

UNIVERSIDADE ESTADUAL PAULISTA
“Júlio de Mesquita Filho”

Pós-Graduação em Ciência da Computação

Roberta Barbosa Oliveira

**Método de detecção e classificação de lesões de pele em
imagens digitais a partir do modelo Chan-Vese e máquina
de vetor de suporte**

UNESP

2012

Roberta Barbosa Oliveira

**Método de detecção e classificação de lesões de pele em
imagens digitais a partir do modelo Chan-Vese e máquina
de vetor de suporte**

Orientador: Prof. Dr. Aledir Silveira Pereira

Dissertação apresentada como parte dos requisitos para obtenção do título de Mestre em Ciência da Computação, junto ao Programa de Pós-Graduação em Ciência da Computação, Área de Concentração – Computação Aplicada, do Instituto de Biociências, Letras e Ciências Exatas da Universidade Estadual Paulista “Júlio de Mesquita Filho”, Campus de São José do Rio Preto.

UNESP

2012

Oliveira, Roberta Barbosa.

Método de detecção e classificação de lesões de pele em imagens digitais a partir do modelo Chan-Vese e máquina de vetor de suporte para imagens de lesões de pele / Roberta Barbosa Oliveira. - São José do Rio Preto: [s.n.], 2012.

134 f. : il. ; 30 cm.

Orientador: Prof. Dr. Aledir Silveira Pereira

Dissertação (mestrado) - Universidade Estadual Paulista, Instituto de Biociências, Letras e Ciências Exatas

1. Processamento de imagens. 2. Filtro de difusão anisotrópica. 3. Modelo Chan-Vese. 4. Máquina de vetor de suporte. I. Pereira, Aledir Silveira. II. Universidade Estadual Paulista, Instituto de Biociências, Letras e Ciências Exatas. III. Título.

CDD – 004.932

Roberta Barbosa Oliveira

**Método de detecção e classificação de lesões de pele em
imagens digitais a partir do modelo Chan-Vese e máquina
de vetor de suporte**

Dissertação apresentada como parte dos requisitos para obtenção do título de Mestre em Ciência da Computação, junto ao Programa de Pós-Graduação em Ciência da Computação, Área de Concentração – Computação Aplicada, do Instituto de Biociências, Letras e Ciências Exatas da Universidade Estadual Paulista “Júlio de Mesquita Filho”, Campus de São José do Rio Preto.

BANCA EXAMINADORA

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

Prof. Dr. Aparecido Nilceu Marana
UNESP – Bauru

Prof. Dr. Evandro Luis Linhari Rodrigues
USP – São Carlos

São José Do Rio Preto, 24 de agosto de 2012

Dedico este trabalho

Aos meus pais, Selma e Batista, e a minha irmã Renata, pelo amor, carinho, amizade, dedicação, compreensão e incentivo para a conquista dos meus objetivos.

AGRADECIMENTOS

Este trabalho representa a concretização de objetivos e sonhos, mediante muito esforço e dedicação. Quero aproveitar a oportunidade para agradecer a todos que estiveram ao meu lado neste momento importante da minha vida, que contribuíram direta ou indiretamente para a realização deste trabalho.

Primeiramente agradeço à Deus por estar sempre presente em minha vida, me ajudar a superar os momentos difíceis, me dar forças para vencer os obstáculos. Também por me proporcionar tanta felicidade, tantas oportunidades e, acima de tudo, por ter me dado saúde e uma família e amigos maravilhosos.

Aos meus pais pelo carinho, confiança, compreensão, apoio financeiro, estrutura e educação que me deram, e por me ensinarem a ser uma pessoa melhor a cada dia. A minha irmã que me incentivou e me ajudou muitas vezes no desenvolvimento deste trabalho. E também a todos os meus familiares (avós, tios e primos) pelo apoio e compreensão no meu afastamento para o desenvolvimento desse trabalho.

Ao meu orientador, Dr. Aledir Silveira Pereira, por me receber e acreditar em meu trabalho, me dar a oportunidade de desenvolver esta pesquisa e por sempre estar disposto a me passar conhecimento. Serei eternamente grata pela sua atenção, dedicação, supervisão e incentivo para o desenvolvimento do mesmo. Além de ser um excelente orientador, que se tornou um exemplo para mim, também é como um pai e amigo, pela preocupação, compreensão, conselhos e estímulos para continuar a buscar meus objetivos.

Ao Alex F. de Araujo e aos professores da UNESP, Dr. Norian Marranghello e Dr. Rodrigo Capobianco Guido, e ao professor da FEUP, Dr. João Manuel R. S. Tavares, pela atenção, disponibilidade, as contribuições ao longo do trabalho e a colaboração nos artigos publicados.

Meus agradecimentos ao doutor Ricardo Baccaro Rossetti, dermatologista da clínica Derm de São José do Rio Preto, pelo tempo disponibilizado, pela discussão sobre os conceitos de dermatologia, as sugestões, contribuições e também as avaliações dos resultados obtidos com o desenvolvimento deste trabalho.

Aos professores Dr. Aparecido Nilceu Marana e Dr. Evandro Luis Linhari Rodrigues por aceitarem participar da banca de defesa desta dissertação e contribuírem para aprimorar o

trabalho. Ao professor da UNESP de Bauru João Fernando Marar pelas sugestões e colaborações no exame de qualificação que permitiu melhorar este trabalho. Aos professores Maurílio Boaventura e Manoel Ferreira Borges Neto e a todos os outros professores da UNESP que me receberam com carinho, que contribuíram para o meu trabalho ou foram meus professores nesse período, que influenciaram no meu amadurecimento pessoal e profissional.

Ao meu orientador da graduação professor Marcelo Luis Murari, por ter acreditado no meu potencial e me incentivado a cursar o mestrado. Esse professor é um dos principais responsáveis por eu estar concretizando um dos meus sonhos.

À Universidade Estadual Paulista (UNESP), campus de São José do Rio Preto (IBILCE), pela estrutura e espaço oferecido para o desenvolvimento desta pesquisa e também pelo apoio financeiro na participação em congresso.

Sou grata a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo suporte financeiro, concedido por meio da bolsa de mestrado.

Agradecimento especial aos meus colegas de laboratório Carlos e Rafael, que se tornaram meus amigos. Vou guarda-los com carinho no meu coração, que não só pelas contribuições no desenvolvimento do meu trabalho, mas, principalmente, pelo companheirismo, compreensão, conselhos, momentos de descontração e diversão dentro e fora do ambiente de trabalho.

Aos meus companheiros dessa caminhada Claudia, Padma, Otávio, Jonathan, Alexandre, Danilo, e Tiago, amizades construídas ao longo deste período e que também contribuíram para o desenvolvimento deste trabalho.

Aos funcionários da UNESP, Adriana, Marta, Olga, Getúlio, Silvia Emiko, Silvia Mara e Alex, pela atenção e carinho com que me receberam e pelo suporte oferecido neste período.

Agradecimento especial para meus amigos Dara, Marielle, Egberto e Alinne que foram muito importante na minha vida nesse período e que sempre estiveram ao meu lado nos momentos bons e ruins.

Aos meus novos amigos Raphael, Gabriel, André Cardoso, Juliana, Gisele, Flávia, Silmara, Edicléia, Roseli, Rose, Nicolly, Cida, Carol, Lara, Leandro, Marcela, André Paiva e Najara, que me apoiaram, compreenderam a minha ausência e fizeram os meus dias mais felizes.

“Os sonhos não determinam o lugar em que você vai estar, mas produzem a força necessária para tirá-lo do lugar em que está.”

Augusto Cury

RESUMO

Neste trabalho desenvolve-se um método computacional capaz de auxiliar os médicos dermatologistas no diagnóstico de lesões de pele por meio de imagens digitais. Com este método pretende-se auxiliar o dermatologista a classificar as lesões de pele utilizando a regra ABCD (Assimetria, Borda, Cor e Diâmetro) e análise de textura, bem como identificar as lesões: nevos melanocíticos, ceratose seborréica e melanoma. Para tanto, utiliza-se a técnica de difusão anisotrópica para efetuar o pré-processamento das imagens com o objetivo de eliminar os ruídos. Para a segmentação das lesões foi utilizado o método de contorno ativo sem bordas (modelo Chan-Vese). O modelo Chan-Vese é baseado na técnica de crescimento de região Mumford-Shah, para segmentar as imagens, e no modelo de contorno ativo *Level Set*, que possibilita a mudança topológica da curva sobreposta à imagem. Na imagem segmentada obtida é aplicado um filtro morfológico para eliminar orifícios e ruídos externos do objeto, como também para suavizar sua borda. As características de assimetria, borda e cor da regra ABCD e a característica de textura são extraídas conforme as informações das imagens segmentadas. As características extraídas das imagens são utilizadas como entradas para o classificador SVM (Máquina de Vetor de Suporte), que é uma técnica baseada em aprendizado estatístico utilizada para caracterizar e classificar as lesões de pele.

Palavras-chave: Lesões de Pele, Filtro de Difusão Anisotrópica, Modelo Chan-Vese, Máquina de Vetor de Suporte.

ABSTRACT

A computational method to assist dermatologists in the diagnosis of skin lesions from digital images has been developed in this work. This method is intended to assist the dermatologist to classify the skin lesions using the ABCD rule (Asymmetry, Border, Color and Diameter) and texture analysis, as well as to identify lesions: melanocytic nevi, seborrheic keratosis and melanoma. Anisotropic diffusion technique is used to preprocess the images to remove noise. The active contour model without edges (Chan-Vese) is used for the segmentation of the lesions. The Chan-Vese model is based on the Mumford-Shah region growing technique, to segment the images, and the Level Set active contour model, which allows topological change of the curve superimposed on the image. A morphological filter is applied to the segmented image to eliminate holes and external noise from the object, as well as to smooth its edges. The asymmetry, border and color features of the ABCD rule and texture feature are extracted according to the information from segmented images. The extracted features from images are used as inputs to the SVM (Support Vector Machine) classifier, which is a technique based on statistical learning, used to characterize and classify the skin lesions.

Keywords: *Skin lesions, Anisotropic Diffusion Filter, Chan-Vese Model, Support Vector Machine.*

LISTA DE FIGURAS

Figura 2.1	Estrutura da pele	11
Figura 2.2	Nevos melanocíticos	14
Figura 2.3	Nevos	15
Figura 2.4	Ceratose seborréica	16
Figura 2.5	Nevos congênitos	17
Figura 2.6	Nevo atípico	18
Figura 2.7	Cânceres cutâneos não melanoma	19
Figura 2.8	Melanoma extensivo superficial	21
Figura 2.9	Imagens dermatoscópicas	25
Figura 3.1	Etapas do processamento de imagens digitais	28
Figura 3.2	Suavização utilizando difusão anisotrópica	33
Figura 3.3	Exemplo de limiarização	36
Figura 3.4	Representação da curva	39
Figura 3.5	O termo apropriado para possíveis posições da curva	42
Figura 3.6	Resultado da aplicação do modelo Chan-Vese	45
Figura 3.7	Composição do triângulo de Sierpinski	46
Figura 4.1	Representação de aprendizado supervisionado	49
Figura 4.2	Exemplos de classificação binária	50
Figura 4.3	Distância entre dois hiperplanos	53
Figura 4.4	Conjunto de dados não lineares	55
Figura 5.1	Estrutura do método desenvolvido	58
Figura 5.2	Banco de imagens	60
Figura 5.3	Estruturada das etapas do pré-processamento	61
Figura 5.4	Resultado da aplicação do filtro de difusão anisotrópica	62
Figura 5.5	Aplicação de difusão anisotrópica com o número de iterações automático	64
Figura 5.6	Estruturada das etapas da segmentação	65
Figura 5.7	Definição da curva sobre a imagem suavizada	66
Figura 5.8	Resultado da aplicação do modelo Chan-Vese	68

Figura 5.9	Estrutura do método automático para definição da curva no modelo Chan-Vese	69
Figura 5.10	Estrutura das etapas do pós-processamento	70
Figura 5.11	Aplicação dos filtros morfológicos	71
Figura 5.12	Definição do contorno e extração da lesão de pele	72
Figura 5.13	Representação da maior diagonal	73
Figura 5.14	Diagrama do método de extração das características	74
Figura 5.15	Exemplos de perpendiculares à diagonal maior para extração das características de assimetria	75
Figura 5.16	Vetor de característica para representar a assimetria das lesões	76
Figura 5.17	Representação do contorno de uma lesão de pele	77
Figura 5.18	Representação da característica de borda	78
Figura 5.19	Exemplo de produto vetorial	79
Figura 5.20	Exemplo de ponto de inflexão	79
Figura 5.21	Vetor de característica para representar a borda das lesões	80
Figura 5.22	Área lesionada extraída	81
Figura 5.23	Vetor de característica para representar a cor das lesões	82
Figura 5.24	Características da textura das lesões de pele	83
Figura 5.25	Vetor de característica para representar a textura das lesões	84
Figura 5.26	Representação da classificação da assimetria	85
Figura 5.27	Representação da classificação da borda	85
Figura 5.28	Representação da classificação da cor	86
Figura 5.29	Representação da classificação de textura	86
Figura 5.30	Classificação das lesões de pele	87
Figura 6.1	Resultado da comparação entre métodos de segmentação	89
Figura 6.2	Resultados das técnicas para segmentação das lesões de pele	94
Figura 6.3	Resultados da aplicação do modelo Chan-Vese com lesões detectadas e não detectadas	95
Figura 6.4	Resultados da classificação de assimetria por diferentes vetores de características utilizando o <i>kernel</i> de intersecção por histograma	98
Figura 6.5	Resultados da classificação de borda por diferentes vetores de características utilizando o <i>kernel</i> de intersecção por histograma	100
Figura 6.6	Resultados da classificação de cor por diferentes vetores de características utilizando o <i>kernel</i> de intersecção por histograma	101

Figura 6.7	Resultados da classificação de textura por diferentes vetores de características utilizando o <i>kernel</i> de intersecção por histograma .	103
Figura 6.8	Vetor de característica para representar as características assimetria, borda, cor e textura	104
Figura 6.9	Resultados da classificação das lesões de pele utilizando o <i>kernel</i> de interseccção por histograma	105
Figura 6.10	Exemplo de lesões com características que não seguem totalmente a regra ABCD	106

LISTA DE TABELAS

Tabela 2.1	Informações básicas sobre os principais tipos clínicos de melanoma	20
Tabela 2.2	Descrição e demonstração da regra ABCDE	23
Tabela 2.3	Imagens de nevos e melanomas diferenciados pela regra ABCDE .	24
Tabela 5.1	Número de iterações retornado pela diferença de pontos dos operadores Roberts e Prewitt	64
Tabela 6.1	Demonstração dos resultado obtidos entre os métodos de segmentação	90
Tabela 6.2	Resultados obtidos pelos métodos de segmentação	93
Tabela 6.3	Resultado de trabalhos desenvolvidos para segmentação de lesões de pele	96
Tabela 6.4	Resultados da classificação de assimetria utilizando o <i>kernel</i> gaussiano e a intersecção por histograma	97
Tabela 6.5	Resultados da classificação de borda utilizando o <i>kernel</i> gaussiano e a intersecção por histograma	99
Tabela 6.6	Resultados da classificação de cor utilizando o <i>kernel</i> gaussiano e a intersecção por histograma	101
Tabela 6.7	Resultados da classificação de textura utilizando o <i>kernel</i> gaussiano e a intersecção por histograma	102
Tabela 6.8	Resultados dos trabalhos desenvolvidos para a classificação das lesões de pele	104
Tabela 6.9	Resultados da classificação das lesões de pele	105
Tabela 6.10	Resultados dos trabalhos desenvolvidos para a classificação das lesões de pele	107

LISTA DE SIGLAS

ABCD	Assimetria, Borda, Cor e Diâmetro
ABCDE	Assimetria, Borda, Cor, Diâmetro e Evolução
BCM	Método <i>box-counting</i>
CART	Classification and Regression Trees (Árvore de Classificação e Regressão)
CCNM	Câncer cutâneo não melanoma
CBC	Carcinoma basocelular
CEC	Carcinoma espinocelular
EDP	Equação Diferencial Parcial
GML	<i>Gaussian Maximum Likelihood</i> (Probabilidade Máxima Gaussiana)
HSI	<i>Hue, Saturation and Intensity</i> (Matiz, Saturação e Intensidade)
HVC	<i>Hue, Value and Chroma</i> (Matiz, Valor e Pureza da cor)
INCA	Instituto Nacional de Câncer
K-NN	<i>K-Nearest Neighbors</i> (K vizinhos mais próximos)
LWL	<i>Locally Weighted Learning</i> (Aprendizado Ponderado Localmente)
MES	Melanoma extensivo superficial
MRL	<i>Multinomial Logistic Regression</i> (Regressão Logística Multinomial)
PDI	Processamento Digital de Imagens
RBF	<i>Radial-Basis Function</i> (Função de Base Radial)
RGB	<i>Red, Green e Blue</i> (Vermelho, Verde e Azul)
RNA	Rede Neural Artificial
SD	Small Difference
SNNS	<i>Stuttgart Neural Network Simulator</i> (Simulador de Redes Neurais da Universidade de Stuttgart)
SVM	<i>Support Vector Machine</i> (Máquina de Vetores de Suporte)
VC	Dimensão de Vapnik-Chervonenkis

SUMÁRIO

1 INTRODUÇÃO	1
1.1 Objetivos	2
1.2 Publicações	3
1.3 Estado da arte	3
1.4 Contribuições do trabalho	8
1.5 Organização do trabalho	9
2 LESÕES DE PELE	10
2.1 Estrutura da pele	10
2.2 Tipos de lesões de pele	11
2.2.1 Lesões benignas	12
2.2.2 Lesões suspeitas	16
2.2.3 Lesões malignas	18
2.3 Diagnóstico dermatológico	21
2.3.1 Métodos	21
2.3.2 Tratamento	26
3 TÉCNICAS DE PROCESSAMENTO DIGITAIS DE IMAGENS	27
3.1 Filtro de difusão anisotrópica	30
3.2 Operadores morfológicos	34
3.3 Limiarização	34
3.3.1 Método de OTSU	35
3.4 Funcional de Mumford-Shah	37
3.5 Modelos de contorno ativo <i>Level Set</i>	38
3.6 Modelo Chan-Vese	40
3.7 Dimensão fractal	45
4 MÁQUINA DE VETOR DE SUPORTE	48
4.1 Aprendizado da máquina	49
4.2 Aprendizado estatístico	50
4.3 SVMs lineares	52
4.4 SVMs não lineares	55
4.5 Funções <i>Kernels</i>	56
5 MÉTODO DESENVOLVIDO	58
5.1 Aquisição de imagens	59
5.2 Pré-processamento	61
5.3 Segmentação	64
5.4 Pós-processamento	70

5.5 Extração das características	72
5.5.1 Descritor de assimetria	74
5.5.2 Descritor de borda	77
5.5.3 Descritor de cor	81
5.5.4 Descritor de textura	82
5.6 Classificação inteligente	84
5.6.1 Classificação de assimetria	84
5.6.2 Classificação de borda	85
5.6.3 Classificação de cor	86
5.6.4 Classificação de textura	86
5.6.5 Classificação das lesões de pele	86
6 RESULTADOS E DISCUSSÕES	88
6.1 Avaliação de técnicas de segmentação para detecção de lesões de pele	88
6.2 Classificação inteligente para lesões de pele	96
6.2.1 Assimetria	97
6.2.2 Borda	99
6.2.3 Cor	100
6.2.4 Textura	102
6.2.5 Lesões de pele	104
CONCLUSÕES	109
TRABALHOS FUTUROS	112
REFERÊNCIAS BIBLIOGRÁFICAS	113

1 INTRODUÇÃO

Há um grande interesse no desenvolvimento de sistemas computacionais para análise de lesões de pele que auxiliam o dermatologista na prevenção contra o desenvolvimento de lesões malignas, considerando o aumento de casos de câncer de pele que vem ocorrendo. De acordo com a estimativa de incidência de câncer no Brasil, realizada pelo Instituto Nacional de Câncer (INCA) [16] para ano de 2012 e também em 2013, 518.510 casos novos de câncer são esperados. Os tipos mais incidentes serão os cânceres de pele, próstata, mama feminina, cólon e reto, pulmão, estômago e colo do útero.

O câncer de pele corresponde a 25% dos tumores malignos registrados no país. Os cânceres de pele do tipo não melanoma, tais como os basocelulares e espinocelulares, são os tumores de maior incidência na população, sendo estimados 134.170 casos novos no período destinado. O melanoma apesar de ser um dos tipos de câncer menos frequente, representando apenas 4% dos casos (6.230 casos novos), é o tumor de pele mais agressivo, que apresenta um alto índice de mortalidade [32]. Mas quando diagnosticado precocemente e tratado corretamente, a cura dos pacientes com este tipo de câncer pode chegar a 69% na média mundial [15].

O aparecimento de câncer na pele pode ocorrer por diversas razões, uma delas é a exposição excessiva ao sol, por isso é necessário uma ação preventiva contra esse fator. Mas também é necessária uma atenção maior em relação aos nevus (pintas), que são lesões benignas, pois 50% dos melanomas podem se originar de pintas ou manchas [55]. Também deve ressaltar-se que o melanoma pode se assemelhar a uma pinta quando está no seu estado inicial. Outra lesão benigna que é importante analisar é ceratose seborréica, que em alguns casos, seu diagnóstico é confundido com melanoma, sendo importante a diferenciação entre estes dois tipos de lesão.

Este grande aumento nos casos de câncer tem motivado a pesquisa e o desenvolvimento de métodos computacionais para auxiliar os dermatologistas no diagnóstico de lesões de pele, com o intuito de analisar as lesões benignas para evitar o seu desenvolvimento, ou diagnosticar as lesões malignas em seu estágio inicial, para que possam ser elaborados planos de tratamento adequados e com maior possibilidade de cura.

No diagnóstico dermatológico, as lesões são examinadas clinicamente, utilizando primeiramente a técnica de análise das características ABCD (assimetria, borda, cor e diâmetro) e textura, para então diagnosticá-las e tratá-las [62]. Para facilitar este processo, os dermatologistas podem dispor de sistemas computacionais, que analisam as características das lesões de forma mais precisa, utilizando imagens digitais, obtidas pelo mesmo, para auxiliar no seu diagnóstico.

Para a construção destes sistemas são muito utilizadas técnicas de processamento de imagens digitais e sistemas inteligentes, tais como, difusão anisotrópica [10], para diminuir o efeito dos ruídos nas imagens, o modelo Chan-Vese [20] para identificar a área doente e a máquina de vetor de suporte (SVM) [17] para caracterizar as lesões de pele. O uso destas técnicas possibilitam uma análise mais rápida e informações mais precisas sobre as características das lesões e por essa razão são temas de diversos trabalhos para detecção e classificação de lesões de pele [1, 5, 11, 19, 63, 64, 67].

1.1 Objetivos

O objetivo principal deste trabalho é o desenvolvimento de uma método para detecção e caracterização de lesões de pele dos tipos: melanoma, nevo melanocítico e ceratose seborréica, a partir de imagens fotográficas para auxiliar o dermatologista no seu diagnóstico.

