Programa de Pós-graduação em Informática Aplicada – PUCPR, Pontifícia Universidade Católica do Paraná, 2005.
- [SOI99] P. Soille. Morphological Image Analysis: Principles and Applications. Berlin: Springer-Verlag, 1999.
- [STA07] R. Stanley, W. V. Stoecker, R. Moss. *A relative color approach to color discrimination for malignant melanoma detection in dermoscopy images.*

Skin Research and Technology 2007; 13: 62–72. Printed in Singapore _ All rights reserved.

- [STO94] W. Stolz. The ABCD rule of derma-toscopy. High prospective value in the diagnosis of doubtful melanocytic skin lesions. *Journal American Academy Dermatology*. 1994 Apr;30(4):551-9.
- [TOB07] M. C. Tobar, C. Platero, G. Ansensio, P. González, J. Sanguino, M. . Poncela. “Teoria e Implementación de Ordenes Totales en los Espacios de Color y Morfología Digital”, XXVIII Jornadas de Automática, Huelva, 2007.
- [TRA92] P. Trahanias, A. Venetsanopoulos. “Colour Edge Detectors Based on Multivariate Ordering”, In: *Proceedings of SPIE, Visual Communications and Image Processing’92*, Petros Maragos, University of Toronto, 1992, Vol. 1818, pp. 1396–1407.
- [TRA10] J. Tran. Segmentação de Imagens utilizando Dermatológica Mistura Modelos e Markov Random Fields. Supervisor: Dr. David Squire. 2010.
- [TVI07] Testez-vous en images. ONCOPEAU. Disponível em <http://info-melanome.net/pub/en_savoir_plus/testez_vous_en_images/>. Acesso em 02 de fev. 2007.
- [VEZ03] V. Vezhnevets, V. Sazonov, A. Andreeva. A Survey on Pixel-Based Skin Color Detection Techniques. 2003, *Proc. of Graphicon* 85–92.
- [YON04] Y. Yong, Z. Chongxun, L. Pan. A novel Fuzzy CMeans Clustering Algorithm for Image Thresholding. *Measurement Science Review*, vol. 4, Section 1, 2004.
- [ZHO09] H. Zhou, G. Schaefer, A. Sadka, E. Celebi. Anisotropic Mean Shift Based Fuzzy CMeans Segmentation of Dermoscopy Images. *IEEE journal of selected topics in signal processing*, vol. 3, no. 1, february 2009.