Outro objetivo é disponibilizar aos dermatologistas informações sobre as principais características das lesões de pele, segundo a regra ABCD (Assimetria, Borda, Cor e Diâmetro) e textura. Para a caracterização e classificação é proposta a utilização da máquina de vetor de suporte (SVM), que é uma técnica baseada em aprendizado estatístico, utilizada para o reconhecimento de padrões em imagens.

1.2 Publicações

Durante o desenvolvimento do presente trabalho, foram publicados trabalhos em revista, livro e alguns congressos. Os artigos são voltados para a segmentação e classificação de lesões de pele, são eles: Caracterização de lesões de pele em imagens digitais a partir da máquina de vetor de suporte [47]; Classificação de assimetria em lesões de pele por meio de imagens usando máquina de vetor de suporte [44]; Extração de contornos de lesões de pele utilizando difusão anisotrópica e modelo de contorno ativo sem bordas [43]; Caracterização de textura em imagens de lesões de pele por meio da máquina de vetor de suporte [45]; Extração de características de lesões de pele a partir de imagens [46]; Análise e caracterização de lesões de pele para auxílio ao diagnóstico médico [7]; Uma metodologia híbrida para segmentação de lesões de pele [8].

1.3 Estado da arte

Devido ao aumento na incidência de câncer de pele, vem crescendo o interesse em métodos para análise de lesões de pele com o intuito de prevenir o desenvolvimento de câncer ou o seu diagnóstico precoce. Há diversos trabalhos que propõem métodos automáticos para auxiliar o dermatologista nos seus diagnósticos, utilizando técnicas de processamento de imagens e sistemas inteligentes para detectar e classificar vários tipos de lesões de pele.

Beuren, Pinheiro e Jacon [14] propõem uma abordagem morfológica para segmentação de imagens de melanoma. A filtragem das imagens, para eliminar os pelos e outros ruídos, é realizada por meio de um processo morfológico de abertura (erosão seguido de dilatação) pela ordenação HSI (Hue, Saturation e Intensity) com elemento estruturante quadrado 7x7. Depois é aplicado o método de limiarização global, onde as imagens filtradas por cor são binarizadas. Para o preenchimento de lacunas na região segmentada e remoção dos ruídos externos é utilizada a abertura binária, com elemento estruturante quadrado 7x7. Essa proposta alcançou um resultado animador para a segmentação de lesões benignas e malignas, avaliado em 200 imagens. Obteve 95,26% de precisão para lesões benignas e 92,62% para lesões malignas.

Um método para detecção de borda em imagens dermatoscópicas de lesões melanocíticas e não melanocíticas é proposto por Norton e colaboradores [42]. Os *pixels* mais

escuras próximos a borda são identificados conforme seu valor de nível de cinza, para que essa região seja pré-processada, utilizando uma elipse como elemento estruturante no processo de dilatação, com o objetivo de incluir as áreas claras da borda e eliminar os *pixels* que não fazem parte dela. Para detectar a borda, são feitos dois tipos de segmentação: da lesão geral e da região com reflexo. A segmentação da lesão geral é realizada em três etapas: I) segmentação da lesão, II) correção da iluminação não uniforme e III) redução de ruídos. Para segmentar a lesão, primeiramente é realizada a sua suavização para a redução de ruídos, por meio de uma filtragem utilizando uma elipse. Em seguida é feita a binarização pelo limiar de OTSU no canal G do modelo de cor RGB (Red, Green e Blue), para manter as regiões com menos intensidades. Para segmentar as imagens com iluminação não uniforme, ou seja, com áreas mais escuras (sombras), é calculada a área de cada objeto encontrado no processo de segmentação, para verificar se a maior área corresponde a 1/3 ou 2/3 do tamanho total da imagem. Neste caso, o efeito de sombra é eliminado, aplicando a equalização de histograma adaptativo de contraste limitado, e depois é feita novamente a segmentação da lesão a partir da imagem com a iluminação corrigida. Na etapa de remoção de ruído são aplicadas as operações de abertura seguida do fechamento, utilizando elemento estruturante em forma de elipse. Depois é realizada uma dilatação usando um octogonal, como elemento estruturante. Já para a segmentação de imagens com reflexos na região da lesão, foi criado um método para solucionar este problema, que realiza a binarização, onde o limiar é o valor do desvio padrão referente a média das intensidades da imagem de fundo no canal B, para segmentar somente as regiões de reflexos, pois possuem intensidades mais altas comparadas com as da pele saudável. Em seguida passa pelo mesmo processo morfológico para que essa região seja unida com a imagem da segmentação da lesão geral. A avaliação deste método foi baseada na precisão, com 84,5% para 107 imagens de lesões não melanocíticas e 93,9% para 319 imagens de lesões melanocíticas.

Cudek et. al. [22] apresentam um método para identificar lesões de pele a partir de imagens digitais usando a regra ABCD. Foram utilizadas 53 imagens de lesões de pele, que foram giradas em 90, 180 e 270 graus, formando um conjunto de 212 imagens, que incluem nevo benigno, nevo azul, nevo suspeito (displásico) e melanoma, que foram transformadas em níveis de cinza. A técnica de equalização de histograma foi utilizada para aumentar o contraste das imagens, e para a redução de ruídos foi aplicado o filtro de média. Para segmentar as lesões de peles os autores propuseram uma modificação do limiar OTSU, pois foi analisado que este método pode, em alguns casos, desconsiderar partes que fazem parte da lesão; para solução do problema foi proposto o SD (Small Difference) que permite procurar

pixels na vizinhança que podem ser classificados como parte da lesão. A segmentação proposta obteve 92% de detecção correta. Em 5% das imagens houve a necessidade de informar manualmente o limiar e em 3% dos casos foi incorreto o seu reconhecimento.

Zhao et al [66] propõem um modelo de Chan-Vese sem reinicialização, para segmentar imagens médicas. Este método melhorado elimina completamente a reinicialização do modelo Chan-Vese tradicional, que causa um aumento no tempo de processamento, afetando o resultado da segmentação ou no caso de pouca reinicialização pode causar sua má qualidade. Também diminui o número de iterações, melhorando o resultado da segmentação. Primeiramente é calculada uma função *Level Set* inicial que determina um contorno inicial sobre a imagem original, não sendo necessária uma posição específica (pode ser em qualquer local da imagem). Sua evolução ocorre conforme uma implementação numérica utilizando gradiente de rotação e invariância e operadores divergentes na direção horizontal, vertical e diagonal. É feita a distribuição de nível de cinza conforme a adaptação do método de Chan-Vese, onde a imagem segmentada por região se mostrou ter maior habilidade de distinguir mais detalhes do que o Chan-Vese tradicional. O método foi testado em imagens médicas reais, tais como de cérebro, obtidas pelo instrumento CT, e imagens microscópicas de células, apresentando ótimos resultados, onde as fronteiras foram muito bem representadas, mesmo estando bastante borradas, devido à quantidade de ruídos ou com pouco contraste.

Araujo [6] desenvolveu um método para extração e caracterização de lesões de pele, que utiliza difusão anisotrópica para suavizar a imagem e eliminar parcialmente os ruídos, preservando as bordas para a extração dos contornos. Para definir a quantidade de iterações da difusão, foi calculado um número aproximado a partir da diferença dos pontos retornados pelos operadores de Roberts e Prewitt [30]. A partir da imagem suavizada é realizada a segmentação por crescimento de região, utilizando a técnica de Mumford-Shah [40] para cada componente RGB. As imagens foram binarizadas para separar a região doente da região saudável, que possibilitou a extração do contorno inicial da lesão, sendo refinado pelas técnicas de *Watershed* [13] e contorno ativo tradicional [33]. Além da detecção do contorno, foram extraídas as características das lesões de acordo com a regra ABCD, para o diagnóstico inicial das lesões. O método para segmentação foi testado em 40 imagens, sendo lesões atípicas, não malignas e malignas. O contorno foi definido como bom em 91,3% das imagens.

Um sistema automático para análise de lesões pigmentadas e diagnóstico de melanoma a partir de imagens adquiridas por câmera digital foi descrito por Alcón et. al. [3]. A segmentação é realizada utilizando o método de limiarização pelo limiar OTSU. A

classificação das lesões em nevos (45 imagens) ou melanoma (107 imagens) é adquirida conforme a extração das características ABCD, totalizando 55 características. O sistema inclui um componente de apoio à decisão que combina o resultado da classificação das imagens com conhecimento, tais como as informações do paciente. Essa combinação obteve 86% de precisão, 94% de sensibilidade e 68% de especificidade na classificação das lesões utilizando seleção de características baseada em correlação e modelo de regressão logística linear.

Um sistema automático para diagnosticar lesões cutâneas, a partir de imagens dermatoscópicas, sendo a classificação obtida pelo método de limiarização, conforme as características da regra ABCD, foi desenvolvido por Rosado [53]. A segmentação é baseada na análise do histograma da imagem, conforme a distribuição de intensidades dos seus pixels. Foram utilizadas 44 imagens, para classificar se a lesão é suspeita ou não de ser um melanoma, onde se obteve 70% de acerto para as lesões não suspeitas e 73% para as lesões suspeitas, por meio do classificador limiarização. Também foi avaliada a eficácia dos algoritmos para a classificação de cada característica da regra ABCD, utilizando o classificador K-vizinhos mais próximos (K-NN). No caso da assimetria, o algoritmo classificou corretamente 75%, 33% e 80% das imagens completamente simétricas, assimétrica em relação a um eixo principal e assimétrica considerando os dois eixos principais a partir do ponto central da lesão, respectivamente. O resultado obtido para a extração da borda se mostrou inadequado, atingindo 23% de taxa de acerto. Os autores consideraram que este valor decorreu devido ao fato da característica ser avaliadas em várias classes diferentes. A taxa de acerto para a extração da cor foi de 60%. A característica de estruturas diferenciais obteve 68% de taxa de acerto. Os autores concluíram que é preciso melhorar o modelo para torná-lo uma ferramenta eficaz no diagnóstico de lesões de pele.

Maglogiannis e Doukas [36] apresentam sistemas de visão computacional para caracterização de lesões de pele. Para comparar os diversos classificadores, os autores utilizaram uma base de 1014 nevos displásicos, 2598 de lesões não displásicas e 95 melanomas. As características utilizadas foram extraídas utilizando a regra ABCD e a textura, totalizando 31 características. Foram aplicados algoritmos de seleção das características, comparando o desempenho na utilização de 31, 18, 11 e apenas 6 características. O resultado indicou a SVM com melhor desempenho na utilização de todas as características. Foram realizados três experimentos: classificação entre melanoma contra nevos displásicos, nevos displásicos contra lesões não displásicas e classificação entre as três classes juntas. Para o processo de aprendizado e classificação foram utilizadas as 31 características e testado vários classificadores. No primeiro experimento a SVM, MRL (Multinomial Logistic Regression),

LWL (Locally Weighted Learning) e o CART (Classification and Regression Trees) tiveram melhor desempenho, tendo 100% de precisão. No segundo experimento, a SVM obteve a melhor precisão, com 76,08%. No terceiro experimento a precisão foi de 77,06%.

Rahman, Bhattacharya e Desai [52] combinaram diferentes classificadores para o reconhecimento de melanoma em imagens dermatoscópicas, com o objetivo de desenvolver um sistema mais robusto e resultados mais precisos. Inicialmente as imagens são passadas do modelo RGB para o espaço de cor HVC (*Hue, Value e Chroma*), que é similar a percepção de cor humana, para obter uma imagem de intensidade, onde os valores altos de níveis de cinza representam a lesão e os baixos o fundo. Também foi considerado outro método para gerar as imagens de intensidade, utilizando o algoritmo de agrupamento c-means *fuzzy*, que apresentou um resultado mais amplo da lesão. A limiarização é aplicada para binarizar a imagem, por meio de um limiar, separando a lesão da pele saudável. Em seguida é realizada uma operação morfológica de abertura e fechamento na imagem binarizada, para remover ruídos e suavizar a borda, obtendo assim o contorno da lesão. Para a classificação das lesões, 128 características de cor e textura são extraídas, conforme a média das cores da lesão no modelo HVC e pela matriz de co-ocorrência de nível de cinza. Desta forma são formados dois vetores, um com as características do histograma de cor, obtido pela quantização uniforme de cada canal do HVC e outro com as características de textura para cada matriz de co-ocorrência, tais como, energia, probabilidade máxima, entropia, contraste e diferença inversa. Em seguida, estes vetores de características são unidos em um só, para serem utilizados pelos classificadores. Para a classificação das lesões de pele foram utilizadas a combinação das técnicas de Máquina de Vetor de Suporte (SVM – *Support Vector Machine*), Probabilidade Máxima Gaussiana (GML – *Gaussian Maximum Likelihood*) e o K vizinhos mais próximos (K-NN – *K-Nearest Neighbor*). As saídas de cada classificador são usadas em combinação utilizando regras de produto, soma, máximo e média para classificar uma imagem em uma determinada categoria (nevo comum, nevo displásico e melanoma maligno). Os melhores resultados foram obtidos com a combinação dos três classificadores com a regra de soma, obtendo 62,50% para nevos comuns, 77,14% para nevos displásicos e 83,75% para melanomas, com base em 358 imagens dermatoscópicas, utilizando 40% para treinamento e 60% para testes.

No trabalho de Soares [60] foi apresentado um método que utiliza as características de cor, forma e textura para análise e classificação das lesões de pele (benigna, melanoma e não-melanoma) utilizando Máquina de Vetor de Suporte (SVM – *Support Vector Machine*). As imagens foram convertidas do modelo RGB para o HSI para realizar a segmentação pelo algoritmo k-médias, sendo aplicado o processo de binarização dinâmica na imagem

segmentada, conforme o valor do limiar calculado para cada região da imagem. As operações morfológicas de fechamento e abertura foram utilizadas para eliminar os orifícios resultantes do processo de segmentação. A borda da lesão foi extraída depois de eliminar os ruídos presentes na mesma, removendo seus *pixels*, pelo uso do algoritmo de conectividade e também os ruídos que não estão conectados a ela. Para a classificação das lesões são determinados os vetores de características de textura, cor e forma, por meio dos seus descritores. O descritor de textura utiliza a Transformada *Wavelet Packet*. O descritor de cor é composto pelo cálculo da média das intensidades da pele e da lesão separadamente, para obter a variação das cores em cada canal, sem a influência da pele. Para obter o contorno da forma são utilizados os descritores de Fourier para determinar sua assinatura, ou seja, sua fronteira. Estas características extraídas são os elementos de entrada da SVM, para o reconhecimento de padrões. Para os testes foram utilizadas 122 imagens, digitais, dermatoscópicas e videodermatoscópicas. No processo de segmentação não foi possível a extração de toda a imagem, devido às condições de luminosidade. O uso das *Waveletes* na extração dos descritores de textura para classificar as lesões pela SVM obteve um resultado de 92,73% de acertos para melanoma e 86% para as benignas e não-melanoma, utilizando três máquinas para testar cada classe de lesão contra as outras.

1.4 Contribuições do trabalho

As principais contribuições do trabalho são:

- Aplicação da difusão anisotrópica e modelo de contorno ativo (Chan-Vese) para detecção de lesões de pele;
- Extração das características de assimetria, borda e cor, conforme a regra ABCD das lesões de pele e aplicação do método *box-counting* para obter as dimensões fractais e extrair as características de textura das imagens, permitindo a classificação inteligente dessas características;
- Caracterização e classificação das lesões de pele por meio da máquina de vetor de suporte (SVM), disponibilizando ao dermatologista informações referentes as características de assimetria, borda, cor e textura, para que possa auxiliá-lo no diagnóstico das lesões de pele.

1.5 Organização do trabalho

Nesta seção é apresentada a estrutura do presente trabalho, que foi organizado da seguinte maneira:

Segundo capítulo: é apresentada uma introdução básica sobre lesões de pele, sendo abordada a estrutura da mesma, os tipos de lesões, os requisitos para o diagnóstico do dermatologista, os tratamentos e os fatores de risco e prevenção;

Terceiro capítulo: são apresentadas técnicas de processamento de imagens digitais que podem ser utilizadas na detecção de lesões de pele, incluindo filtro para remoção de ruídos, técnicas de segmentação e operadores morfológicos;

Quarto capítulo: é feita uma introdução a máquina de vetor de suporte, utilizada no trabalho para a classificação de características das lesões de pele.

Quinto capítulo: é descrito o método desenvolvido neste trabalho, mostrando cada etapa de processamento e os resultados obtidos na utilização das técnicas, incluindo os motivos da utilização das mesmas;

Sexto capítulo: são descritos os testes realizados e expostos os resultados do trabalho, bem como uma discussão sobre eles.

Em seguida é apresentada a conclusão do trabalho realizado, as técnicas propostas, os resultados dos testes e sugestões para trabalhos futuros.

2 LESÕES DE PELE

Neste capítulo são apresentados os principais fundamentos da pele, alguns tipos de lesões de pele e suas características. É importante conhecer as características e funções da pele, pois é ela que protege todo o nosso corpo contra agressões externas, como fungos, bactérias, produtos químicos, físicos e também fatores ambientais, como o sol. Essa proteção é formada pelas células da epiderme e derme que serão abordadas a seguir. Mesmo a pele possuindo essa proteção, ela é permeável, então se deve tomar alguns cuidados. A exposição excessiva ao sol pode causar diversas lesões de pele, que devem ser observadas como prevenção contra cânceres.

2.1 Estrutura da pele

A pele é um dos maiores órgãos do corpo humano, representando 16% do seu peso total [55]. Sendo responsável pela proteção do corpo, contra vários riscos, como os raios ultravioletas, agentes físicos, químicos, desidratação e micro-organismos. Também é considerado um órgão sensorial, pois tem função de receber estímulos por meio das suas terminações nervosas, que causam sensações como dor, temperatura, pressão e tato [56].

A pele é constituída por duas camadas: epiderme e derme [21]. A epiderme é a camada mais externa da pele e a derme a mais profunda. Estas duas camadas se encontram sobre a hipoderme, que é um tecido subcutâneo, conforme se visualiza na Figura 2.1.




Figura 2.1: Estrutura da pele [55].

2.2 Tipos de lesões de pele

As lesões na pele são decorrentes da produção anormal de um grupo de células em um determinado local na pele, podendo invadir outros tecidos. Ao contrário das células normais que possuem o seu desenvolvimento organizado, ou seja, vivem, se dividem e morrem de forma controlada e não se espalham pelo organismo [31].

As lesões na pele são classificadas em benignas e malignas. Nas lesões malignas, as células se dividem sem parar rapidamente e não morrem, continuam a se proliferar, produzindo novas células anormais, que invade outros tecidos e pode se espalhar para outra parte do corpo, caracterizando um câncer de pele, como o melanoma. No caso das lesões benignas, as células têm um comportamento mais organizado do que as lesões malignas, não sendo capaz de invadir outros tecidos, mas algumas delas podem ser consideradas suspeitas, pois podem se transformar em malignas, então devem ser observadas com atenção [31].

2.2.1 Lesões benignas

Os melanócitos são células da pele, que produz a melanina, substância responsável pelo pigmento da pele e proteção contra os raios solares. No caso de pessoas albinas, possuem uma defici

ência na produção de melanócitos, deixando a pele muito branca, já nas pessoas negras, há uma grande produção dessas células, deixando a pele mais escura. O distúrbio na produção dessas células pode provocar lesões benignas na pele, como manchas, pintas (nevus) e ceratose seborréica, que não se proliferam exageradamente, e não se espalham para outros tecidos [18, 54].

A) Manchas

As manchas são o clareamento ou escurecimento de um determinado local da pele, devido à diminuição ou aumento dos melanócitos em determinada área. Alguns exemplos de manchas que surgem na pele são: sarda, mancha senil, mancha de gravidez e manchas brancas [54].

As sardas são manchas pequenas que aparecem nas partes do corpo onde há uma exposição maior do sol, como rosto ombros e colo, principalmente em pessoas claras e ruivas. Não há risco de evoluírem para câncer, mas indicam que as pessoas com este tipo de mancha devem tomar mais cuidados com o sol, para evitar queimaduras e também o envelhecimento precoce, além de estar sempre observando o aparecimento de novas manchas suspeitas pelo corpo.

Outra mancha que não há perigo de se transformar em câncer é a mancha senil, também causada pela exposição ao sol, principalmente nas regiões expostas, como o rosto, antebraço e o dorso das mãos. Geralmente aparecem após os 45 anos devido ao efeito prolongado do sol. Estas manchas são acastanhadas e maiores do que as sardas.

As manchas de gravidez surgem principalmente nas regiões do rosto, onde há mais exposição ao sol e podem estar relacionadas com as alterações hormonais do período de gravidez e uso de anticoncepcionais, mas também podem aparecer em homens, por fatores como tendências genéticas e características raciais.

Por outro lado, existem as manchas brancas, que não são decorrentes da exposição solar, mas representam várias doenças de pele, como, vitiligo¹. Também existem as denominadas manchas claras, que aparecem no corpo decorrente dos raios solares.

B) Nevos

Os nevos (nevos de células névicas ou nevo nevocelular) conhecidos como pintas ou sinais, são tumores pigmentados benignos, formados pela falha na proliferação dos melanócitos. Podem ser denominados congênitos, quando surgem na pele desde o nascimento, ou adquiridos, quando surgem ao longo da vida [21, 54].

Existem vários tipos de nevos que tem em comum a pigmentação e a presença de células névicas melanocíticas nas camadas da pele. Sua forma comum é dos nevos melanocíticos adquiridos, mas também há o nevo azul, nevo halo, nevo sptiz, nevo spilus e outros, sendo formas especiais. Também há o nevo congênito e o nevo atípico, que são considerados suspeitos, pois podem ser precursores do câncer melanoma, e são abordados na próxima seção.

Nevos melanocíticos adquiridos: são caracterizados por máculas, pápulas ou nódulos pigmentados adquiridos, com cerca de 1 cm. Estas pintas são compostas por células névicas melanocíticas que se localizam na epiderme, derme e raramente na hipoderme (tecido subcutâneo). Os nevos podem ser classificados em: juncional, composto e dérmico, conforme sua evolução e localização das células névicas nas camadas da pele [21, 62]:

- **Nevo juncional:** as células névicas surgem na junção dermeepidérmica, ou seja, intra-epidérmico, acima da camada basal da epiderme. Geralmente é uma mácula plana ou ligeiramente elevada, variando de 1 mm a 1 cm de diâmetro. A cor varia de marrom clara a marrom escura, ou também, negra. Pode ser oval ou elíptica, com bordas lisas e regulares e podem estar isoladas ou dispersas em qualquer ponto da pele;
- **Nevo composto:** as células névicas invadem a camada papilar da derme, se localizando tanto na camada epiderme quanto na derme. É formado por pápulas ou nódulos, com variação de cor de marrom claro a escuro ou ser da cor da pele. Superfície lisa ou arredondada, com borda regular e bem definida, tendo 1 cm de diâmetro, aproximadamente;

¹ Doença causada pela falta de pigmentação da pele, quando surgem manchas brancas pelo corpo.

- **Nevo dérmico:** ou intradérmico, ocorrem no último estágio da evolução, onde todas as células névicas passam para a camada derme. É representado por uma pápula ou nódulo bem-definido. A lesão é da cor da pele ou acastanhada, devido às células perderem a capacidade de pigmentação, conforme sua posição de profundidade na pele. São redondas e superfície lisa, com aproximadamente 1 cm de diâmetro.

Um exemplo de cada classificação é apresentado na Figura 2.2. Temos na imagem (a) uma mácula ligeiramente elevada e negra, com borda marrom. Na imagem (b) é visto um nódulo arredondado de 1,4 cm de diâmetro, com um anel hiperpigmentado na base, caracterizando um nevo melanocítico composto. Na imagem (c) é apresentado um exemplo de nevo melanocítico dérmico, tendo duas pápulas marrons de 4 mm de diâmetro cada.




Figura 2.2: Nevos melanocíticos: (a) nevo juncional, (b) nevo composto e (c) nevo dérmico [23, 25].

Nevo halo: também denominado de sutton, é um nevo melanocítico rodeado por um halo despigmentado, ou seja, uma área com melanina reduzida e ausência de melanócitos na junção dermepidérmica. Geralmente é uma pápula marrom, com aproximadamente 5 mm de diâmetro, com halo oval ou redondo com margens bem definidas, tendo o nevo pigmentado no seu centro, como visto na Figura 2.3(a). Com o tempo o nevo pigmentado pode desaparecer, permanecendo apenas o halo (área branca). Em raros casos o halo pode envolver o nevo azul e melanoma ou ser congênito.




Figura 2.3: Nevos. Em (a) tem-se um nevo halo. Em (b) tem-se um nevo azul celular. Em (c) tem-se um nevo spitz. E em (d) tem-se um nevo spilus [23].

Nevo azul: é uma pápula ou nódulo firme e bem definido de redondos a ovais, de cor azul escura ou negra azulada. Basicamente possui dois tipos, o comum e o celular. O nevo azul comum é um nódulo azul pequeno com aproximadamente 0,5 cm de diâmetro e o nevo azul celular é uma pápula ou nódulo azulado grande, de 1 a 3 cm, que se estende ao tecido celular subcutâneo, visto um exemplo na Figura 2.3(b). Ocorre principalmente nas nádegas, parte inferior das costas e no couro cabeludo.

Nevo spitz: esta lesão também é conhecida como melanoma juvenil, sendo apresentada na Figura 2.3(c). Geralmente é um nódulo benigno pequeno, de cor rosa ou castanha, com superfície lisa e fina, mas pode se tornar verrucosa. Atinge aproximadamente 1 a 2 cm de diâmetro, e pode ter um crescimento rápido. Sua ocorrência é mais comum na infância, mas pode aparecer em adultos também.

Nevo spilus: se caracteriza por uma mácula acastanhada, cor café-com-leite, com tamanho variável, podendo ser uma lesão pequena de poucos centímetros, ou até alcançar uma área mais extensa, chegando a possuir mais de 15 cm de diâmetro. Essa lesão é salpicada, em toda sua extensão, por máculas pequenas, que são mais escuras e com diâmetro entre 2 a 3 mm. Podem surgir no tronco e nos membros inferiores, sendo únicas ou múltiplas e possuir diferentes tamanhos. Este tipo de lesão é apresentado na Figura 2.3(d).

C) Ceratose seborréica

A ceratose seborréica é um tumor epitelial benigno, geralmente formado por pápulas verrucosas solitárias ou múltiplas. Sua cor varia de castanho claro a negra, e são recobertas por escamas, um exemplo é mostrado na Figura 2.4. A incidência dessa doença é comum e hereditária, que aparece a partir dos 30 anos em ambos os sexos, mas com maior número de

lesões em homens. Ocorrem devido à proliferação de ceratinócitos e melanócitos, formando cistos² na camada córnea da epiderme [21, 62].



Figura 2.4: Ceratose seborréica. Lesão única verrucosa de cor escura [24].

Na sua fase inicial é formada por pápula com ou sem pigmento, ligeiramente elevada e pequena, com 1 a 3 mm de diâmetro, mas se torna maior com o tempo. Sua superfície é gordurosa e geralmente apresenta pontilhados finos. Já em uma fase mais avançada, é representada por uma placa com superfície verrucosa, de forma oval ou redonda, com tamanho de 1 a 6 cm, e variação de cor entre a cor da pele, marrom, cinza e negro.

Essas lesões podem ser únicas ou dispersas, por várias partes do corpo, geralmente decorrentes na face, tronco e extremidades superiores, e se desenvolvem com o avanço da idade. São benignas e não há possibilidade de se transformarem em lesões malignas, mas algumas lesões pigmentadas e maiores podem ter aspectos parecidos com carcinoma basocelular e melanoma maligno, que são cânceres de pele, podendo ter o seu diagnóstico confundido, sendo importante sua diferenciação.

2.2.2 Lesões suspeitas

Algumas lesões benignas são consideradas suspeitas, devido serem precursoras do câncer de pele. Desta forma devem ser monitoradas frequentemente, pois sua evolução pode dar origem ao melanoma. Podemos citar dois tipos de nevos: o congênito e o atípico.

A) Nevo congênito

São lesões pigmentadas benignas, presentes em 1% dos recém nascidos brancos, mas podem aparecer após o nascimento, sendo consideradas tardias. Estas lesões podem ser

² Constituído de cavidade contendo material líquido, sólido ou semi-sólido e pode ser superficial ou profundo. Neste caso são cistos epidérmicos que produzem material ceratinoso.

pequenas, grandes ou gigantes, conforme apresentado na Figura 2.5. As lesões grandes e gigantes possui 6,3% de chance de se desenvolverem em melanoma maligno, com diagnóstico eventualmente entre os 3 e 5 anos de idade. Já no caso das lesões pequenas os riscos são menores, sendo de 1 a 5%.




Figura 2.5: Nevos congênitos. Em (a) temos uma nevo congênito pequeno. Em (b) há um nevo congênito grande. No caso da figura (c), temos um nevo congênito gigante [23].

São caracterizadas pela deformação da superfície da pele, que forma uma placa com ou sem pêlos. As bordas podem ser regulares ou irregulares, e bem demarcadas ou se misturarem com a pele. A sua superfície é definida conforme a profundidade da lesão, que pode se estender para a camada reticular da derme, desta forma, se define como lisa ou áspera e rugosa. O formato pode ser oval ou redondo, com cores que variam entre marrom claro a escuro, podendo ter pontilhados finos e mais escuros sobre a lesão. Geralmente são isoladas e podem estar localizada em qualquer região.

B) Nevo displásico

O nevo displásico, também conhecido como nevo atípico ou nevo Clark, é um tipo especial dos nevos pigmentados, um exemplo é apresentado na Figura 2.6. São adquiridos devido à proliferação exacerbada de melanócitos com atipias variáveis na camada basal, causada pela exposição solar. Geralmente é composta por várias lesões, que podem atingir 2 cm de diâmetro e podem surgir diretamente na pele saudável ou fazer parte de um nevo melanocítico composto, localizando-se no seu centro. São maiores e com mais variedades de cores, comparadas com os nevos comuns, além de serem lesões assimétricas, com bordas irregulares, que são características semelhantes de lesões malignas, porém o seu tamanho é menor do que os melanomas.




Figura 2.6: Nevo atípico. Pápulas arredondadas e ovais hiperpigmentada, com bordas um pouco irregulares, variação de pigmento e diâmetro de 4 a 8 mm [23].

Essa doença pode ocorrer tanto em adultos como em crianças, na mesma proporção em ambos os sexos, presentes em 5% desta população. São mais frequentes nas áreas sujeitas à exposição solar. Geralmente surgem no final da infância e continuam a se desenvolver durante muitos anos. Por isso é necessário o acompanhamento destas pintas, pois podem sofrer alterações em suas características e se desenvolverem em melanoma extensivo superficial, que surge inicialmente como uma pápula pequena, com mudanças na cor. Quando há a presença de uma lesão atípica o risco de desenvolver melanoma duplica, e no caso de ter mais de 10 lesões o risco aumenta 12 vezes.

2.2.3 Lesões malignas

As lesões malignas ocorrem quando as células da pele se dividem descontroladamente, criando metástase, onde as células anormais são espalhadas para outros locais do corpo, continuando a se reproduzir e ocupar tecidos saudáveis. Dependendo do tipo de células malignas que se proliferam é formado um tipo de câncer cutâneo diferente, que podem ser divididos em não melanoma e melanoma.

A) Cânceres cutâneos não melanoma

O câncer de pele não melanoma (CCNM) é o tipo mais incidente no Brasil para ambos os sexos. Foi estimado para o ano de 2012, o surgimento de 62.680 casos novos de câncer não melanoma entre os homens e 71.490 entre as mulheres [16]. Apesar da alta ocorrência, são lesões malignas mais fáceis de diagnosticar e tratar, tendo uma taxa de mortalidade mais baixa do que o melanoma, de 1.507, sendo 842 homens e 665 mulheres no

ano de 2010 [32]. Os tipos de câncer não melanoma mais incidentes são: o carcinoma basocelular (CBC) e carcinoma espinocelular (CEC).

Carcinoma basocelular: câncer maligno mais comum, sendo invasivo, agressivo e destrutivo. Tem origem nas células basais da epiderme, mas possui pouca capacidade de produzir metástase e se espalhar pelo corpo, um exemplo é apresentado na Figura 2.7(a). Geralmente surgem em pessoas de pele clara, acima de 40 anos, mais em homens do que em mulheres. São lesões sólidas e podem ser múltiplas, e 90% ocorrem na face. Suas características dependem dos seus tipos, nodular, ulcerado, cicatricial, superficial e pigmentado. Apesar da não produção de metástase, pode ocorrer sérios problemas quando situadas em locais perigosos, como na cabeça [62].




Figura 2.7: Cânceres cutâneos não melanoma. Em (a) tem-se um carcinoma basocelular e em (b) um carcinoma espinocelular [25].

Carcinoma espinocelular: esta lesão maligna é o segundo câncer mais frequente. Seu surgimento é decorrente das células escamosas na camada epiderme, induzidas pelos raios solares e podem gerar metástases, mas com baixa quantidade. Geralmente surgem após os 50 anos de idade, mais frequente em homens do que em mulheres e podem ocorrer em pele clara e também parda ou negra. Seu desenvolvimento é lento, tem forma de nódulo que pode evoluir em uma pápula ou mácula isolada, ceratótica ou erosada [62]. Na Figura 2.7(b) temos a representação de um carcinoma espinocelular.

B) Câncer cutâneo melanoma

O melanoma é uma lesão maligna, que tem origem nos melanócitos na junção dermepidérmica. É considerada a mais invasiva e agressiva entre os outros cânceres de pele, devido sua alta produção de metástase. Para o ano de 2012 foram estimados 5.930 novos casos no Brasil, sendo 3.170 nos homens e 3.060 nas mulheres [16]. Apesar da baixa

incidência, possui maior índice de mortalidade. Em 2009, foi responsável pelas mortes de 1.392 pessoas, sendo 827 homens e 565 mulheres [32]. Mas quando detectado precocemente, há uma grande possibilidade de sobrevivência.

Geralmente os melanomas apresentam fase de crescimento radial, seguida do crescimento vertical. A fase inicial, ou seja, o crescimento radial, ocorre intra-epidérmico, sendo pouco invasivo. Já o crescimento vertical é caracterizado pelo crescimento da lesão para dentro da camada derme, encontrando-se com os vasos sanguíneos, que se tornam caminhos livres para a metástase.

O melanoma pode ser primário ou surgir das lesões precursoras (nevos atípicos ou nevos congênitos). O melanoma primário pode ser classificado em vários tipos clínicos, tais como, melanoma extensivo superficial, melanoma nodular, lentigo maligno melanoma e melanoma lentiginoso acral [21, 62]. O extensivo superficial é o mais frequente entre os melanomas, como mostrado na Tabela 2.1, também são apresentados os principais locais onde estes tipos de melanoma se desenvolvem e o seu período de crescimento radial e vertical.

Tabela 2.1: Informações básicas sobre os principais tipos clínicos de melanoma (adaptado de [62]).

Tipo de melanoma	Frequência (%)	Principais locais	Período de crescimento radial	Período de crescimento vertical
Extensivo superficial	70	Extremidades inferiores e tronco	Meses a 2 anos	Tardio
Nodular	15	Tronco, cabeça e pescoço	Nenhum crescimento	Imediato
Lentiginoso acral	10	Face, pescoço e dorso das mãos	Anos	Muito tardio
Lentigo maligno melanoma	5	Palmas, plantas e subungueais	Meses e anos	Inicial, mas com reconhecimento tardio

O melanoma extensivo superficial (MES) surge em 70% das pessoas brancas, geralmente na parte superior das costas. Seu crescimento é mais lento, em até 2 anos. Ocorrem em média aos 37 anos de idade, sendo acima dos 50 anos nos homens e abaixo dos 40 nas mulheres, tendo incidência um pouco maior em mulheres [21, 62]. Um melanoma extensivo superficial é visto na Figura 2.8.



Figura 2.8: Melanoma extensivo superficial. Lesão maligna assimétrica, com textura variada, com variações de preto e roxo e diâmetro de 2 cm [23].

Este tipo de melanoma é caracterizado por uma placa plana e elevada, geralmente única, mas pode ocorrer casos de lesões múltiplas. Sua cor é formada por marrom clara, escura, negra, azul e vermelha, com regiões acinzentadas. Conforme ocorre a fase de crescimento vertical, surgem pápulas e nódulos na lesão, podendo desenvolver erosões e ulceração em sua superfície.

2.3 Diagnóstico dermatológico

O diagnóstico dermatológico tem como objetivo detectar o câncer de pele precocemente, pois há grandes chances de cura. Inicialmente, o dermatologista realiza o exame físico no paciente, em busca de lesões na pele. Também deve levar em consideração o seu histórico, tendo informações, tais como, sua raça, se alguém da família ou o próprio paciente já desenvolveu câncer de pele e se já obteve queimaduras devido à excessiva exposição solar [21, 62].

Quando lesões são encontradas devem ser examinadas clinicamente, para isso, podem ser utilizadas várias técnicas especiais, tais como, análise das características, a dermatoscopia e exames laboratoriais, para então diagnosticá-las e tratá-las.

2.3.1 Métodos

Primeiramente são analisadas as características das lesões, no próprio paciente ou por imagens obtidas por câmera digital. O resultado do diagnóstico pode ser confirmado pela dermatoscopia, tendo informações mais detalhadas da lesão e ainda em caso de dúvidas é

importante fazer a biopsia, um exame laboratorial, que detecta precisamente o tipo da lesão [62].

Para facilitar este processo inicial, os dermatologistas podem dispor de sistemas computacionais, que analisam as características das lesões de forma mais precisa, utilizando tanto imagens fotográficas, quanto imagens dermatoscópicas, obtidas pelo mesmo, para auxiliar no seu diagnóstico.

A) Características das lesões de pele

As lesões podem ser diferenciadas pelas suas características, que podem ser definidas pelos dermatologistas utilizando a regra ABCDE ou também a análise de textura, que são muito utilizadas para analisar computacionalmente lesões a partir de imagens fotográficas [6, 60].

Regra ABCDE: são cinco sinais que contribuem para o diagnóstico clínico das lesões de pele. Mas também podem ser utilizadas pelas pessoas para examinarem o próprio corpo, para verificar se há alguma pinta. Essa regra pode determinar se a lesão é benigna ou maligna, podendo ser aplicada nos nevus e melanomas. Mas deve levar em consideração que em alguns casos, como o melanoma em sua fase inicial, pode não seguir esta regra totalmente. Cada letra representa uma característica diferente da lesão [21, 59, 62]. A regra **A** representa a Assimetria, **B** representa a Borda, **C** a Cor, **D** o Diâmetro e **E** representa a Elevação ou Evolução. Na Tabela 2.2 é apresentada uma descrição e demonstração dessa regra ABCDE, para lesões benignas e malignas.

Na característica de assimetria (A) listada na linha "A" considera-se a maior distância entre os pontos do contorno da lesão e traça-se uma reta sobre a mesma, para que possa ser analisada a similaridade entre as duas partes divididas. Quando essas partes são semelhantes, a característica de assimetria é considerada simétrica, que geralmente representa as lesões benignas. No caso destas partes serem muito diferentes, esta característica é assimétrica, caracterizando lesões malignas.

A borda (B) considerada regular representa lesões benignas e a borda irregular geralmente definem as lesões malignas, assim como mostrado na linha "B". No caso da característica de cor (C), as lesões benignas geralmente possuem apenas uma tonalidade e já as malignas possuem várias tonalidades, como pode ser visto na linha "C". A característica de diâmetro (D), especificada na linha "D", das lesões benignas são menores, até 6 mm e das malignas são iguais ou maiores que 6 mm.

Tabela 2.2: Descrição e demonstração da regra ABCDE [adaptado de 55].

Regras		Lesões benignas		Lesões malignas	
A	Assimetria	Simétrica		Assimétrica	
B	Bordas	Regulares e bem definidas		Irregulares e mal definidas	
C	Cor	Uniforme		Variedades	
D	Diâmetro	Menor que 6 mm		Acima de 6 mm	
E	Elevação ou Evolução	Superfície lisa ou crescimento estável		Superfície irregular ou aumento de tamanho	

A característica elevação ou evolução (E), foi adicionada recentemente na regra, representa a elevação das lesões, que na maioria das vezes está presente em sua superfície, sendo deformada (irregular) nas lesões malignas e também há histórico de evolução, ocorrendo aumento ao decorrer do tempo, ao contrário das lesões benignas.

Vejamos na Tabela 2.3 alguns exemplos de lesões de pele, que se diferenciam pelas características ABCDE. Na linha 1 temos nevus, que são lesões benignas e na linha 2 melanomas, representando as lesões malignas. Na coluna Assimetria, temos na linha 1 um nevo simétrico e na linha 2 uma melanoma assimétrico, devido suas partes serem diferentes. Na coluna Borda, percebe-se que a lesão da linha 1, tem sua borda regular, já no caso da lesão da linha 2, a borda está irregular. A regra C, demonstrada nas imagens da Coluna Cor, a lesão da linha 1 tem cor uniforme, com apenas uma tonalidade, ao contrário do melanoma da linha 2 que possui mais de uma tonalidade. Na regra do Diâmetro, as lesões benignas são inferiores a 6 mm, representada pela imagem da linha 1, as maiores são malignas, como a lesão da linha 2, que possui 3 cm. Na coluna Elevação, temos uma lesão benigna, considerando que tem uma superfície lisa e não muito elevada e a lesão da linha 2 tem sua superfície elevada e irregular.

Tabela 2.3: Imagens de nevos e melanomas diferenciados pela regra ABCDE [23, 25, 55].

	Assimetria	Borda	Cor	Diâmetro	Elevação
1					
2					

Análise de textura: as características de textura das lesões de pele, como sua suavidade ou rugosidade e regularidade ou irregularidade podem ser utilizadas para identificar os padrões de uma determinada lesão. Estas características de textura se tornam um diferencial para sua classificação, auxiliam também, quando não houve uma boa definição da lesão utilizando a regra ABCDE. A análise de textura pode ser realizada em todos os tipos de lesões, incluindo os nevos e melanomas, mas principalmente na ceratose seborréica, devido possuir um aspecto escamoso e rugoso como característica principal. As lesões de ceratose seborréica não são estabelecidas utilizando a regra ABCDE, pois não possuem essas características definidas.

B) Dermatoscopia

O exame de dermatoscopia (microscopia de epiluminescência) é feito por um instrumento dermatoscópio, composto por uma lupa com iluminação, que aumenta a proximidade a lesão em 10 a 30 vezes, permitindo uma inspeção não invasiva e mais profunda da pele. Este tipo de exame pode ser utilizado para confirmar o diagnóstico adquirido da regra ABCDE, pois adquire informações mais detalhadas [62].

As lesões, tanto benignas quanto malignas, podem ser diagnosticadas pela análise de suas características, por meio das imagens adquiridas pelo dermatoscópio. Exemplos de imagens dermatoscópicas são apresentados na Figura 2.9. Além de utilizar a regra ABCDE, outros métodos também são usados: a análise de padrão e a lista de sete pontos, para o diagnóstico de lesões em imagens dermatoscópicas [34, 39].




Figura 2.9: Imagens dermatoscópicas. Em (a) e (c) temos imagens fotográficas e (b) e (d) as mesmas lesões capturadas por um dermatoscópio [25].

As lesões de pele são caracterizadas por padrões, tais como, globular, homogêneo, reticular e paralelo, que podem ser identificados nas imagens dermatoscópicas pela análise de padrão, para definir se a lesão é benigna ou maligna. A lista de sete pontos é um método mais simplificado da análise de padrão, ou seja, utiliza menos características para o seu diagnóstico. São sete critérios estabelecidos em ordem. Os critérios maiores representam a presença de pigmentação atípica, véu branco azulado e padrão de vascularização atípica. Os critérios menores são compostos por estrias irregulares, pigmentação irregular, pontos ou glóbulos irregulares e estruturas de regressão.

C) Exame laboratorial

Em caso de dúvida, depois de utilizados esses recursos clínicos, é necessário realizar a biopsia, um exame histopatológico, realizado depois da remoção total (excisão) ou de uma amostra do tecido da região doente, para análise microscópica. Este exame identifica a presença ou não de células anormais e determina o estágio (estadiamento) que o câncer se encontra, conforme as suas características histopatológicas [21, 31]. Algumas destas características são: sua espessura (Breslow) e a profundidade da lesão (níveis de Clark).

2.3.2 Tratamento

Existem várias formas de se tratar as lesões de pele, sendo de acordo com o seu diagnóstico e o estágio ao qual se encontra. Geralmente as lesões benignas como os nevos melanocíticos, não precisam ser retirados, mas nos casos de serem suspeitas é importante a excisão cirúrgica e a realização da biopsia, para descartar a possibilidade de ser câncer. A ceratose seborréica também não tem a necessidade de sua excisão, mas normalmente os pacientes desejam realizar este procedimento por motivos de estética [21, 31, 62].

No caso das lesões malignas, podem ser tratadas com cirurgia, radioterapia ou quimioterapia. Na cirurgia é retirada toda a pele doente. A radioterapia trata o câncer localizado, sendo utilizada para reduzir o tumor antes da cirurgia ou eliminar as células doentes após a cirurgia. Essa técnica afeta essas células, e não prejudica outros tecidos. Na quimioterapia são utilizados medicamentos que podem atingir qualquer parte do corpo, pela corrente sanguínea. Este procedimento reduz o risco do câncer aparecer novamente.

3 TÉCNICAS DE PROCESSAMENTO DIGITAL DE IMAGENS

Neste capítulo são apresentadas e discutidas as técnicas de processamento de imagens digitais utilizadas no trabalho para detecção e caracterização de lesões de pele.

Uma imagem forma uma matriz $M \times N$, conforme a quantidade de linhas e colunas, sendo composta por vários elementos (pontos), denominados *pixels* (*picture elements*). Cada ponto na imagem bidimensional possui um valor de intensidade ou nível de cinza definido pela função $f(x, y)$, sendo x e y suas coordenadas espaciais, que representam a localização de cada ponto .

O processamento digital de imagens é realizado em etapas que permitem a utilização de diferentes técnicas, que podem ser aplicadas para o tratamento de imagens, as quais normalmente foram obtidas com algum ruído, melhorando assim sua qualidade de visualização, com o objetivo de extrair informações, que possam ser utilizadas para alguma finalidade.

De acordo com Gonzalez [30], o processamento de imagens é constituído de algumas etapas, que são: aquisição, pré-processamento, segmentação, pós-processamento e funções cognitivas. Cada etapa corresponde a um nível: baixo, médio ou alto, conforme visto na Figura 3.1. As etapas não possuem técnicas de processamento de imagem definidas, ou seja, dependendo da aplicação elas serão estabelecidas para uma determinada etapa. Por exemplo, a limiarização pode ser realizada tanto na etapa de pré-processamento, quanto na segmentação. Todas as etapas se relacionam com uma base de conhecimento. Essa base é responsável por armazenar o conhecimento referente ao problema de cada etapa e controlar a interação entre elas.




Figura 3.1: Etapas do processamento de imagens digitais (adaptado de [37]).

Aquisição: A primeira etapa, aquisição, corresponde a um processamento de nível baixo, é aquela através da qual se obtém a imagem. Esta etapa pode fazer uso de câmera fotográfica, câmera de vídeo ou outros dispositivos que possuem essa mesma finalidade, que sejam compostos por um sensor, com a função de transformar a imagem em sinal elétrico para ser digitalizada. Na aquisição da imagem, alguns aspectos devem ser levados em consideração, tais como, a escolha do tipo de sensor, dos tipos de lentes, da iluminação do ambiente e outros, com o objetivo de diminuir os ruídos na imagem.

Pré-processamento: A etapa descrita anteriormente pode causar vários ruídos na imagem, dificultando assim sua visualização de forma correta. A solução para este problema está na etapa de pré-processamento (nível baixo), por meio da utilização de técnicas para diminuir os ruídos, suavizar a imagem e realçar os contornos, gerando assim uma imagem de saída com melhor qualidade.

Segmentação: A etapa de segmentação (processamento de nível médio) é caracterizada pela extração dos objetos de interesse presentes na imagem. Inclui a

representação e a descrição desses objetos em forma de fronteiras ou regiões, obtendo-se a saída, que são as características da imagem de entrada, tais como bordas e contornos.

- A representação por fronteiras normalmente é utilizada para diferenciar as características externas do objeto, como cantos ou pontos de inflexões. Já a representação por regiões é utilizada para distinguir as características internas do objeto, tais como textura ou forma do esqueleto. Todavia, não se descarta a possibilidade de utilizar as duas representações de modo complementar.
- O processo de descrição pode ser feito para destacar as características do objeto conforme sua representação ou diferenciar um conjunto de objeto dos outros.

Geralmente a segmentação em imagens monocromáticas é baseada nas propriedades de descontinuidade e similaridade. A primeira é caracterizada pelas mudanças abruptas das intensidades, como os detectores de borda, abordados anteriormente. No caso da segunda propriedade, a segmentação ocorre conforme um critério de similaridade, podendo ser de cor, textura ou outros. A propriedade de similaridade é utilizada por técnicas, tais como, limiarização e crescimento de região.

Pós-processamento: Esta etapa, também considerada de nível médio, é aplicada para melhorar o resultado obtido na etapa de segmentação, por meio de um novo processamento para a obtenção ou reajuste do objeto de interesse.

Funções cognitivas: são realizadas em um processamento de nível alto e envolve o processo de reconhecimento e interpretação dos objetos, representando a atribuição de rótulos dos referentes objetos conforme as suas características destacadas pelo processo de descrição na etapa de segmentação. As técnicas desta etapa são associadas à percepção humana, podendo ser utilizado sistemas inteligentes para a análise e caracterização das imagens.

Para Sonka, Hlavac e Boyle [61] as etapas de processamento de imagens são representadas apenas em dois níveis de processamento: o nível baixo e o nível alto. No processamento de nível baixo considera-se não somente as etapas de aquisição e pré-processamento, conforme Gonzalez afirma [30], mas também as etapas de segmentação e pós-processamento. As funções cognitivas, ou seja, a habilidade de tomar decisões de acordo com as informações contidas na imagem, são realizadas em um processamento de nível alto.

3.1 Filtro de difusão anisotrópica

As imagens geralmente são obtidas com interferências (ruídos), sendo necessário passar por uma filtragem. Um filtro que pode ser utilizado para suavizar imagens é a difusão anisotrópica [6, 11]. Este filtro, considerado um filtro não linear, é aplicado por meio de iterações, que podem ser definidas de acordo com a quantidade de ruídos, tendo como resultado uma suavização seletiva da imagem, mas pode eliminar as bordas da lesão quando aplicado em excesso.

Barcelos, Boaventura e Silva [10] acrescentaram o termo $(1 - g)$ da equação de difusão anisotrópica, descrita na Equação 3.1, para realizar a suavização da imagem com menos perda da borda, com objetivo de aplicá-la em imagens que necessitem de uma maior suavização. Este filtro foi inicialmente proposto por Perona e Malik [50], tendo o seguinte modelo: $u_t = \text{div}(g(\nabla u)\nabla u)$. O termo $g|\nabla u| \text{div}(\nabla u/|\nabla u|)$ da Equação 3.1 foi proposto por Alvarez, Lions e Morel [4], como uma alteração do modelo proposto por Perona e Malik. Já o termo $(u - I)$ adicionado na Equação 3.1, foi proposto por Nordström [41].

$$u_t = g |\nabla u| \text{div} \left(\frac{\nabla u}{|\nabla u|} \right) - \lambda (1 - g)(u - I) \quad (3.1)$$

onde:

- $u(x, y, 0) = I(x, y)$, sendo $x, y \in \Omega \subset \mathbb{R}^2$;
- u é a imagem suavizada;
- I é a imagem original;
- t é a escala da suavização, sendo $t > 0$;
- div é o operador divergente;
- ∇u é o valor do gradiente de u ;
- λ é um parâmetro que auxilia na velocidade da difusão.

O termo g , definido pela Equação 3.1, é utilizado para detecção de borda. Considerando uma vizinhança de um ponto x , quanto o gradiente ∇ possui uma média baixa, ou seja, há poucos pontos (ruídos) na imagem, o x é considerado um ponto interior (região

homogênea), tendo como resultado $g \sim 1$. Mas, caso o gradiente ∇ tenha uma média alta, possuindo vários pontos, o x será um ponto de um contorno, $g \sim 0$.

$$g = \frac{1}{1+k|\nabla(G_\sigma * u)|^2} \quad (3.2)$$

tal que $g(0) = 1$, $g(s) \geq 0$ e $g(s) \rightarrow 0$ quando $s \rightarrow \infty$, k é uma parâmetro e G_σ é a função gaussiana (Equação 3.3).

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} \quad (3.3)$$

Encontrada a borda, o termo $|\nabla u| \operatorname{div} (\nabla u / |\nabla u|)$ da Equação 3.1 tem por objetivo realizar uma suavização alta em ambos os lados da borda quando $g \sim 1$, e uma suavização baixa na mesma, quando $g \sim 0$. O termo de moderação $(1 - g)$ tem função de equilibrar o termo forçante $(u - I)$, juntos reforçam a borda para não perdê-la na difusão permitindo uma melhor suavização da imagem.

Para desenvolver este filtro, a Equação 3.1 deve ser discretizada, ou seja, obtida por aproximação utilizando métodos de diferenças finitas, como o método de Euler. Considerando u a intensidade de uma imagem com dimensão $M \times N$ na posição (x_i, y_j) , sendo $i = 1, 2, \dots, N$ e $j = 1, 2, \dots, M$, e $t_n = n\Delta t$, onde $t = 1, 2, \dots, Z$, que representa a evolução de tempo da difusão, temos u_{ij}^n . A discretização do termo $(G_\sigma * u)$ da Equação 3.2 é obtida da seguinte maneira [11]:

$$\begin{aligned} (G_\sigma * u_{ij}^n) = \frac{1}{36} \{ & G_\sigma(1,1)u_{i-1,j-1}^n + G_\sigma(-1,1)u_{i+1,j-1}^n + G_\sigma(1,-1)u_{i-1,j+1}^n + G_\sigma(-1,-1)u_{i+1,j+1}^n \\ & + 16G_\sigma(0,0) + 4[G_\sigma(0,1)u_{i,j-1}^n + G_\sigma(1,0)u_{i-1,j}^n + G_\sigma(-1,0)u_{i+1,j}^n + G_\sigma(0,-1)u_{i,j+1}^n] \} \end{aligned} \quad (3.4)$$

onde G_σ é função gaussiana representada pela Equação 3.3. Considerando U o resultado da Equação 3.4, o termo $|\nabla(G_\sigma * u)|^2$ da Equação 3.2 é definida por:

$$|\nabla(G_\sigma * u_{ij}^n)|^2 = \left(\frac{U_{(i+1,j)}^n - U_{(i-1,j)}^n}{2} \right)^2 + \left(\frac{U_{(i,j+1)}^n - U_{(i,j-1)}^n}{2} \right)^2 \quad (3.5)$$

Outro termo que deve ser discretizado é o da Equação 3.1 $|\nabla u| \operatorname{div} \left(\frac{\nabla u}{|\nabla u|} \right)$, sendo representado por:

$$|\nabla u| \operatorname{div} \left(\frac{\nabla u}{|\nabla u|} \right) = \frac{u_x^2 u_{yy} - 2u_x u_y u_{xy} + u_y^2 u_{xx}}{u_x^2 + u_y^2} \quad (3.6)$$

As derivadas presentes na Equação 3.6 ($u_x, u_y, u_{xx}, u_{yy}, u_{xy}$) são aproximadas utilizando diferenças centrais, sendo:

$$u_x(x_i, x_y) \cong \frac{u_{(i+1,j)} - u_{(i-1,j)}}{2} \quad (3.7)$$

$$u_y(x_i, x_y) \cong \frac{u_{(i,j+1)} - u_{(i,j-1)}}{2} \quad (3.8)$$

$$u_{xx}(x_i, x_y) \cong u_{(i+1,j)} - 2u_{(i,j)} + u_{(i-1,j)} \quad (3.9)$$

$$u_{yy}(x_i, x_y) \cong u_{(i,j+1)} - 2u_{(i,j)} + u_{(i,j-1)} \quad (3.10)$$

$$u_{xy}(x_i, x_y) \cong \frac{u_{(i+1,j+1)} - u_{(i+1,j-1)} - u_{(i-1,j+1)} + u_{(i-1,j-1)}}{4} \quad (3.11)$$

Desta forma, a aproximação numérica da Equação 3.1 é representada da seguinte maneira [11]:

$$\begin{aligned} u_{ij}^{n+1} = u_{ij}^n + \Delta t & \left(g_{ij}^n \left[\frac{\left(\frac{u_{(i+1,j)}^n - u_{(i-1,j)}^n}{2} \right)^2 (u_{(i,j+1)}^n - 2u_{(i,j)}^n + u_{(i,j-1)}^n)}{\left(\frac{u_{(i+1,j)}^n - u_{(i-1,j)}^n}{2} \right)^2 + \left(\frac{u_{(i,j+1)}^n - u_{(i,j-1)}^n}{2} \right)^2} \right. \right. \\ & - \frac{2 \left(\frac{u_{(i+1,j)}^n - u_{(i-1,j)}^n}{2} \right) \left(\frac{u_{(i,j+1)}^n - u_{(i,j-1)}^n}{2} \right) \left(\frac{u_{(i+1,j+1)}^n - u_{(i+1,j-1)}^n - u_{(i-1,j+1)}^n + u_{(i-1,j-1)}^n}{4} \right)}{\left(\frac{u_{(i+1,j)}^n - u_{(i-1,j)}^n}{2} \right)^2 + \left(\frac{u_{(i,j+1)}^n - u_{(i,j-1)}^n}{2} \right)^2} \\ & \left. \left. + \frac{\left(\frac{u_{(i,j+1)}^n - u_{(i,j-1)}^n}{2} \right)^2 (u_{(i+1,j)}^n - 2u_{(i,j)}^n + u_{(i-1,j)}^n)}{\left(\frac{u_{(i+1,j)}^n - u_{(i-1,j)}^n}{2} \right)^2 + \left(\frac{u_{(i,j+1)}^n - u_{(i,j-1)}^n}{2} \right)^2} - \lambda(1 - g_{ij}^n)(u_{ij}^n - I) \right] \right) \end{aligned} \quad (3.12)$$

O resultado da aplicação do filtro de difusão anisotrópica utilizando a Equação 3.12, pode ser visto na Figura 3.2. Sendo a imagem original apresentada na Figura 3.2(a) e o resultado da aplicação do filtro apresentado na Figura 3.2(b), onde podemos observar a suavização da imagem, com preservação das bordas.




Figura 3.2: Suavização utilizando difusão anisotrópica. (a) Imagem original e (b) Imagem suavizada.

Araujo [6] propôs uma estimativa automática para definir o número de iterações da difusão anisotrópica, que se baseia na diferença dos pontos retornados pela aplicação dos operadores de Roberts e Prewitt, determinando o número de iterações n necessárias para a aplicação do filtro. Essa estimativa é calculada por:

$$n = \frac{(N_R(I) - N_P(I))(P_R - P_P)}{100}, \quad (3.13)$$

sendo:

- I é a imagem original;
- rc é quantidade total de pontos (*pixels*) da imagem original;
- N_R é o número de pontos retornado pelo operador de Roberts;
- N_P é o número de pontos retornado pelo operador de Prewitt;
- P_R é porcentagem de N_R em relação a rc , sendo $P_R = \frac{100N_R}{rc}$;
- P_P é porcentagem de N_P em relação a rc , sendo $P_P = \frac{100N_P}{rc}$;

3.2 Operadores morfológicos

A morfologia matemática é baseada na teoria de conjuntos e são aplicadas em diversos trabalhos na área de processamento de imagens [14, 19, 42], sendo utilizadas para realce, filtragem, segmentação, detecção de borda, dentre outras atividades. Consiste na extração ou modificação das informações referentes a estrutura geométrica dos objetos presentes na imagem por meio de um elemento estruturante definido. O elemento estruturante representa uma máscara, com determinado tamanho, podendo ser estruturado com diferentes formas, tais como, quadrado, circular, elíptica e cruz.

Considerando os conjuntos de *pixels* A e B , sendo B um elemento estruturante, que interage com o conjunto A que representa a imagem, de forma que B tenha qualquer ponto (geralmente o central quando possível) posicionado em cada *pixel*, deslizado-se sobre a imagem no momento da aplicação, realizando as operações morfológicas. Alguns dos operadores morfológicos são: dilatação, erosão, abertura, fechamento e filtros morfológicos [28, 37].

3.3 Limiarização

A técnica de limiarização (*thresholding*) pode ser utilizada na etapa de segmentação para separar os objetos do fundo da imagem. Esse processo tem como resultado uma imagem binária, onde a cor preta pode representar o objeto e a branca o fundo. A sua aplicação envolve a escolha de um limiar (T) para fazer a separação dos níveis de cinza da imagem, que são representados pelo histograma³. Este limiar pode ser representado apenas por um valor (limiar único) ou corresponder a um intervalo (limiares múltiplos).

No caso da seleção de um limiar, a aplicação da limiarização segue a seguinte condição [30, 37]:

$$g(x, y) = 1 \text{ se } f(x, y) \geq T \quad (3.14)$$

$$g(x, y) = 0 \text{ se } f(x, y) < T, \quad (3.15)$$

³ Representação gráfica da quantidade de pixel para cada nível de cinza da imagem.

onde $g(x, y)$ representa cada ponto da imagem de saída, que receberá 1 quando o *pixel* da imagem original f nas coordenadas (x, y) for maior ou igual ao limiar T ou 0 quando a intensidade do *pixel* for menor que o limiar. Os *pixels* com valores transformados para 1, ou seja, cor branca, representam o fundo e os definidos com 0, estabelecem o objeto da imagem com cor preta. Também podem ser escolhidos vários limiares, determinando intervalos e condições diferentes de limiarização. Podendo ser estabelecido da seguinte forma: os *pixels* da imagem $f(x, y)$ com intensidade entre os valores do intervalo definidos pelos limiares T_1 e T_2 , sendo $T_1 < f(x, y) \leq T_2$, recebem o valor 0, sendo considerado um objeto e os *pixels* maiores que T_2 , ou seja, $f(x, y) \leq T_1$, recebem o valor 1, representando o fundo da imagem e no caso dos valores menores ou iguais a T , tal como, $f(x, y) \leq T_2$, recebem um nível de cinza diferente, representando outro objeto.

O limiar é definido por uma função, que pode utilizar a intensidade original do *pixel*, sendo considerado um limiar global ou seu valor pode ser adquirido por alguma propriedade, como a média dos seus vizinhos, neste caso o limiar é considerado local. Um exemplo de limiar utilizado na binarização das imagens é o método de OTSU [49].

3.3.1 Método de OTSU

O método de OTSU [49] se baseia no histograma normalizado da imagem e considera a distribuição de probabilidade P_i em uma imagem com L níveis de cinza $[1, 2, \dots, L]$, conforme a Equação 3.16.

$$P_i = \frac{n_i}{N}, \quad (3.16)$$

onde n_i representa o número de *pixels* no determinado nível de cinza i e N é o número total de *pixels* da imagem, sendo $N = n_1 + n_2 + \dots + n_L$.

Para encontrar o limiar k , que separe os *pixels* em duas classes (C_0 e C_1), sendo $C_0 = [1, 2, \dots, k]$ e $C_1 = [k + 1, k + 2, \dots, L]$, k é definido pela minimização da variância intra-grupo σ_B^2 , descrita na Equação 3.17.

$$\sigma_B^2 = \omega_0(\mu_0 - \mu_T)^2 + \omega_1(\mu_1 - \mu_T)^2, \quad (3.17)$$

onde ω_0 e ω_1 são a probabilidade de ocorrência das classes C_0 e C_1 , respectivamente, sendo descritas por:

$$\omega_0 = \sum_{i=1}^k P_i \quad (3.18)$$

$$\omega_1 = \sum_{i=k+1}^L P_i, \quad (3.19)$$

os termos μ_0 e μ_1 da Equação 3.17, determinam as médias para as classes C_0 e C_1 , respectivamente, da seguinte forma:

$$\mu_0 = \sum_{i=1}^k \frac{iP_i}{\omega_0} \quad (3.20)$$

$$\mu_1 = \sum_{i=k+1}^L \frac{iP_i}{\omega_i} \quad (3.21)$$

e o termo μ_T da Equação 3.17 é a média total das intensidades da imagem original, definida pela Equação 3.22.

$$\mu_T = \sum_{i=k+1}^L iP_i \quad (3.22)$$

Desta forma, a partir da definição de k , por meio da Equação 3.17, o limiar encontrado será utilizado para binarizar a imagem, separando-a em duas classes C_0 e C_1 . Um exemplo pode ser visto na Figura 3.3.




Figura 3.3: Exemplo de limiarização. (a) Imagem original e (b) Imagem binarizada.

3.4 Funcional de Mumford-Shah

Este algoritmo introduzido por Mumford e Shah [40] é um método de crescimento de região muito utilizado na segmentação de imagem, devido aos seus resultados precisos, apesar de ter como desvantagem um longo tempo de processamento [6, 51]. Consiste em separar a imagem em várias regiões dependendo da sua variação de intensidades. Considerando Ω o domínio da imagem, Ω_i representa a decomposição de várias regiões suavizadas, ou seja, $\Omega = \Omega_1 \cup \Omega_2 \cup \dots \cup \Omega_n \cup k$, sendo o k a fronteira entre as regiões. Esta técnica é baseada em funcional de energia descrita como:

$$E(u, k) = \int \int_{\Omega} |u(x, y) - g(x, y)|^2 dx dy + \int \int_{\frac{\Omega}{k}} |\nabla u(x, y)|^2 dx dy + \lambda l(k) \quad (3.23)$$

onde:

- $E(u, k)$ é a energia do funcional do Mumford-Shah para u e k ;
- $u(x, y)$ é uma função diferenciável dentro de cada região Ω_i , seu valor é constante e obtido pela média das intensidades dos pontos de $g(x, y)$ dentro da região;
- $g(x, y)$ é o gradiente em um determinado ponto (x, y) , tendo valor baixo quando o ponto se localiza dentro da região e valor elevado nas fronteiras;
- $l(k)$ é o comprimento total das fronteiras entre as regiões, sendo reduzidas quando as regiões vão sendo fundidas;
- λ é um parâmetro, que é incrementado a cada iteração;
- $dx dy$ representa o diferencial de x e y .

O primeiro termo da Equação 3.23, $\int \int_{\Omega} |u(x, y) - g(x, y)|^2 dx dy$, é responsável por verificar se u é uma boa aproximação de g , pois quanto maior essa aproximação, menor será sua contribuição para o valor de energia, ou seja, isso ocorre no caso de regiões semelhantes, indicando que podem ser unidas. O segundo termo da equação, $\int \int_{\frac{\Omega}{k}} |\nabla u(x, y)|^2 dx dy$, obtém a variação mínima de u dentro de cada região sem a borda. Devido u ter sempre um valor constante, não havendo variações, este termo sempre terá valor nulo. No caso do terceiro termo, $l(k)$, é calculado o comprimento das fronteiras, sendo

multiplicado por um parâmetro λ . Quanto maior o seu valor, maior será sua contribuição para o valor de energia.

Uma forma reduzida do funcional, da Equação 3.23, é obtida pela restrição do valor de energia $E(u, k)$ para as funções constantes u de cada parte (região) da imagem Ω_i . Este caso reduzido, posposto por Mumford e Shah [40] para solucionar o chamado “problema de partição mínima”, ou seja, problema de minimização da função de energia, é definido da seguinte forma:

$$E(k) = \sum_i \int \int_{\Omega_i} ||u - c_i||^2 dx dy + \lambda l(k) \quad (3.24)$$

onde $c_i = média(u)$ em cada componente Ω_i . O funcional de energia $E(k)$ assume apenas k , sendo u uma constante dentro de cada região.

3.5 Modelo de contorno ativo *Level Set*

Os modelos de contornos ativos, conhecidos como *snakes*, foram propostos na década de 80 pelos autores Kass, Witkin e Terzopoulos [33], para solucionar problemas de segmentação de imagens. Este modelo utiliza funcionais $\int$ para minimização de energias internas e externas da imagem, fazendo com que uma curva sobreposta a mesma se mova em direção a seus objetos. A função de minimização de energia pode ser definida conforme o cálculo de variação por meio da equação de *Euler-Langrange* e discretizada por diferenças finitas. O processo de movimentação da curva caracteriza esse modelo como deformável, que pode ser classificado em paramétrico ou geométrico conforme a maneira usada para movimentá-la.

Os modelos deformáveis paramétricos acompanham a evolução da curva por meio dos pontos do contorno encontrado. Este processo considerado explícito permite o desenvolvimento de aplicações em tempo real, além de possuir alta eficiência computacional. Uma das técnicas que utiliza este modelo é o contorno ativo tradicional, posposto Kass, Witkin e Terzopoulos [33].

Os modelos deformáveis geométricos manipulam facilmente a mudança topológica da curva e calculam as propriedades geométricas do contorno implicitamente. Este modelo elimina a influência de ruídos, evita perda do resultado da borda, melhora a precisão e

eficiência, pois os algoritmos são mais automáticos e possui menos dependência das condições iniciais.

O modelo *Level Set* [48] é um exemplo de modelo deformável geométrico, utilizado na segmentação de imagens, para detectar a borda dos objetos, por meio de uma curva que é deformada em sentido à borda até encontra-lá. O *Level Set* é um modelo de contorno ativo para deformação geométrica, proposto por Osher e Sethian [48] para manipular mudanças topológicas durante a evolução da curva, uma das limitações dos modelos deformáveis paramétricos, como o contorno ativo tradicional. Devido as suas vantagens, como, a facilidade de detecção de propriedades geométrica, o modelo *Level Set* é abordado em vários trabalhos [20, 65].

A curva C é representada implicitamente pela função $\phi(x, y, t)$, tendo sua evolução no nível zero no instante t , sendo $C = \{(x, y) | \phi(x, y) = 0\}$, onde $C \subset \Omega$. A evolução da curva C segue algumas condições, tais como:

$$C = \{(x, y) \in \Omega: \phi(x, y) = 0\} \quad (3.25)$$

$$C(dentro) = \{(x, y) \in \Omega: \phi(x, y) > 0\} \quad (3.26)$$

$$C(fora) = \{(x, y) \in \Omega: \phi(x, y) < 0\} \quad (3.27)$$

Essas condições são apresentadas na Figura 3.4. Quando $\phi(x, y) > 0$, indica que o ponto $(x, y) \in \Omega$ está dentro da curva C . Se $\phi(x, y) < 0$, ou seja, valor negativo, o ponto $(x, y) \in \bar{\Omega}$ está fora da curva C . No caso de $\phi(x, y) = 0$, o ponto $(x, y) \in \partial\Omega$ está localizado sobre a curva C .




Figura 3.4: Representação da curva [20].

O modelo *Level Set* variacional proposto por Zhao et al [65] se baseia nas funções de Heaviside H e de Dirac δ para definir o comprimento da curva $(\partial\Omega)$ e a área da região (Ω) dentro da mesma, que são utilizadas para estabelecer uma função de energia na evolução da curva. Sendo:

$$\text{comprimento}(\partial\Omega) = \iint \delta(\phi(x, y)) |\nabla\phi(x, y)| \, dx \, dy \quad (3.28)$$

$$\text{area}(\Omega) = \iint H(\phi(x, y)) \, dsdy \quad (3.29)$$

onde δ é a função de Dirac, dada por:

$$\delta(x) = \frac{d}{dx} H(x) \quad (3.30)$$

e $H(x)$ é a função Heaviside, sendo

$$H(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (3.31)$$

3.6 Modelo Chan-Vese

Este método é um modelo de contorno ativo sem bordas, proposto por Chan e Vese [20] para segmentação baseada em região e detecção de objetos em uma imagem. O modelo se baseia na técnica de segmentação Mumford-Shah e também no método *Level Set*, para representar a curva. As principais vantagens desta técnica são:

- A posição da curva inicial pode ser definida em qualquer lugar da imagem;
- Os contornos interiores são automaticamente detectados, sem a necessidade de introduzir uma nova curva na imagem, ao contrário do *Level Set*;
- Detecção de diferentes objetos com variadas intensidades e ainda com fronteiras borradas;
- Mudança topológica automática da curva;
- Detecção de objetos onde o contorno não possui gradiente, devido ao critério de parada da evolução da curva até a fronteira desejada não depender do

gradiente da imagem. Isso não é possível com a utilização do modelo tradicional;

- Tem-se um bom resultado na detecção dos objetos em imagens com ruídos.

O modelo Chan-Vese se baseia na segmentação para a minimização de energia. Considerando uma curva C , como uma fronteira que separa o domínio da imagem Ω em dois subconjuntos ω e $\bar{\omega}$, sendo ω a região fora da curva C e $\bar{\omega}$ representa a região dentro da curva C , onde $\omega \subset \Omega$ e $C = \partial\omega$. Este modelo basicamente considera um termo “apropriado” F de energia funcional (Equação 3.32) utilizado para a minimização da energia, que faz com que a curva C se deforme em sentido a fronteira C_0 de uma imagem u_0 com regiões de intensidades u_0^i constantes e aproximadas.

$$F = F_1(C) + F_2(C) \quad (3.32)$$

sendo $F_1(C)$ e $F_2(C)$ a localização da curva C , se está dentro ou fora do objeto, respectivamente. São calculados por funcionais da seguinte forma:

$$F = \int_{dentro(C)} |u_0(x, y) - c_1|^2 dx dy + \int_{fora(C)} |u_0(x, y) - c_2|^2 dx dy \quad (3.33)$$

onde c_1 é a média da imagem u_0 dentro da curva C e c_2 a média fora da curva. Desta forma, podemos visualizar na Figura 3.5 os resultados do termo “apropriado” F para as possíveis posições da curva. O objeto é representado pela cor preta e a curva pelo círculo branco.

Se o $F_1(C) > 0$ e $F_2(C) \approx 0$, então a curva está localizada fora do objeto, como no caso da Figura 3.5(a). Na Figura 3.5(b), temos uma curva dentro do objeto, sendo $F_1(C) \approx 0$ e $F_2(C) > 0$. Quando a curva se encontra dentro e fora do objeto, como no caso da Figura 3.5(c), $F_1(C) > 0$ e $F_2(C) > 0$. Outra situação é quando $F_1(C) \approx 0$ e $F_2(C) \approx 0$, neste caso, Figura 3.5(d), o termo de energia $F = 0$ está minimizado, ou seja, a curva C está sobre a fronteira C_0 .




Figura 3.5: O termo apropriado para possíveis posições da curva. Em (a), (b) e (c) o termo apropriado $F > 0$ e somente em (d) a curva está sobre o objeto, quando $F = 0$ [20].

Para a minimização do termo de energia apropriado, utiliza-se o modelo de contorno ativo, baseado na segmentação de Mumford-Shah, explicado anteriormente, com o complemento de alguns termos de regularização, como o comprimento da curva $L(C)$ e a área da região dentro da curva $A(dentro(C))$. Então a energia funcional $F(c_1, c_2, C)$ é representada por:

$$F(c_1, c_2, C) = \mu \cdot L(C) + \nu \cdot A(dentro(C)) + \lambda_1 \int_{dentro(C)} |u_0(x, y) - c_1|^2 dx dy + \lambda_2 \int_{fora(C)} |u_0(x, y) - c_2|^2 dx dy \quad (3.34)$$

tendo como parâmetros fixos μ e $\nu \geq 0$ e λ_1 e $\lambda_2 > 0$, que auxiliam cada termo, respectivamente, em seus resultados.

Considerando que o modelo Chan-Vese também possui o problema de partição mínima, como no Mumford-Shah, pois busca a melhor aproximação da região u da imagem u_0 , tendo apenas dois valores, sendo:

$$u = \begin{cases} \text{média}(u_0) \text{ dentro de } C \\ \text{média}(u_0) \text{ fora de } C \end{cases} \quad (3.35)$$

Para resolver este problema, o modelo utiliza a formulação variacional do método *Level Set*, apresentada na seção anterior, para substituir a variável desconhecida C pela variável desconhecida ϕ . Definidos os termos de comprimento $L(C)$ e área $A(\text{dentro}(C))$ da Equação 3.34 a partir das funções de Dirac δ (Equação 3.30) e Heaviside H (Equação 3.31), se obtêm a seguinte funcional de energia *Level Set* $F(c_1, c_2, \phi)$:

$$\begin{aligned} F(c_1, c_2, \phi) = & \mu \int_{\Omega} \delta(\phi(x, y)) |\nabla \phi(x, y)| dx dy + \nu \int_{\Omega} H(\phi(x, y)) dx dy \\ & + \lambda_1 \int_{\Omega} |u_0(x, y) - c_1|^2 H(\phi(x, y)) dx dy \\ & + \lambda_2 \int_{\Omega} |u_0(x, y) - c_2|^2 (1 - H(\phi(x, y))) dx dy \end{aligned} \quad (3.36)$$

onde as constantes c_1 e c_2 , respectivamente, são expressas por:

$$c_1(\phi) = \frac{\int_{\Omega} u_0(x, y) H(\phi(x, y)) dx dy}{\int_{\Omega} H(\phi(x, y)) dx dy} \quad (3.37)$$

$$c_2(\phi) = \frac{\int_{\Omega} u_0(x, y) (1 - H(\phi(x, y))) dx dy}{\int_{\Omega} (1 - H(\phi(x, y))) dx dy} \quad (3.38)$$

A Equação Diferencial Parcial (EDP) define o contorno inicial, utilizando a equação Euler-Lagrange para a evolução da função *Level Set* ϕ que minimiza o termo de energia apropriado, representada pela seguinte forma derivativa:

$$\frac{\partial \phi}{\partial t} = \delta(\phi) \left[\mu \operatorname{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) - \nu - \lambda_1 (u_0 - c_1)^2 + \lambda_2 (u_0 - c_2)^2 \right] \quad (3.39)$$

A Equação 3.39 é discretizada utilizando diferenças finitas, considerando $\phi_{i,j}^n$ para a função de *Level Set* no *pixel* (i, j) com n iterações. Tendo as seguintes notações:

$$\Delta_-^x \phi_{i,j}^n = \phi_{i,j}^n - \phi_{i-1,j}^n \quad (3.40)$$

$$\Delta_-^y \phi_{i,j}^n = \phi_{i,j}^n - \phi_{i,j-1}^n \quad (3.41)$$

$$\Delta_+^x \phi_{i,j}^n = \phi_{i+1,j}^n - \phi_{i,j}^n \quad (3.42)$$

$$\Delta_+^y \phi_{i,j}^n = \phi_{i,j+1}^n - \phi_{i,j}^n \quad (3.43)$$

A discretização da Equação Diferencial Parcial para a minimização da função de energia apropriada é dada pela Equação 3.44.

$$\begin{aligned} \frac{\phi_{i,j}^{n+1} - \phi_{i,j}^n}{\Delta t} = & \delta^h(\phi_{i,j}^n) \left[\frac{\mu}{h^2} \Delta_-^x \cdot \left(\frac{\Delta_+^x \phi_{i,j}^{n+1}}{\sqrt{\frac{(\Delta_+^x \phi_{i,j}^n)^2}{(h^2)} + \frac{(\phi_{i,j+1}^n - \phi_{i,j-1}^n)^2}{(2h)^2}}} \right) + \frac{\mu}{h^2} \Delta_-^y \cdot \left(\frac{\Delta_+^y \phi_{i,j}^{n+1}}{\sqrt{\frac{(\phi_{i+1,j}^n - \phi_{i-1,j}^n)^2}{(2h^2)} + \frac{(\Delta_+^y \phi_{i,j}^n)^2}{(h)^2}}} \right) - \right. \\ & \left. v - \lambda_1 \left(u_{0,i,j} - c_1(\phi^n) \right)^2 + \lambda_2 \left(u_{0,i,j} - c_2(\phi^n) \right)^2 \right] \quad (3.44) \end{aligned}$$

Para cada iteração, pode ser realizada a reinicialização de ϕ para o conjunto de nível zero, prevenindo que a função *Level Set* se torne muito plana, um efeito causado pela utilização da função delta Dirac δ^h , sendo aplicado a seguinte função de distância de sinal:

$$\psi_\tau = \text{sign}(\phi(t))(1 - |\nabla \psi|) \quad (3.45)$$

$$\psi(0) = \phi(t) \quad (3.46)$$

onde $\phi(t)$ é a solução ϕ no tempo t , tendo ψ a cada novo $\phi(t)$. O ψ_τ da Equação 3.45 terá o mesmo sinal de $\phi(t)$ e a distância $\nabla \psi$ é convertida para 1.

Para a aplicação deste modelo, os seguintes passos são realizados:

- Inicialização de $\phi_{i,j}^n$ da função ϕ_0 com $n = 0$;
- Cálculo de c_1 e c_2 expressas pelas Equações 3.37 e 3.38 respectivamente;
- Execução do Equação Diferencial Parcial (EDP) da forma discretizada da Equação 3.44;
- Reinicialização de $\phi_{i,j}^{n+1}$ usando a função de distância de sinal da Equação 3.45;

- Verificar se a solução é satisfatória, se não, define-se $n = n + 1$ e repete os processos.

O resultado da aplicação do modelo Chan-Vese para imagens em níveis de cinza pode visto na Figura 3.6.




Figura 3.6: Resultado da aplicação do modelo Chan-Vese. (a) Imagem original e (b) Imagem binarizada.

Na imagem da Figura 3.6(b) temos um exemplo de imagem binarizada a partir da aplicação do modelo Chan-Vese para imagens em níveis de cinza, conforme a imagem da Figura 3.6(a). A cor preta da imagem binarizada representa a lesão e a cor branca representa a pele.

3.7 Dimensão fractal

A teoria fractal é aplicada tanto em sinais 1D, tais como, voz, áudio e outros, como também em sinais 2D, isto é imagens, para descrever propriedades texturais. O fractal, abordado primeiramente por Mandelbrot, representa um objeto geométrico que pode ser dividido em várias partes, onde cada parte é similar ao objeto maior [2]. Um exemplo, que pode ser encontrado na natureza, é o de algumas plantas que possuem suas folhas compostas por folhas menores similares a mesma. Um outro exemplo é o triângulo de Sierpinski, que pode ser visto na Figura 3.7.



Figura 3.7: Composição do triângulo de Sierpinski [29].

A dimensão fractal (D) é uma medida que quantifica o nível de irregularidade ou auto-similaridade dos fractais. A dimensão fractal é dada por:

$$D = \frac{\log(N)}{\log(1/T)} \quad (3.47)$$

onde N representa a quantidade de elementos das partes auto-similares que reconstrói a imagem original e T representa a quantidade de quadrantes correspondente a uma fração do tamanho anterior.

Existem diversas técnicas para estimar a dimensão fractal. O método *box-counting* (BCM), desenvolvido por Voss, é um dos algoritmos mais populares para calcular a dimensão fractal de sinais e imagens [2]. Essa técnica caracteriza-se, basicamente, pela definição de uma grade com n caixas sobre a imagem, para manter o sinal em um quadrado, e então é feita uma contagem da quantidade de caixas que cobrem o fractal para representar a dimensão (D). Esse processo é feito por um processo iterativo, ao qual o tamanho das caixas vai se reduzindo, conforme cada iteração.

O algoritmo *box-counting* utiliza o método de mínimos quadrados para ajustar os dados em um gráfico e obter uma reta média, com o objetivo de encontrar o coeficiente angular b da reta, dada uma constante c , conforme a aplicação da Equação 3.48.

$$\hat{f}_i = bx_i + c \quad (3.48)$$

O termo $\hat{f}_i$ é a aproximação da função real f_i , considerando i o seu número de elementos. O erro de mínimos quadrados (e) é dado por:

$$e = \sum_i (f_i - \hat{f}_i)^2 \quad (3.49)$$

Para encontrar o melhor ajuste, o erro "e" deve ser minimizado, por meio da seguinte equação:

$$\frac{\partial E}{\partial b} = 0 \text{ e } \frac{\partial E}{\partial c} = 0 \quad (3.50)$$

A diferenciação entre b e c é realizada pelas Equações 3.51 e 3.52:

$$\sum_i x_i (f_i - bx_i - c) = 0 \quad (3.51)$$

$$\sum_i (f_i - bx_i - c) = 0 \quad (3.52)$$

Considerando as Equações 3.51 e 3.52, a solução para b e c é dado por:

$$b = \frac{N \sum_i f_i x_i - (\sum_i f_i)(\sum_i x_i)}{N \sum_i x_i^2 - (\sum_i x_i)^2} \quad (3.53)$$

$$c = \frac{\sum_i f_i - b \sum_i x_i}{N} \quad (3.54)$$

No caso de imagens, é encontrada a dimensão de cada linha e coluna da matriz, separadamente, depois é aplicada a Equação 3.55.

$$D = \left(\frac{\sum_i D_i}{t} \right) + 1 \quad (3.55)$$

onde é feito o somatório de todas as dimensões fractais (D_i) encontradas, dividindo-se o valor pela quantidade total (t) de dimensões da imagem. O valor resultante é somado com 1, obtendo-se um valor entre 2 e 3.

A dimensão fractal permite medir a auto-similaridade ou irregularidade presente na imagem. A aplicação do algoritmo de *box-counting* possibilita quantificar a textura da imagem de forma simples e eficiente.

4 MÁQUINA DE VETOR DE SUPORTE

Neste capítulo será abordada a máquina de vetor de suporte, um classificador que se baseia no aprendizado estatístico para o reconhecimento de padrões. O padrão é a descrição do objeto de interesse em uma imagem de forma quantitativa ou estrutural por meio de descritores [30]. As descrições estruturais podem ser representadas por cadeias ou árvores, e no caso das descrições quantitativas, são utilizados os vetores de características. As suas características podem ser do tipo: nominal ou contínua [35]. A característica é considerada nominal quando os valores não assumem uma ordem e considerada contínua nos casos onde os valores possuem uma ordem linear. O reconhecimento de padrões é a atribuição dos padrões a sua classe correspondente, ou seja, cada classe é definida por um conjunto de padrões que possuem propriedades em comum.

As Máquinas de Vetores de Suporte (SVMs - *Support Vector Machines*) vem sendo muito utilizadas em diversos trabalhos, devido aos bons resultados [5, 19, 36, 52, 60]. As SVMs, que podem ser implementadas como um tipo especial de rede neural artificial (RNA), são sistemas paralelos distribuídos que são compostos por unidades de processamento simples, às quais correspondem os neurônios. Dessa forma, as RNAs, também conhecidas como redes conexionistas, têm por objetivo simular o funcionamento dos elementos do cérebro, tais como os neurônios e as suas conexões, que são conhecidas como sinapses.

A SVM é um classificador binário, ou seja, permite a classificação entre duas classes. Esse classificador é baseado em aprendizado estatístico, que podem ser utilizadas no reconhecimento de padrões em imagens. Para que o classificador tenha uma boa generalização, ou seja, identifique corretamente as classes das novas amostras de dados inseridas, devem ser seguidos alguns princípios da teoria de aprendizado estatístico.

Este classificador pode ser aplicado em casos linearmente separáveis e também para casos não linearmente separáveis. Nos casos em que os dados não são linearmente separáveis, a utilização das funções de *Kernel* torna possível os dados serem tratados de forma computacional.

4.1 Aprendizado da máquina

Os métodos de aprendizado de máquinas utilizam o modelo de inferência, onde o aprendizado pode ser por indução, que é o mais utilizado no reconhecimento de padrão, sendo as conclusões obtidas a partir de fatos concretos. O aprendizado pode ser dividido em supervisionado e não supervisionado [9].

No aprendizado supervisionado um agente externo controla o aprendizado da máquina, sendo apresentado para a rede um conjunto de padrões para o treinamento e a saída desejada. O agente indica se a resposta está correta ou não, tendo possibilidade de alterar os seus parâmetros, conforme a resposta, com finalidade de que a máquina seja capaz de produzir saídas corretas quando passadas entradas não conhecidas. No aprendizado não supervisionado não há a presença de um agente externo. O algoritmo aprende a representar as entradas fornecidas, por uma medida de qualidade, com o objetivo de encontrar padrões que auxiliem na compreensão dos dados.

Considere um conjunto de n amostras de dados (X_i) que são utilizadas para gerar um classificador a partir do aprendizado supervisionado, conforme pode ser visto na Figura 4.1. Cada amostra X_i é composta por m atributos (características), representados por x_{im} e a classe a qual pertence y_i . Estas informações são utilizadas para o treinamento do classificador, que realiza uma função $f(x)$, onde recebe um valor x e fornece um resultado y .




Figura 4.1: Representação de aprendizado supervisionado [35].

O conjunto de amostras geralmente é dividido em duas partes, uma para o treinamento e outra para os testes. As amostras de treinamento são utilizadas para o aprendizado do classificador e as amostras de testes são utilizadas para medir a capacidade do aprendizado, referente à introdução de novas amostras. Para avaliar o resultado fornecido pelo classificador sobre os novos dados introduzidos, é estimada a taxa de acerto e a taxa de erro.

4.2 Aprendizado estatístico

O aprendizado estatístico estabelece condições matemáticas que permitem a escolha de um classificador particular $\hat{f}$, dentre um conjunto de outras possibilidades de classificadores F gerados por um algoritmo de aprendizagem. O classificador separa os dados das classes, a partir de um conjunto de treinamento T [35].

Na Figura 4.2 tem-se três classificações diferentes de um treinamento binário, onde os círculos são dados de uma classe (com valor 1), os pontos pretos são dados de outra classe (com valor -1) e os círculos e pontos marcados com um x são ruídos. Esses dados são separados por uma fronteira.




Figura 4.2: Exemplos de classificação binária [57].

No caso da Figura 4.2(a), o classificador desconsidera pontos de outra classe que estejam próximos entre si, ocorrendo um subajustamento (*underfitting*), ou seja, o classificador não consegue se ajustar mesmo aos exemplos de treinamento, causando assim muitos erros, até mesmo em casos simples. Já na Figura 4.2(c) temos uma classificação correta das amostras do conjunto de treinamento, incluindo até mesmo os ruídos marcados com um círculo. Mas neste caso o classificador está sujeito a cometer erros quando se depara

com novos dados, pois ocorre um superajustamento (*overfitting*) do modelo aos dados de treinamento. Uma boa generalização é apresentada na Figura 4.2(b), que classifica corretamente a maioria dos dados, sem se preocupar com pontos individuais (ruídos).

Para a escolha de um classificador, deve ser avaliada sua capacidade de generalização. Considera-se que os dados são gerados de forma independente e distribuídos por probabilidades $P(X, y)$, de acordo com os seus dados X e classes y . A capacidade de generalização é medida pelo erro ou risco esperado $R(f)$ de um classificador f em condições de teste, que pode ser quantificado pela Equação 4.1 [35].

$$R(f) = \int c(f(X), y) dP(X, y) \quad (4.1)$$

onde $c(f(X), y)$ é uma função de custo relacionada a previsão $f(X)$ quando a saída é y . Essa função pode ser representada por $c(f(X), y) = \frac{1}{2} |y - f(X)|$, que retorna 0 quando sua classificação for correta e 1 quando isso não ocorrer.

Devido a distribuição de probabilidade $P(X, y)$ ser desconhecida, não é possível minimizar diretamente o risco esperado como demonstrado na Equação 4.1. Dessa forma, é utilizado um princípio de indução sobre os dados de treinamento para minimização do risco empírico R_{emp} . Este princípio mede o desempenho do classificador f , por meio de taxa de classificações incorretas obtidas pelo conjunto de treinamento T . O risco empírico é definido por:

$$R_{emp}(f) = \frac{1}{n} \sum_{i=1}^n c(f(X_i), y_i) \quad (4.2)$$

onde $n \rightarrow \infty$ é a quantidade de amostras de pares (X_i, y_i) , sendo possível estabelecer condições para que o algoritmo de aprendizagem obtenha classificadores que transferem os valores de risco empíricos para o risco esperado. Apesar da minimização do risco empírico causar um menor risco esperado, isso pode não ocorrer em todos os casos. Dessa forma, para a escolha de um classificador, a teoria de aprendizado estatístico disponibiliza vários limites no risco esperado de uma função de classificação, nos quais a SVM se baseia.

A característica de um dos mais importantes desses limites é relacionar o risco esperado $R(f)$ de uma função ao seu risco empírico $R_{emp}(f)$ e também a um termo de

capacidade, como pode ser visto na Equação 4.3. Esse limite é garantido com probabilidade $1 - \theta$, onde $\theta \in [0,1]$.

$$R(f) \leq R_{emp}(f) + \sqrt{\frac{h\left(\ln\left(\frac{2n}{h}\right)+1\right)-\log\left(\frac{\theta}{4}\right)}{n}} \quad (4.3)$$

sendo $\sqrt{\frac{h\left(\ln\left(\frac{2n}{h}\right)+1\right)-\ln\left(\frac{\theta}{4}\right)}{n}}$ o termo de capacidade, onde h é a dimensão de Vapnik-Chervonenkis (VC) da classe de funções F à qual o classificador f pertence e n é a quantidade de amostras que o conjunto de treinamento T possui. Esse limite utiliza a dimensão VC para controlar a complexidades das funções de classificação, de forma que possam ser adaptadas a cada problema. Em um problema de classificação binário, a dimensão VC é definida com o número máximo de amostras que podem ser divididas em duas classes pelas funções contidas em F , para todas as combinações binárias possíveis dos dados.

As SVMs podem ser classificadas de duas maneiras: lineares, quando os dados são separáveis linearmente e não lineares quando lida com dados que não são separáveis linearmente.

4.3 SVMs lineares

As Máquinas de Vetores de Suporte lineares são utilizadas para definir fronteiras para a separação de dados que pertencem a duas classes, lidando com dados linearmente separáveis. Considerando um conjunto de treinamento T com n amostras de dados $x_i \in X$ e suas respectivas classes $y_i \in Y$, sendo X o espaço de dados e $Y = \{-1, +1\}$. Neste caso o conjunto de dados T é linearmente separável por um classificador, quando é possível separar os dados conforme suas classes -1 e $+1$ por um hiperplano [17, 35]. A Equação 4.4 define o hiperplano:

$$f(x) = w \cdot x + b = 0 \quad (4.4)$$

onde $w \cdot x$ é o produto escalar entre os vetores w e x , $w \in X$ é o vetor normal ao hiperplano e b determina a distância do hiperplano em relação à origem, sendo $b \in \mathbb{R}$. A equação $f(x)$ divide o espaço dos dados X em duas regiões, determinadas por $w \cdot x + b > 0$ e $w \cdot x + b < 0$.

0. Dessa forma, as classificações podem ser obtidas por uma função de sinal $g(x) = \text{sgn}(f(x))$, tendo as seguintes condições:

$$g(x) = \begin{cases} +1 & \text{se } w \cdot x + b > 0 \\ -1 & \text{se } w \cdot x + b < 0 \end{cases} \quad (4.5)$$

Um número infinito de hiperplanos pode ser definido por $f(x)$. Para solucionar este problema, w e b são escalados para que as amostras mais próximas ao hiperplano $w \cdot x + b = 0$ satisfaçam $|w \cdot x_i + b| = 1$, definida resumidamente da por:

$$y_i(w \cdot x_i + b) - 1 \geq 0, \quad \forall (x_i, y_i) \in T \quad (4.6)$$

Na Figura 4.3 pode ser visto um exemplo de distância d entre dois hiperplanos H_1 e H_2 , estabelecidos conforme os pontos x_1 e x_2 respectivamente. Essa distância é obtida pela projeção de $x_1 - x_2$ na direção de w , perpendicular ao hiperplano separador $w \cdot x + b = 0$.




Figura 4.3: Distância entre dois hiperplanos H_1 e H_2 [35].

Essa distância entre o hiperplano separador e os dados de treinamento é definida como a margem geométrica do classificador linear, podendo ser obtida pela minimização de $\|w\|$, que acarreta um problema de otimização. Para assegurar que não haja dados de treinamento entre as margens de separação das classes, algumas restrições são impostas, como $y_i(w \cdot x_i + b) - 1 \geq 0$, sendo $\forall i = 1, \dots, n$.

O problema de otimização pode ser resolvido utilizando função Lagrangiana L que engloba as restrições e parâmetros multiplicadores de Lagrange α_i , sendo definida por:

$$L(w, b, \alpha) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^n \alpha_i (y_i (w \cdot x_i + b) - 1) \quad (4.7)$$

A função Lagrangiana deve ser minimizada, ou seja, maximizar α_i e minimizar w e b , obtendo as seguintes expressões:

$$\sum_{i=1}^n \alpha_i y_i = 0 \quad (4.8)$$

$$w = \sum_{i=1}^n \alpha_i y_i x_i \quad (4.9)$$

Conforme as Equações 4.8 e 4.9, temos um problema de otimização, sendo solucionado por:

$$\alpha_i^* (y_i (w^* \cdot x_i + b^*) - 1) = 0, \quad \forall i = 1, \dots, n \quad (4.10)$$

$$b^* = \frac{1}{n_{SV}} \sum_{x_j \in SV} \left(\frac{1}{y_j} - \sum_{x_i \in SV} \alpha_i^* y_i x_i \cdot y_j \right) \quad (4.11)$$

sendo w^* definido pela Equação 4.9. O parâmetro b^* é calculado a partir das condições da Equação 4.11 e por condições Hühn-Tucker, provenientes da teoria de otimização com restrições e que devem ser satisfeitas no ponto ótimo. Obtemos o classificador $g(x)$, onde sgn representa a função sinal, da seguinte forma:

$$g(x) = sgn(f(x)) = sgn\left(\sum_{x_i \in SV} y_i \alpha_i^* x_i \cdot x + b^*\right) \quad (4.12)$$

A função linear representa o hiperplano que separa os dados com a maior margem, considerando a que possui melhor capacidade de generalização de acordo com a aprendizagem estatística.

4.4 SVMs não lineares

As Máquinas de Vetores de Suporte não lineares são uma extensão das lineares [17, 35]. Em algumas situações os dados de treinamento não podem ser divididos por um hiperplano, ou seja, os dados não são linearmente separáveis, como podemos visualizar na Figura 4.4(a). Na Figura 4.4(a) temos a amostra de dados, representando duas classes, uma por círculo e a outra por triângulo. Nesse caso, uma fronteira circular seria uma forma de separar as classes, como pode ser visto na Figura 4.4(b). Mas para solucionar este problema de dados não linearmente separáveis por um reta, o conjunto de entrada em um espaço original é mapeado para um novo espaço de maior dimensão, denominado espaço de característica. Este caso é apresentado na Figura 4.4(c).




Figura 4.4: Conjunto de dados não lineares [35].

Este mapeamento é representado por $\Phi: X \rightarrow \mathfrak{Z}$, sendo X o espaço de entrada e $\mathfrak{Z}$ o espaço de características. Dessa forma é possível tornar os dados linearmente separáveis e utilizar um hiperplano para separar os dados conforme as respectivas classes. Para transformar os dados $\mathfrak{R}^2$ para $\mathfrak{R}^3$, ou seja, mapear os dados não lineares para lineares, pode ser utilizada, por exemplo, a Equação 4.13.

$$\Phi(x) = \Phi(x_1, x_2) = (x_1^2, \sqrt{2}x_1x_2, x_2^2) \quad (4.13)$$

Depois de realizado o mapeamento dos dados para um espaço de característica $\mathfrak{Z}$, é possível encontrar o hiperplano e separar os dados, como segue:

$$f(x) = w \cdot \Phi(x) + b = w_1x_1^2 + w_2\sqrt{2}x_1x_2 + w_3x_2^2 + b = 0 \quad (4.14)$$

O classificador é então obtido pela Equação 4.15.

$$g(x) = \text{sgn}(f(x)) = \text{sgn}\left(\sum_{x_i \in SV} \alpha_i^* y_i \Phi(x_i) \cdot \Phi(x) + b^*\right) \quad (4.15)$$

sendo b^* definido por:

$$b^* = \frac{1}{n_{SV:\alpha^* < C}} \sum_{x_j \in SV:\alpha_j^* < C} \left(\frac{1}{y_j} - \sum_{x_i \in SV} \alpha_i^* y_i \Phi(x_i) \cdot \Phi(x_j) \right) \quad (4.16)$$

4.5 Funções *Kernels*

O mapeamento dos dados não lineares para lineares Φ pode se muito complexo devido à grande dimensão do espaço de característica $\mathfrak{F}$. Dessa forma, para realizar o cálculo de produtos escalares $\Phi(x_i) \cdot \Phi(x_j)$ entre os dados no espaço de característica são utilizadas funções *Kernels*.

O *Kernel* K é uma função que recebe dois pontos x_i e x_j do espaço de entrada e calcula o seu produto escalar no espaço de característica [35], sendo dada por:

$$K(x_i, x_j) = \Phi(x_i) \cdot \Phi(x_j) \quad (4.17)$$

Para mapear os dados, conforme a Equação 4.17, o *Kernel* dos dois pontos $x_i = (x_{1i}, x_{2i})$ e $x_j = (x_{1j}, x_{2j})$ no espaço original $\mathfrak{R}^2$, pode ser dado por:

$$K(x_i, x_j) = (x_{1i}^2, \sqrt{2}x_{1i}x_{2i}, x_{2i}^2) \cdot (x_{1j}^2, \sqrt{2}x_{1j}x_{2j}, x_{2j}^2) = (x_i \cdot x_j)^2 \quad (4.18)$$

Há várias funções de *Kernels* $K(x_i, x_j)$. Alguns dos tipos são o Polinomial, o Gaussiano (ou RBF - *Radial-Basis Function*), o Sigmoidal [35] e o Intersecção por histograma [12]. Essas funções são dadas pelas Equações 4.19, 4.20, 4.21 e 4.22, respectivamente.

$$K(\mathbf{x}_i, \mathbf{x}_j) = (\delta(\mathbf{x}_i \cdot \mathbf{x}_j) + k)^d \quad (4.19)$$

$$K(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\sigma \|\mathbf{x}_i - \mathbf{x}_j\|^2) \quad (4.20)$$

$$K(\mathbf{x}_i, \mathbf{x}_j) = \tanh(\delta(\mathbf{x}_i \cdot \mathbf{x}_j) + k) \quad (4.21)$$

$$K(\mathbf{x}_i, \mathbf{x}_j) = \sum_{i=1}^n \min\{\mathbf{x}_i, \mathbf{x}_j\} \quad (4.22)$$

sendo δ , k , d e σ parâmetros que são determinados pelos. As limitações dessa técnica são justamente as escolhas dos valores para esses parâmetros, além da dificuldade de interpretação do modelo gerado [35].

A utilização das funções de *Kernel* para dados não separáveis linearmente torna o algoritmo eficiente, devido a construção de simples hiperplanos em um espaço com alta dimensão, sendo possível ser tratados de forma computacional.

5 MÉTODO DESENVOLVIDO

Neste capítulo apresenta-se o método desenvolvido para segmentação e classificação de lesões de pele, com intuito de auxiliar o dermatologista no seu diagnóstico. Na Figura 5.1, temos a estrutura do método desenvolvido. Este método é baseado nas etapas de processamento de imagens digitais, apresentadas na Figura 3.1.




Figura 5.1: Estrutura do método desenvolvido.

O método desenvolvido possui as seguintes etapas de processamento: aquisição de imagens, pré-processamento, segmentação, pós-processamento, formação do vetor de características e classificação das lesões de pele conforme as suas classes estabelecidas.

Primeiramente são adquiridas imagens para compor o banco de testes. A segunda etapa do método desenvolvido é a suavização das imagens por meio do filtro de difusão anisotrópica, para eliminar os ruídos presentes nas mesmas e não afetar o resultado da segmentação. Depois é realizada a segmentação utilizando o modelo de contorno ativo sem borda Chan-Vese para detectar a lesão. Para suavizar a borda e eliminar ruídos resultantes do processo de segmentação, são aplicados filtros morfológicos nas imagens segmentadas. A partir da lesão detectada é definido o contorno, e também as características, segundo a regra ABCD (Assimetria, Borda, Cor e Diâmetro) e a característica de textura são extraídas. A característica de evolução E da regra ABCDE não será utilizada, devido a base não possuir imagens das mesmas lesões em períodos diferentes. Desta maneira, não foi possível analisar a característica de evolução. As características obtidas são utilizadas como dados de entrada pelo classificador SVM (Máquina de Vetor de Suporte) para classificar as lesões em suas classes.

5.1 Aquisição de imagens

A primeira etapa do método desenvolvido foi a aquisição de imagens para a formação de um banco de imagens de lesões de pele, utilizada para os testes. O banco deste trabalho é formado por imagens das seguintes bases: Loyola University Chicago [38], YSP Dermatology Image Database [24], DermAtlas [23], DermIS [25], Saúde Total [55], Skin Cancer Guide [58] e Dermnet - Skin Disease Atlas [26, 27].

O banco é composto por imagens fotográficas, no formato jpg, com dimensões variadas, diferentes aproximações e diversas influências de ruído, tais como, reflexos, linhas da pele, sangue e pelos. As imagens foram convertidas para BMP com 16 bits e para dimensão 200 x 200, para facilitar o processamento das mesmas. Além das imagens, o banco possui algumas informações sobre elas, como seu diagnóstico, descrição, localização da lesão e também o sexo, idade e raça do paciente. Essas informações sobre as lesões e os pacientes, não são disponibilizadas por todas as bases utilizadas.

O banco utilizado neste trabalho é constituído de 408 imagens, sendo 62 imagens de nevos, 86 imagens de ceratose seborréica e 260 imagens de melanoma. Exemplos de cada um desses tipos de lesões são apresentados na Figura 5.2.




Figura 5.2: Banco de imagens: (a) Nevo melanocítico, (b) Ceratose seborréica e (c) Melanoma.

As imagens do banco foram analisadas pelo especialista Doutor Ricardo Baccaro Rossetti, dermatologista da clínica DERME de São José do Rio Preto. A finalidade da análise foi estabelecer as características de assimetria, borda e cor da regra ABCD e a textura das 408 imagens, considerando que essas informações não foram informadas nas bases utilizadas. A característica de assimetria (A) é representada por 137 imagens simétricas e 271 imagens assimétricas. Na característica de borda (B), 77 imagens possuem bordas regulares e 331 possuem bordas irregulares. Para a característica de cor (C), há 32 imagens com cor uniforme e 376 imagens não uniforme. A textura regular é composta por 224 imagens e a textura irregular é representada por 184 imagens.

5.2 Pré-processamento

Nesta etapa é realizada a suavização nas imagens da base, com o intuito de amenizar os efeitos dos ruídos presentes nas mesmas, como os pelos, que podem atrapalhar no resultado da segmentação. O filtro não linear denominado difusão anisotrópica é utilizado, conforme proposto por Barcelos, Boaventura e Silva [10]. Esse filtro foi escolhido devido ao seu ótimo resultado de suavização nas imagens, sem a perda das bordas das lesões de pele [6, 11]. Visto que uma das características analisadas para o diagnóstico das lesões de pele é a irregularidade da borda, esse filtro se mostra uma eficiente técnica para suavizar as imagens.

Considerando que o método de segmentação utilizado neste trabalho é aplicado para imagens em níveis de cinza, as imagens originais, que antes eram coloridas são convertidas para imagens em níveis de cinza. Dessa forma, o tempo de processamento é menor, visto que não é necessário a suavização nas três componentes RGB, separadamente. Logo, as mesmas passam por um processo de suavização, sendo aplicado o método de difusão anisotrópica, obtendo-se como resultado as imagens suavizadas. As etapas do pré-processamento podem ser vistas na Figura 5.3.



Figura 5.3: Estrutura das etapas do pré-processamento.

A implementação deste filtro foi baseada na Equação 3.12, que possui os seguintes parâmetros: Δt determina o tamanho da evolução temporal, em que cada iteração da difusão será realizada; o parâmetro σ é o desvio padrão da função Gaussiana G_σ ; o parâmetro λ ajuda a reforçar a borda; k auxilia a função gaussiana a definir se o ponto faz parte da borda ou não, caso seja um ponto da borda, este sofrerá menos suavização; e a imagem será suavizada, de acordo com o número de iterações NI .

O resultado da aplicação deste filtro pode ser visto na Figura 5.4. Os parâmetros foram fixados mediante testes, considerando os parâmetros dos trabalhos já desenvolvidos [6, 11], com os seguintes valores: $\Delta t = 0.1$, $\sigma = 1$, $\lambda = 1$, $k = 0.0008$ e $NI = 100$.




Figura 5.4: Resultado da aplicação do filtro de difusão anisotrópica. As imagens em (c), (f) e (i) são resultados da aplicação do filtro nas imagens em níveis de cinza (b), (e) e (h), respectivamente.

As imagens originais (a), (d) e (g) da Figura 5.4 são convertidas para imagens em níveis de cinza, como pode ser visto nas imagens (b), (e) e (h). Em (c), (f) e (i) temos as imagens suavizadas pelo filtro de difusão anisotrópica, a partir das imagens em níveis de cinza. Podemos observar que o filtro diminuiu a presença de pelos nas imagens de lesões de pele, obtendo-se resultados promissores. No caso das imagens que possuem áreas com sombras ou reflexos, como na imagem (c), o filtro não permitiu eliminar a influencias dos mesmos, apesar de amenizar a sua presença.

No filtro proposto por Barcelos, Boaventura e Silva [10], o número de iterações é estabelecido manualmente para cada imagem, considerando sua quantidade de ruídos. Para utilizar a característica de suavização seletiva do filtro, foi analisada uma estimativa automática para definir o número de iterações da difusão anisotrópica, proposto por Araujo [6]. Foi observado pelo autor que, geralmente, o operador de Roberts retorna mais pontos do que o operador de Prewitt. Esta estimativa automática utiliza a diferença de pontos retornados pela aplicação destes operadores, para definir a quantidade de iterações necessárias. Considera-se que quanto maior a quantidade de ruídos, maior é a diferença de pontos entre os operadores.

Nas imagens (c) e (f) da Figura 5.5 são apresentados os resultados da aplicação do filtro de difusão anisotrópica, utilizando a estimativa automática, a partir das imagens em níveis de cinza (b) e (e) da Figura 5.5. O número de iterações é estabelecido conforme a estimativa automática, Equação 3.13.

Podemos observar a partir da Figura 5.5 e da Tabela 5.1, que a utilização da estimativa automática não alcançou um resultado animador para as imagens que compõem o banco deste trabalho. No caso da imagem suavizada (c), a aplicação do filtro não obteve uma suavização proporcional a quantidade de ruídos da imagem em nível de cinza (b). Foram realizadas 6 iterações, conforme visto na Tabela 5.1. A imagem (f) é representada por uma grande quantidade de ruídos, mas foi pouco suavizada. O número de iterações obtidos pelas diferenças de pontos dos operadores foi muito pequeno, permitindo apenas 1 iteração. Neste caso os ruídos não foram amenizados, necessitando de uma maior suavização.




Figura 5.5: Aplicação de difusão anisotrópica com o número de iterações automático. Em (a) e (b) temos as imagens originais, que são convertidas em níveis de cinza, obtendo-se as imagens (b) e (e). As imagens (c) e (f) são os resultados da aplicação do filtro.

Tabela 5.1: Número de iterações retornado pela diferença de pontos dos operadores Roberts e Prewitt.

Imagem	Roberts	Prewitt	Diferença	Iterações
(a)	1755	1298	457	6
(d)	1155	1044	111	1

Com o intuito de automatizar o método proposto nesse trabalho, foi estabelecida 100 iterações para a suavização de todas as imagens do banco. A definição desse valor não alterou o desempenho do método, pois equilibrou a suavização tanto das imagens muito ruidosas, quanto as imagens que não necessitavam de muita suavização.

5.3 Segmentação

A segmentação das imagens de lesões de pele consiste em separar a região doente da região saudável, para que as lesões possam ser detectadas. No presente trabalho foram

abordadas duas técnicas para segmentação: a técnica de limiarização e o modelo de contorno ativo sem borda. Testes, que serão descritos no próximo capítulo, foram realizados para avaliar qual técnica apresenta melhores resultados. Considerando os resultados obtidos, a técnica utilizada para a segmentação das imagens neste trabalho é o modelo de contorno ativo sem borda, para imagens em níveis de cinza, proposto por Chan e Vese [20]. Este método é realizado por meio da minimização de energia da curva sobreposta a imagem. A segmentação deste modelo é baseada em região, e utiliza conceitos das técnicas de Mumford-Shah [40] e *Level Set* [48].

São várias as vantagens deste método, que permite que com seu uso obtenha-se bons resultados: a detecção de diferentes objetos com variadas intensidades e ainda com fronteiras borradas; mudança topológica da curva; detecção de objetos onde o contorno não possui gradiente, devido ao critério de parada da evolução da curva até a fronteira desejada não depender do gradiente da imagem (isso não é possível com a utilização do modelo de contorno ativo tradicional); e tem-se um bom resultado na detecção dos objetos em imagens com ruídos [20]. As etapas da segmentação estão descritas na Figura 5.6.




Figura 5.6: Estrutura das etapas da segmentação.

A primeira etapa da segmentação utilizando o modelo Chan-Vese é a definição de uma curva sobre a imagem, que será minimizada até a fronteira do objeto. Esse modelo possui como características a possibilidade de definir a curva em qualquer local da imagem, representá-la por diversas formas e diferentes tamanhos.

Visando diminuir o tempo de processamento, neste trabalho a forma inicial da curva é quadrada e posicionada próxima ao centro da imagem, desta forma são realizadas menos iterações para a curva envolver a lesão. Inicialmente, a curva foi definida com 140×140 pixels, considerando que a maioria das imagens do banco, aproximadamente 64%, são compostas por lesões maiores, ou seja, que representam uma grande quantidade de pixels. Isso tende a ocorrer quando a distância no momento da aquisição é bem próxima a lesão. Um exemplo da curva definição com 140×140 pixels pode ser visto na imagem da Figura 5.7(d), representada pela cor vermelha.




Figura 5.7: Definição da curva sobre a imagem suavizada. Em (a) tem-se uma lesão pequena e em (b) uma curva 40×40 pixels sobre a imagem suavizada. A imagem (c) representa uma lesão maior e na imagem (d) uma curva 140×140 pixels foi sobreposta a imagem suavizada.

No entanto, neste trabalho foi constatado que quanto mais próxima a curva estiver da lesão, melhores serão os resultados. Além de detectar a lesão em menos tempo, ou seja, com menos iterações, menor será a possibilidade de encontrar bordas falsas, como as causadas pelos reflexos e sombras. Desta forma, considerando a quantidade significativa de lesões

pequenas, foi necessário definir uma curva menor para as lesões pequenas (Figura 5.7(b)) e uma curva maior para as lesões grandes (Figura 5.7(d)). Foram estabelecidas duas curvas com tamanhos diferentes: $40 \times 40 \text{ pixels}$ e $140 \times 140 \text{ pixels}$ para serem sobrepostas as imagens com lesões pequenas e grandes, respectivamente. A definição do tamanho da curva deve ser informado pelo usuário conforme a sua necessidade.

Na aplicação do modelo Chan-Vese a Equação 3.44 é utilizada para a evolução da curva. No qual foram definidos os parâmetros mediante testes, baseado-se no trabalho já desenvolvido [20]:

- $\mu = 0.2$, parâmetro que controla o comprimento da curva;
- $\nu = 0$, influência na área dentro da curva;
- λ_1 e $\lambda_2 = 1$, auxilia na localização do objeto dentro e fora da curva respectivamente;
- $h = 1$, auxilia na detecção do contorno interior;
- $\Delta t = 0.1$, é tempo da evolução.

Foram aplicadas 500 iterações para a evolução da curva, ou seja, a minimização da mesma ocorrerá até o número de iterações ou quando a curva C estiver localizada sobre o objeto. Na Figura 5.8 são apresentados alguns resultados da aplicação do modelo de contorno ativo sem borda nas imagens suavizadas (b), (e) e (h).

O resultado da aplicação do modelo Chan-Vese possibilita a binarização da imagem, como pode ser visto nas imagens (c), (f) e (i) da Figura 5.8. As imagens resultantes do processo de segmentação podem apresentar: orifícios dentro da região da lesão e ruídos na parte externa, causados por reflexos, sombras ou algum outro ruído que não foi eliminado na etapa de suavização. Estes fatores são tratados na próxima etapa de pós-processamento das imagens.

Com o intuito de automatizar a definição da curva para o processo de segmentação pelo modelo Chan-Vese, foi analisado um método para estabelecer a curva conforme o tamanho da lesão. As etapas do método podem ser vistas na Figura 5.9.




Figura 5.8: Resultado da aplicação do modelo Chan-Vese. Em (a), (d) e (g) temos imagens em níveis de cinza, as imagens (b), (e) e (h) representam as imagens suavizadas com difusão anisotrópica e as imagens em (c), (f) e (i) são os resultados da aplicação do modelo Chan-Vese.

Para a definição do limiar que é utilizado para estabelecer a curva, foram consideradas apenas as imagens compostas por lesões pequenas, nas quais a utilização da curva com tamanho 40×40 *pixels* obteve melhores resultados com a aplicação do modelo Chan-Vese. Primeiramente, a partir da imagem segmentada é feita a contagem somente dos *pixels* que fazem parte da lesão, ou seja, os *pixels* pretos.

Em seguida são calculados a média e o desvio padrão dos *pixels* referentes a todas as imagens compostas por lesões pequenas. O resultado da soma da média com o desvio padrão define o limiar (L). O limiar possibilita diferenciar as lesões pequenas das grandes nas imagens segmentadas. Considerando que as dimensões das imagens do banco são 200×200 ,

as imagens são compostas por 40.000 *pixels*. O resultado do limiar foi 6.345 *pixels*, que representam a quantidade limite de *pixels* que compõem as imagens com lesões pequenas.




Figura 5.9: Estrutura do método automático para definição da curva no modelo Chan-Vese.

Considerando a definição do limiar conforme a análise do resultado da segmentação manual utilizando o modelo Chan-Vese, foi possível automatizar a definição da curva para a segmentação das imagens. Para isso, a técnica de limiarização é aplicada, por meio do método OTSU. Para cada imagem binarizada é feita a contagem da quantidade de *pixels* (TP) correspondentes a lesão. Para a definição da curva é realizada a verificação do limiar. Se o total de *pixels* for menor ou igual ao limiar ($TP \leq L$), a curva definida sobre a lesão será pequena, de 40×40 *pixels*. Se o valor for maior que o limiar ($TP > L$), a curva será grande, de 140×140 *pixels*, para a aplicação do método Chan-Vese. Os resultados da aplicação desse método são apresentados no Capítulo de testes e discussão.

5.4 Pós-processamento

Depois de realizada a segmentação por meio do modelo Chan-Vese são aplicados filtros morfológicos nas imagens binarizadas para tratá-las. A utilização dos filtros permite eliminar ruídos dentro e fora das regiões segmentadas. Esses ruídos podem causar a definição de bordas falsas pelo método de segmentação, como os reflexos. Na Figura 5.10 podem ser vistas as etapas do pós-processamento.



Figura 5.10: Estrutura das etapas do pós-processamento.

Os filtros aplicados neste trabalho foram "abertura" seguida do "fechamento". O elemento estruturante utilizado possui a forma de elipse, com os dois raios iguais a quatro. A aplicação do filtro permite a suavização da borda e eliminação dos ruídos internos ou externos a lesão.

Nas imagens (b), (e) e (h) da Figura 5.11 podem ser vistos os resultados da aplicação destes filtros morfológicos, nas imagens segmentadas (b), (e) e (h) pelo modelo de contorno ativo Chan-Vese. Nas imagens (c), (f) e (i) resultantes da aplicação dos filtros morfológicos apresentadas na Figura 5.11, podemos observar que os orifícios e pontos isolados da região da lesão foram eliminados, além de suavizar a borda sem compromete-la.




Figura 5.11: Aplicação dos filtros morfológicos. Em (a), (d) e (g) temos imagens suavizadas, em (b), (e) e (h) representam as imagens segmentadas e (c), (f) e (i) são as imagens depois de aplicado os filtros morfológicos.

Depois de realizada a etapa de pós-processamento nas imagens de lesão de pele, o seu contorno é então definido. O contorno representa as delimitações e irregularidades da borda, permitindo a separação da região doente da região saudável. Essa separação é importante para que suas características possam ser adquiridas, sem influência da pele. Na Figura 5.12 pode ser visto o resultado do contorno (b), a definição da borda na lesão (c) e a lesão sem influência da pele (d), conforme a imagem segmentada (a) depois da aplicação do filtro morfológico.




Figura 5.12: Definição do contorno e extração da lesão de pele. Na imagem da figura (a) temos o resultado depois de aplicado o filtro morfológico, em (b) a representação do seu contorno, em (c) o contorno sobre a lesão e em (d) a lesão sem influência da pele.

O contorno é estabelecido nos *pixels* onde ocorrem as mudanças bruscas de intensidade nas imagens binarizadas. Considerando que as lesões são de cor preta e a pele de cor branca, como determinadas neste trabalho, ao percorrer a imagem *pixel a pixel*, quando houver a mudança de cor, o pixel na mesma posição na imagem original recebe a cor branca para definir o contorno.

5.5 Extração das características

A partir da região segmentada pode-se extrair as características de assimetria, borda e cor da regra ABCD (assimetria, borda, cor e diâmetro) e a textura da lesão associada, por

meio de descritores, com o intuito de descrever o objeto. Essas características são muito utilizadas pelos dermatologistas para diferenciar lesões benignas das malignas (Tabela 2.2).

No caso da característica de textura, não há uma regra pré-definida para diferenciar lesões benignas das malignas. A textura irregular é um atributo predominante da ceratose seborréica, que auxilia na sua identificação. Esse tipo de lesão é abordada no presente trabalho, devido a importância da sua diferenciação dos melanomas.

A regra ABCD é estabelecida da seguinte maneira: no quesito “Assimetria” as lesões benignas tendem a ser mais simétricas enquanto as malignas costumam ser mais assimétricas; as “Bordas” das lesões benignas são, usualmente, mais regulares, ao passo que aquelas das lesões malignas via de regra são irregulares; a “Cor” das lesões benignas geralmente é mais homogênea enquanto a das lesões malignas tem mais variações de tonalidades; por fim, as lesões com “Diâmetro” menores do que 6mm tendem a ser benignas e as maiores do que isto costumam ser malignas.

O diâmetro (D) das lesões é estabelecido conforme a medição da sua maior diagonal, que pode ser calculada pela distância euclidiana, sendo [30]:

$$D_{(p,q)} = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2} \quad (5.1)$$

onde (x_1, y_1) e (x_2, y_2) são as coordenadas dos pontos p e q . Todos os pontos do contorno são analisados, para definir quais pares de pontos possuem maior distância. Uma demonstração da maior diagonal é vista na Figura 5.13, representada pela reta amarela.



Figura 5.13: Representação da maior diagonal.

As imagens do banco não possuem a escala do diâmetro das lesões, e sendo este um valor determinado, não é necessário uma máquina para estimá-lo. Por essa razão, essa

característica não é utilizada para a classificação das lesões de pele, mas as informações referente a maior diagonal são utilizadas para extrair a característica de assimetria.

O diagrama do método de extração de característica pode ser visto na Figura 5.14. Os descritores das características serão abordadas com mais detalhes nas próximas subseções.




Figura 5.14: Diagrama do método de extração das características.

Para a extração das características, somente os pontos referentes a lesão são considerados. Os atributos extraídos formam os vetores de características, que são entradas para o classificador inteligente interpretar a qual classe a lesão pertence.

5.5.1 Descritor de assimetria

A característica de Assimetria (A) representa a forma de uma lesão. Uma maneira para medi-la se dá pela definição de um segmento de reta ligando os dois pontos da borda da lesão mais distantes entre si. Esse segmento de reta divide a lesão em duas regiões, as quais são analisadas. Caso sejam muito diferentes, considera-se uma lesão assimétrica, senão, a lesão é considerada simétrica.

Para extrair as características da assimetria, são consideradas apenas os pontos que fazem parte da borda da lesão, representados pelos contornos brancos nas imagens (a) e (b) da Figura 5.15. Primeiramente é calculada a maior diagonal entre os pontos do contorno da lesão. Calculam-se as distâncias euclidianas [30] entre todos os pares de *pixels* da borda da lesão e traça-se uma reta entre os pontos da maior distância encontrada. Dois exemplos da

maior diagonal D, podem ser vistos na Figura 5.15, representadas pelas retas amarelas. A reta estabelecida na maior diagonal divide a lesão em duas partes.




Figura 5.15: Exemplos de perpendiculares à diagonal maior para extração das características de assimetria. Em (a) tem-se um lesão simétrica e em (b) uma lesão assimétrica.

Em seguida, encontram-se as perpendiculares de cada ponto da diagonal maior, referentes aos pontos do contorno [6]. Cada perpendicular representa dois segmentos (P1 e P2), para cada parte da lesão. Nas imagens da Figura 5.15 são apresentados dois exemplos de perpendicular a diagonal maior em cada imagem. Os segmentos P1 e P2 são representadas pelas linha azul e vermelha, respectivamente, que juntas formam uma perpendicular de um determinado ponto da diagonal maior.

A quantidade de perpendiculares de cada imagem é diferente, dependendo do tamanho da diagonal maior. Desta forma, para estabelecer uma única quantidade de perpendiculares para todas as imagens, foi calculado o numero de saltos S de pontos na diagonal maior, conforme a quantidade de perpendiculares desejadas. Sendo:

$$S = \frac{perp}{n} \quad (5.2)$$

onde S é o número de saltos ao percorrer a diagonal maior para encontrar as perpendiculares, $perp$ é o total de perpendiculares encontradas anteriormente e n representa a quantidade de perpendiculares desejadas. Forma-se um conjunto de amostras de perpendiculares.

Para cada perpendicular do conjunto de amostras são calculadas a distâncias euclidianas das duas retas, considerando o ponto da diagonal maior até o ponto da borda

perpendicular a ele. Então, a característica que representa cada perpendicular é definida pela razão entre a distância menor sobre a maior, obtendo coeficientes entre 0 (zero) e 1 (um). A razão entre as duas retas possibilita representar o quanto assimétrica é a lesão no determinado ponto da diagonal maior, ou seja, quanto mais próximo de 0, mais a área é assimétrica ou no caso contrário, se a razão for mais próxima de 1 a lesão no determinado ponto comparado é mais simétrica.

As imagens são representadas por vetores de características com as informações referentes a assimetria, como apresentado na Figura 5.16. O vetor é composto por: desvio padrão das perpendiculares e também todas as razões de perpendiculares conforme a quantidade desejada, possibilitando ao classificador fazer uma análise estatística de todas as razões para analisar as diversas situações, e assim classificá-la em simétrica ou assimétrica.




Figura 5.16: Vetor de característica para representar a assimetria das lesões.

Para representar essa característica, foram definidos cinco vetores (A1, A2, A3, A4 e A5), com o intuito de analisar qual representa melhor a característica de assimetria. Então, é realizada uma variação no termo " n " referenciado na Equação 5.2, conforme a quantidade de amostras de perpendiculares desejadas a serem analisadas. Os valores desejados para cada vetor em sequência são 10, 20, 30, 40 e 50 amostras. Depois de definida a quantidade de perpendiculares desejadas, são estabelecidas as razões para cada perpendicular. Cada vetor de característica é então formado pelo valor do desvio padrão das razões das perpendiculares, mais as razões das perpendiculares conforme a quantidade referida. Neste caso, o tamanho (N) de cada vetor (A1, A2, A3, A4 e A5) da Figura 5.16 será de 11, 21, 31, 41 e 51 características, respectivamente.

5.5.2 Descritor de borda

As bordas das lesões de pele podem ser consideradas pelos dermatologistas regulares ou possuir pequenas ou grandes irregularidades, como nas imagens (a) e (b) da Figura 5.17. As informações referentes à irregularidade do contorno são extraídas a partir da assinatura da possível lesão, que é a representação unidimensional do contorno [30].




Figura 5.17: Representação do contorno de uma lesão de pele. Em (a) tem-se uma borda regular e em (b) uma borda irregular.

Para definir a assinatura da lesão, primeiramente são encontrados somente os pontos do contorno, utilizando a vizinhança de 8, a partir do primeiro ponto encontrado. Tendo a sequência correta dos pixels da borda, é possível gerar sua assinatura. Um ponto central é estabelecido na lesão de cada imagem, considerando o ponto de intersecção das retas da diagonal maior com a reta da sua maior perpendicular, vista na subseção anterior. Para construir a imagem com a assinatura são consideradas as mesmas distâncias do ponto central a cada ponto da borda. A distância é obtida pela técnica de distância euclidiana.

Um exemplo de assinatura pode ser visto na imagem (b) da Figura 5.18, onde a lesão é exposta em vermelho. A assinatura representa o contorno branco da imagem (a) de forma unidimensional. Para a demonstração da assinatura, as coordenadas da origem (0,0) foram alteradas para o canto inferior esquerdo.




Figura 5.18: Representação da característica de borda. Em (a) tem-se uma imagem com o contorno definido e em (b) a assinatura da imagem.

Para a extração das características da borda são consideradas duas técnicas: produto vetorial e ponto de inflexão [6]. Ambas possuem a mesma característica: identificar a irregularidade de uma borda, analisando a quantidade de picos, vales e retas.

O produto vetorial P utiliza três pontos $p_1(x_1, y_1)$, $p_2(x_2, y_2)$ e $p_3(x_3, y_3)$ do contorno para definir sua direção, com variação de i pixels, sendo calculado conforme a Equação 5.3. O produto vetorial define se o segmento do contorno formado por tais pontos é um pico, vale ou reta.

$$P = (x_2 - x_1)(y_3 - y_1) - (y_2 - y_1)(x_3 - x_1) \quad (5.3)$$

O conjunto de três pontos é considerado um vale, quando o produto vetorial é menor que zero, $P < 0$, como mostrado na Figura 5.19, pelo segmento azul. Quando o produto vetorial é maior que zero, $P > 0$, os pontos definem um pico, como no caso do segmento vermelho na Figura 5.19. Os pontos formam uma reta, como no caso do segmento rosa da Figura 5.19, quando o produto vetorial é igual a zero, $P = 0$.

No presente trabalho o produto vetorial é aplicado para representar tanto os picos e vales pequenos, quanto os grandes. Para representar as pequenas irregularidades foram considerados três pontos do contorno com um intervalo de quatro pixels entre os pontos, $i = 4$, para definir os picos, vales e retas menores. Para identificar as grandes irregularidades foi estabelecido um intervalo de quinze pixels, $i = 15$, entre os pontos [6]. Posteriormente, calcula-se o produto vetorial para todos os pontos que representam o contorno n , para definir a quantidade de picos, vales e retas grandes e pequenos.




Figura 5.19: Exemplo de produto vetorial [6].

A técnica de ponto de inflexão também foi abordada para representar os picos e vales grandes e pequenos. Para analisar as irregularidades pequenas, para cada ponto da borda P_i são analisados os quatro vizinhos, $i = 4$, da esquerda e também da direita como visto no exemplo da Figura 5.20. Para a análise de grandes irregularidades são definidos quinze vizinhos, $i = 15$, para a esquerda e direita do ponto P_i .




Figura 5.20: Exemplo de ponto de inflexão [6].

O objetivo desta técnica é analisar se o ponto P_i é um ponto de inflexão, ou seja, se o ponto sofre uma mudança de direção. Para determinar se o ponto P_i é uma inflexão, foram definidos pesos, que são atribuídos para todos os vizinhos. Considerando a coordenada y , os vizinhos que estiverem abaixo do ponto P_i , recebem peso 1. Os vizinhos que estiverem acima

- O vetor B1 é composto por seis características. As três primeiras são os valores dos picos, vales e retas, obtidos pelo produto vetorial, para representar pequenas irregularidades, ou seja com intervalo de 4 *pixels*. As outras três características são os valores de picos, vales e retas também obtidos pelo produto vetorial, para representar grandes irregularidades, ou seja, com um intervalo de 15 *pixels*;
- No vetor B2 as três primeiras características são obtidas pelo produto vetorial e as outras três obtidas pelo ponto de inflexão;
- No vetor B3 as três primeiras características são obtidas pelo ponto de inflexão e as outras três também obtidas pelo ponto de inflexão;
- No vetor B4 as três primeiras características são obtidas pelo ponto de inflexão e as outras três pelo produto vetorial.

5.5.3 Descritor de cor

A cor é uma das principais características utilizadas pelos dermatologistas para identificar se a lesão é benigna ou maligna. A variação de tonalidades é um dos fatores da regra de cor, visto que as lesões benignas geralmente possuem apenas uma tonalidade e já as malignas possuem várias tonalidades. Para representar a característica de cor, as informações são extraídas somente na área lesionada das imagens RGB e em níveis de cinza. Na imagem (a) da Figura 5.22 tem-se um exemplo de lesão uniforme e em (b) uma lesão com mais de uma tonalidade.




Figura 5.22: Área lesionada extraída. Em (a) tem-se uma lesão uniforme e em (b) um lesão não uniforme.

As características extraídas das lesões de pele são: a média das cores de cada canal RGB; a variância das cores de cada canal RGB; a variância das intensidades nas imagens em níveis de cinza; o desvio padrão das cores de cada canal RGB; e o desvio padrão das intensidades nas imagens em níveis de cinza. Na Figura 5.23 tem-se um vetor de característica com informações referentes a cor da lesão, onde o seu tamanho N é definido conforme o vetor utilizado. As características do vetor são utilizadas para classificar as lesões em uniforme ou não uniforme.




Figura 5.23: Vetor de característica para representar a cor das lesões.

Quatro diferentes vetores (C1, C2, C3 e C4) foram definidos para representar as características de cor, com o intuito de analisar qual representa melhor a lesão. Os vetores possuem a seguintes estruturas:

- O vetor C1 é definido por três características, correspondendo a variância de cada canal RGB;
- O vetor C2 com 4 características, possui além da variância de cada canal RGB, também a variância da imagem em níveis de cinza;
- O vetor C3, possui 9 características, sendo composto pela média, variância e o desvio padrão de cada canal RGB;
- O vetor C4 é definido por 10 características, que além de representar as características do vetor C3, também possui o desvio padrão da imagem em níveis de cinza.

5.5.4 Descritor de textura

A extração das características referentes à textura das lesões de pele é obtida pela dimensão fractal das imagens em níveis de cinza. Existem diversas técnicas para este fim. No

presente trabalho a dimensão é obtida por meio do método box-counting (BCM) [2], conforme abordado na Seção 3.7.

Para representar a característica de textura foram consideradas as dimensões fractais: somente da área lesionada, de toda a imagem e também as dimensões de cada uma das 16 partes iguais a qual a imagem é dividida, como visto nas imagens (a), (b) e (c) da Figura 5.24. O objetivo da divisão da imagem é analisar suas partes separadamente para representar melhor a textura das lesões. Considerando que a maioria das lesões da base são grandes, essa divisão da imagem permite representar pelo menos 4 regiões diferentes da lesão, quantidade aqui utilizada para analisar sua textura separadamente.




Figura 5.24: Características da textura das lesões de pele: (a) Lesão extraída (b) imagem original e (c) divisão da imagem em 16 partes iguais.

As características extraídas das imagens são utilizadas para formar vetores que as representem. Os vetores de características geram um conjunto de amostras, que são utilizadas pela SVM, para classificar a textura das lesões como regular ou irregular. Foram estabelecidos quatro vetores diferentes (T1, T2, T3 e T4) com N características.

O vetor T1 é composto por 18 características. A primeira característica é a dimensão fractal somente da área lesionada, determinada na segmentação. A segunda característica representa a dimensão de toda a imagem original. O restante das características (3 a 18) é composta da dimensão de cada uma das 16 partes iguais a qual a imagem é dividida. A representação deste vetor pode ser visto na Figura 5.25.

O vetor T2 possui 2 características: a dimensão fractal que representa a lesão e a dimensão de toda a imagem. Tem-se no vetor T3 apenas a dimensão da região lesionada. E o vetor T4 é composto pelas dimensões das 16 partes as quais a imagem foi dividida. Os

diferentes vetores de características são analisados com o intuito de representar melhor a textura das lesões.




Figura 5.25: Vetor de característica para representar a textura das lesões.

5.6 Classificação inteligente

O desenvolvimento desse trabalho almeja caracterizar as lesões de pele, de acordo com as características de assimetria, borda e cor da regra ABCD e textura. Para isso é utilizado um classificador inteligente, que permite reconhecer os padrões desejados por meio da aprendizagem. O classificador utilizado nesse trabalho é a SVM (Máquina de Vetor de Suporte), que é uma técnica baseada em aprendizado estatístico, utilizada para o reconhecimento de padrões em imagens. Esse classificador vem sendo muito utilizado para análises de lesões de pele e tem obtido bons resultados, comparado a outros métodos, por isso a escolha em usá-lo no presente trabalho.

O algoritmo é baseado no aprendizado supervisionado e utiliza duas funções de *Kernel* $K(x_i, x_j)$ diferentes: gaussiano (Equação 4.20) e intersecção por histograma (Equação 4.22) [12], para analisar qual deles permite obter melhor resultado para reconhecimento dos padrões. As classificações realizadas pela SVM são: classificação da assimetria, borda, cor, textura e dos tipos de lesões de pele abordadas no presente trabalho.

5.6.1 Classificação de assimetria

As características de assimetria (A) extraídas são utilizadas como entradas para o classificador SVM para identificar se a lesão é: simétrica ou assimétrica. Essa informação pode ser utilizada pelo dermatologista para auxiliá-lo em seu diagnóstico.

Considerando que a SVM é um método binário e que neste trabalho a assimetria possui apenas duas classes, o sistema é composto por uma máquina, responsável por classificar a assimetria das lesões de pele. Na Figura 5.26, tem-se a representação da classificação da assimetria a partir das características extraídas.




Figura 5.26: Representação da classificação da assimetria.

Para a classificação da assimetria são utilizados os cinco vetores de características (A1, A2, A3, A4 e A5), definidos na seção anterior, como dados de entrada para a SVM tanto para o treinamento como para os testes. Se o algoritmo obtiver o valor +1, a imagem é considerada simétrica, ou assimétrica, caso retorne o valor -1. Os resultados obtidos pela utilização de cada vetor de característica são analisados para verificar qual obteve melhor resultado na classificação.

5.6.2 Classificação de borda

Para medir a irregularidade da borda (B) e classifica-la em regular ou irregular, como visto na Figura 5.27, a máquina recebe as características do vetor, conforme extraídas na seção anterior. São utilizadas como entrada na SVM, quatro vetores diferentes (B1, B2, B3 e B4) para o treinamento e testes. A máquina retorna o valor +1 para as lesões com bordas consideradas regulares e o valor -1 para as bordas irregulares.




Figura 5.27: Representação da classificação da borda.

5.6.3 Classificação de cor

Foram estabelecidos quatro vetores de características (C1, C2, C3 e C4) para representar as informações das cores das lesões. Cada vetor é utilizado pela máquina para identificar se a lesão é uniforme ou não uniforme, considerando os seus valores retornados +1 e -1, respectivamente. Um exemplo de representação da classificação de cor é visto da Figura 5.28.




Figura 5.28: Representação da classificação da cor.

5.6.4 Classificação de textura

Para identificar se a textura é regular (+1) ou irregular (-1), a SVM treina e testa as amostras de lesões de pele, utilizando as características dos quatro vetores que representam as imagens (T1, T2, T3 e T4). Na Figura 5.29 tem-se uma representação da classificação da textura em lesões de pele, utilizando máquina de vetor de suporte.




Figura 5.29: Representação da classificação de textura.

5.6.5 Classificação das lesões de pele

Um dos objetivos deste trabalho é classificar alguns tipos de lesões de pele, como os nevos melanocíticos, ceratose seborréica e melanoma, para prevenir o desenvolvimento de câncer ou diagnosticá-lo precocemente.

O vetor de característica utilizado para classificar as lesões de pele é composto por todas as características dos vetores que obtiveram melhores resultados na classificação das características de assimetria, borda, cor e textura, que serão abordadas no próximo capítulo. São utilizadas as características de textura, assimetria, borda, cor e também o diâmetro.

Os vetores com as características são utilizados como entrada no classificador binário SVM para diferenciar os nevos da ceratose seborréica, que apesar de serem lesões benignas, possuem características diferentes, considerando que a ceratose seborréica não segue exatamente a regra ABCD. Uma outra classificação é realizada para diferenciar nevos de melanomas, devido a importância em diferenciar lesões benignas de malignas. Também é importante diferenciar a ceratose seborréica (lesão benigna) do melanoma (lesão maligna). Esses dois tipos de lesão muitas vezes são confundidos, devido às suas semelhanças. Na Figura 5.30 tem-se a representação da classificação das lesões.




Figura 5.30: Classificação das lesões de pele.

Todas as classificações descritas nessa subseção são testadas e analisadas no próximo capítulo. Os resultados obtidos na classificação pela SVM são disponibilizados ao dermatologista com o objetivo de auxiliá-lo no seu diagnóstico.

6 RESULTADOS E DISCUSSÕES

A realização dos testes tem por objetivo avaliar o método proposto neste trabalho para detecção e classificação de lesões de pele, para auxiliar o dermatologista em seu diagnóstico. Os testes foram divididos em duas etapas: na primeira etapa foram utilizadas todas as imagens do banco para avaliar os resultados obtidos pela detecção das lesões de pele. Nessa etapa foram aplicados os métodos de difusão anisotrópica para a suavização e o modelo de contorno ativo sem borda (Chan-Vese) para a segmentação das lesões de pele. As imagens resultantes da aplicação do método, com os contornos estabelecidos foram avaliadas visualmente pelo dermatologista Doutor Ricardo Baccaro Rossetti.

A segunda etapa visou avaliar a classificação inteligente dos tipos de lesões de pele e suas determinadas características de assimetria, borda, cor e textura. Nessa etapa todas as imagens do banco foram utilizadas, exceto aquelas em que as lesões não foram detectadas, como avaliadas pelo especialista. Foram utilizados descritores para extrair as informações das características das lesões de pele, conforme a regra ABCD e textura que foram utilizadas na sua análise inicial pelos dermatologistas. Foram avaliados os resultados obtidos pela máquina de vetor de suporte (SVM) para a classificação por meio da aprendizagem.

6.1 Avaliações de técnicas de segmentação para detecção de lesões de pele

As aplicações de técnicas de segmentação permitem detectar as lesões de pele em uma determinada imagem e definir o seu contorno, para que possam ser extraídas suas principais características a fim de classificá-las. Para obter um resultado que melhor

represente a lesão, foram realizados testes para avaliar duas técnicas de segmentação para a detecção de lesões de pele: limiarização e o modelo Chan-Vese. As duas técnicas foram aplicadas nas imagens suavizadas pela difusão anisotrópica. Em seguida foram definidos os contornos das lesões a partir das imagens pós-processadas pelos filtros morfológicos. Esta etapa elimina os orifícios dentro da região doente, os ruídos externos e também suaviza o contorno.

A segmentação das imagens pela técnica de limiarização é aplicada pelo limiar de OTSU, conforme a Equação 3.16. As intensidades menores que o limiar são transformadas em "0", para representar a lesão. Já as intensidades maiores que o limiar recebem "1", representando a região saudável. No caso da segmentação pelo modelo Chan-Vese, foram utilizados os seguintes parâmetros para a evolução da curva, conforme a Equação 3.44: $\mu = 0.2$, $\nu = 0$, λ_1 e $\lambda_2 = 1$, $h = 1$, $\Delta t = 0.1$ e 500 iterações. A curva é estabelecida conforme o tamanho da lesão. Caso seja uma lesão pequena, o tamanho da curva é definida com 40x40 *pixels*, e no caso de uma lesão grande, a curva é definida com 140x140 *pixels*.

Também foi avaliado o método proposto para automatizar a definição da curva, conforme mostrado na Figura 5.9. O método utiliza a quantidade de pixel que compõe a lesão, retornada pelo método de limiarização, para definir o tamanho da curva conforme o limiar estabelecido pela média e desvio padrão dos pontos pertencentes à lesão, retornados da aplicação mais adequada do modelo Chan-Vese para as imagens grandes e pequenas.

Pode-se visualizar na Figura 6.1 o resultado da aplicação dos três métodos de segmentação na imagem original (a).










Figura 6.1: Resultado da comparação entre métodos de segmentação. Em (a) a imagem original, com aplicação da técnica de limiarização (b), em (c) a segmentação utilizando o modelo Chan-Vese e em (d) o método automático para a definição da curva.

Considerando a Figura 6.1, o resultado da segmentação utilizando a técnica de limiarização é apresentado na imagem (b), o resultado da aplicação do modelo Chan-Vese pode ser visto na imagem (c) e em (d) o contorno foi obtido pela utilização do método automático para definir a curva pelo modelo Chan-Vese. Podemos observar na imagem (c), com a aplicação do modelo Chan-Vese, que o contorno envolveu melhor a lesão, do que na imagem (b), obtida pela técnica de limiarização. Algumas regiões da lesão na imagem (b), não foram detectadas completamente. No caso da imagem (d), o resultado do contorno foi igual ao da imagem (c), visto que foi determinado o mesmo tamanho da curva pelo método automático, com a utilização do modelo Chan-Vese

Na Tabela 6.1 têm-se outros resultados da aplicação dos diferentes métodos para a segmentação, onde o Chan-Vese obteve melhor resultado.

Tabela 6.1: Demonstração dos resultados obtidos entre os métodos de segmentação.

	Imagem	Limiarização	Chan-Vese	Curva automática
1				
2				
3				

Continuação da Tabela 6.1				
4				
5				
6				
7				
8				
9				

Na primeira coluna da Tabela 6.1 é especificado um número para representar as imagens originais da segunda coluna, que foram processadas. Nas terceira, quarta e quinta colunas são apresentados os resultados das técnicas de limiarização, modelo Chan-Vese e com a definição de uma curva automática, respectivamente.

Os resultados do modelo Chan-Vese das imagens de 1 a 3 da Tabela 6.1 obtiveram melhor envolvimento das regiões com intensidades mais próximas da cor da pele do que a técnica de limiarização. Nos casos das imagens 1 e 3, para o método que estabelece a curva automática, não foram detectadas corretamente as lesões devido à definição errada do tamanho da curva. A curva deveria ser maior, ou seja, 140×140 , mas a quantidade de *pixel* que compõe a lesão obtida pelo método de limiarização é menor que o limiar estabelecido.

Para as imagens muito ruidosas, o modelo Chan-Vese também alcançou melhores resultados, com a influência do filtro de difusão anisotrópica. Alguns resultados podem ser vistos nas imagens 4 a 6 da Tabela 6.1, onde as lesões foram detectadas. Para o método com a definição automática da curva, as lesões também foram envolvidas apesar de estabelecer outras bordas falsas na imagem. Nas imagens resultantes da aplicação da técnica de limiarização, as lesões não foram detectadas, exceto a imagem 6, mas também foram estabelecidas outras áreas além da lesão.

As imagens 7 a 9 da Tabela 6.1 possuem algumas regiões na pele, como a vermelhidão na imagem 7, que podem influenciar em sua detecção. Estas regiões foram consideradas pertencentes à lesão pela técnica de limiarização. Isso também ocorreu no método de detecção automática da curva, exceto na imagem 7, que apesar de identificar outra região, detectou corretamente a lesão. Nas três imagens a curva correta para o método automático deveria ser pequena, ou seja, 40×40 , devido ao tamanho das lesões, mas foi utilizada uma curva grande, considerando a grande área estabelecida nas imagens pela técnica de limiarização. O modelo Chan-Vese também obteve um melhor resultado para esses casos, pois detectou somente a lesão.

Foram avaliados os resultados com base em todas as imagens do banco: 62 imagens de nevos melanocíticos, 86 imagens de ceratose soborréica e 260 imagens de melanoma. A alta quantidade de imagens de melanoma decorre devido à preocupação com esse tipo de lesão, que é cancerígena e apresenta uma alta taxa de mortalidade. As imagens foram analisadas pelo especialista para identificar se a lesão foi detectada ou não pelas técnicas de segmentação: limiarização, Chan-Vese e a aplicação da curva automática. As imagens foram consideradas, pelo dermatologista, detectadas nos casos em que foram envolvidas totalmente pelo contorno, como nos casos das imagens 7 a 9 resultantes da aplicação do modelo Chan-

Vese, que foram totalmente envolvidas pelo contorno, ao contrário das imagens resultantes da aplicação da técnica de limiarização, onde as lesões não foram detectadas.

Na Tabela 6.2, tem-se os resultados do método desenvolvido com a aplicação de cada técnica de segmentação analisada neste trabalho.

Tabela 6.2: Resultados obtidos pelos métodos de segmentação.

Técnicas de segmentação	Nevo melanocítico	Ceratose seborréica	Melanoma	Taxa de acerto
Limiarização	80,65%	81,40%	80%	80,39%
Chan-Vese	96,77%	93,02%	94,23%	94,36%
Curva automática	83,87%	86,05%	85,38%	85,29%

De acordo com os resultados mostrados na Tabela 6.2, a aplicação do modelo de contorno ativo sem borda (Chan-Vese) obteve melhores resultados para a segmentação das lesões de pele, do que as outras técnicas também analisadas. Esse modelo permitiu detectar corretamente 94,36% das imagens. A técnica de limiarização teve o resultado menos significativo, com 80,39% de detecção correta das lesões de pele. Esse resultado deu-se devido à dificuldade em segmentar as imagens com ruídos, como pelos e sombras, mesmo com a utilização do método de suavização, a difusão anisotrópica.

O método proposto para definir uma curva automática na segmentação pelo modelo Chan-Vese, obteve um melhor resultado do que a técnica de limiarização. Aproximadamente 14% das imagens não foram detectadas devido à definição incorreta do tamanho da curva, que é baseada na técnica de limiarização. Geralmente isso ocorre com lesões consideradas pequenas, que necessitam de uma curva menor para a sua detecção, mas é definida uma curva grande, devido o método de limiarização não detectar corretamente a lesão e determinar uma grande área segmentada nas imagens com os problemas citados anteriormente. Esta área grande se torna maior que o limiar necessário para estabelecer uma curva pequena na imagem. A definição incorreta da curva, causou erro na segmentação de determinadas imagens, não permitindo detectar corretamente as lesões, visto que o número de iterações é muito pequeno para esse tipo de situação. Para esse caso, a minimização da curva necessitaria de mais iterações e também poderia detectar outros objetos falsos na imagem devido sua proximidade com a curva.

Analisando os resultados obtidos pelo modelo Chan-Vese, percebe-se pelo gráfico da Figura 6.2, que os nevos melanocíticos obtiveram melhores resultados comparados com os outros tipos de lesões. A proposta permitiu definir uma curva menor para segmentar as lesões pequenas. Um exemplo é visto nas imagens (b) e (c) da Figura 6.3.




Figura 6.2: Resultados das técnicas para segmentação das lesões de pele.

As lesões do tipo ceratose seborréica tiveram mais erros de detecção, devido as cores das lesões na maioria das imagens da base serem similares as cores da pele, dificultando sua detecção, como na imagem da Figura 6.3(f). Outros exemplos onde as lesões não foram detectadas são representados pelas imagens (e), (g) e (h), onde os reflexos e sombras não foram eliminados no pré-processamento.

O método se mostrou uma técnica promissora para imagens com muitos pelos e com intensidades próximas a cor da pele, como nas imagens (a) e (d) respectivamente, apesar das imagens (k) e (l) não terem obtido um bom contorno devido aos reflexos sobre a fronteira e as intensidades muito claras. Em algumas imagens, como em (i) e (j) foram definidas algumas bordas falsas, por motivo de mancha ou ruídos que não foram totalmente eliminados pelo filtro de suavização.




Figura 6.3: Resultados da aplicação do modelo Chan-Vese com lesões detectadas e não detectadas.

Os trabalhos abordados no estado da arte [14, 22, 42], que avaliaram somente a segmentação e para isso foram aplicadas as técnicas de limiarização, são expostos na Tabela 6.3, bem como os resultados do presente trabalho que utiliza o modelo Chan-Vese. Na mesma são apresentadas as referências dos trabalhos, os anos de suas publicações, os métodos de segmentações, os tipos de lesões abordadas e suas precisões (taxa de acerto), respectivamente.

No primeiro trabalho [14] os autores obtiveram 95,26% de acerto para as lesões benignas e 92,62% de acerto para as malignas. No caso do segundo trabalho [42], os autores classificaram as lesões em não melanocíticas e melanocíticas, que obtiveram 84,5% e 93,9% de acerto, respectivamente. Já no terceiro trabalho [22], os autores avaliam a taxa de acerto para as lesões benignas e malignas, e obtiveram 92% de acerto para as duas classes. No

presente trabalho, o método proposto obteve 96,77% de acertos na classificação de nevos melanocíticos, 93,03% de acertos para a classe de ceratose seborréica e 94,23% de acertos para a classe de melanoma.

Tabela 6.3: Resultados de trabalhos desenvolvidos para segmentação de lesões de pele.

Fonte	Ano	Segmentação	Imagens	Taxa de acerto
Método proposto	2012	Modelo Chan-Vese	Nevo melanocítico	96,77%
			Ceratose seborréica	93,02%
			Melanoma	94,23%
[14]	2011	Limiarização	Lesões benignas	95,26%
			Lesões malignas	92,62%
[42]	2010	Limiarização	Lesões não melanocíticas	84,5%
			Lesões melanocíticas	93,9%
[22]	2010	Limiarização	Lesões benignas e malignas	92%

Apesar dos resultados da segmentação do presente trabalho ter se mostrado melhor, não foi possível realizar uma comparação entre os trabalhos, devido diversos fatores, tais como, as imagens da base serem diferentes, as lesões de pele abordadas não serem do mesmo tipo e também a classificação ser de modo diferente.

6.2 Classificação inteligente para lesões de pele

Para auxiliar o dermatologista em seu diagnóstico, este trabalho foi desenvolvido tendo como objetivo a caracterização das lesões de pele, por meio das características assimetria, borda, cor e textura. O classificador inteligente utilizado para a caracterização foi a SVM (Máquina de Vetor de Suporte). Foram testados dois *kernels*: o gaussiano e a intersecção por histograma (Equação 4.20 e 4.22, respectivamente), com o intuito de obter melhores resultados.

Para o treinamento e os testes foram reunidas todas as imagens resultantes do processo de avaliação da segmentação, que obtiveram como resultado a detecção correta das lesões de pele. Desta forma não são passadas informações não verdadeiras a SVM. Foram utilizadas 385 imagens, sendo 251 imagens de melanoma, 59 de nevos melanocíticos e 75 imagens de ceratose seborréica. As características das imagens são representadas por 124 imagens simétricas, 261 imagens assimétricas, 69 imagens com borda regular, 316 imagens com borda irregular, 31 imagens com cor uniforme, 354 imagens com cor não uniforme, 219 imagens com textura regular e 166 imagens com textura irregular.

O conjunto de imagens determinado para o treinamento foi avaliado conforme os testes. Foram realizados testes com conjuntos de 10%, 20%, 30%, 40% e 50% para compor as imagens de treinamento. Serão apresentados os resultados obtidos apenas pelo conjunto de treinamento que obteve melhores resultados nos testes, considerando os dois *kernels*. O intuito é que o classificador tenha uma boa generalização e assim possa lidar corretamente com as novas amostras inseridas e também evitar o subajustamento ou o superajustamento do modelo aos dados de treinamento.

Considerando o classificador binário, características de assimetria, borda, cor e textura foram classificadas em duas classes, conforme a regra ABCD e análise de textura utilizadas pelos dermatologistas para diagnosticar as lesões de pele. Os resultados dessas classificações e também da diferenciação das lesões de pele são apresentados a seguir.

6.2.1 Assimetria

Para identificar a assimetria da lesão, foram definidas duas classes: simétrica ou assimétrica. Os resultados foram obtidos com base nos *kernels* gaussiano e intersecção por histograma. De acordo com os melhores resultados, o conjunto de imagens para o treinamento foi de 10% para ambos os *kernels* e o restante das imagens foi utilizadas para testes. Na Tabela 6.4 têm-se os resultados obtidos para os *kernels* gaussiano e intersecção por histograma. Foram avaliados os resultados da classificação pela SVM para cada vetor de característica (A1, A2, A3, A4 e A5) estabelecidos na Subseção 5.5.1. Para cada vetor de característica e *kernel* são apresentados a quantidade de acertos (%) para cada classe, simétrica ou assimétrica e também a taxa de acerto (%) da classificação para as duas classes.

Tabela 6.4. Resultados da classificação de assimetria utilizando o *kernel* gaussiano e a intersecção por histograma.

Vetores de características	Gaussiano			Intersecção por histograma		
	Simétrica	Assimétrica	Taxa de acerto	Simétrica	Assimétrica	Taxa de acerto
A1	60,71%	73,62%	69,45%	89,29%	100%	96,54%
A2	70,54%	69,36%	69,74%	26,79%	93,19%	71,76%
A3	69,64%	66,81%	67,72%	27,68%	93,19%	72,04%
A4	65,18%	71,06%	69,16%	57,14%	80,42%	72,91%
A5	53,57%	75,74%	68,59%	72,32%	71,06%	71,47%

Na Tabela 6.4, podemos observar pelos resultados da taxa de acerto de ambos os *kernels* para cada vetor de característica, que com a utilização do *kernel* de intersecção por histograma, a SVM obteve melhor generalização. Em média, os resultados das taxas de acerto do *kernel* de intersecção por histograma obtidos foram de aproximadamente 76%, enquanto que para o *kernel* gaussiano foi de aproximadamente 66%. Considerando que o *kernel* de intersecção por histograma obteve melhor generalização de classificação, na Figura 6.4 tem-se um gráfico com os resultados obtidos na classificação das lesões em simétricas e assimétricas e sua determinada taxa de acerto para cada vetor de característica (A1, A2, A3, A4 e A5).




Figura 6.4: Resultados da classificação de assimetria por diferentes vetores de características utilizando o *kernel* de intersecção por histograma.

O melhor resultado foi na utilização do vetor de característica A1, onde obteve 96,54% de taxa de acerto, sendo 89,29% de acertos para as lesões simétricas e 100% de acerto para as lesões assimétricas. No caso dos resultados dos vetores A2, A3 e A4, apenas houve boa generalização para a classe de assimetria (93,19%, 93,19% e 80,42%, respectivamente). Isso pode ocorrer, dependendo do conjunto de imagens de treinamento, pois algumas lesões assimétricas possuem características próximas as simétricas. Para o vetor A5, o resultado obtido já se mostrou mais equilibrado. A quantidade de acertos para as lesões simétricas foi de 72,32% e para as assimétricas foram 71,06% de acertos.

6.2.2 Borda

As bordas das lesões são classificadas em regulares ou irregulares, por meio da utilização do classificador inteligente SVM. As características que representam a borda e são utilizadas como entradas para a SVM, estão representadas nos vetores de características B1, B2, B3 e B4, que foram definidos na Subseção 5.5.2. São analisados os resultados para o *kernel* gaussiano e intersecção por histograma. Foi utilizado um conjunto de 50% das imagens no treinamento para a classificação com ambos os *kernels*, que obteve melhores resultados. Na Tabela 6.5 têm-se os resultados obtidos para ambos os *kernels* e os diferentes vetores de características utilizados.

Tabela 6.5. Resultados da classificação de borda utilizando o *kernel* gaussiano e a intersecção por histograma.

Vetores de características	Gaussiano			Intersecção por histograma		
	Regular	Irregular	Taxa de acerto	Regular	Irregular	Taxa de acerto
B1	17,14%	96,84%	82,38%	51,43%	76,58%	72,02%
B2	11,43%	96,20%	80,83%	57,14%	75,95%	72,54%
B3	34,29%	87,97%	78,24%	8,57%	100%	83,42%
B4	22,86%	94,30%	81,35%	71,43%	74,68%	74,09%

Para classificar a característica de borda das lesões, apesar do *kernel* gaussiano ter atingido uma quantidade maior de taxas de acerto, o *kernel* de intersecção por histograma obteve melhores resultados do que o *kernel* gaussiano, analisando os acertos das duas classes, como pode ser visto na Tabela 6.5. Considerando que o *kernel* de intersecção por histograma obteve melhor generalização de classificação, na Figura 6.5 tem-se um gráfico com os resultados obtidos na classificação das lesões em regulares e irregulares e a taxa de acerto para cada vetor de característica (B1, B2, B3 e B4).

A melhor generalização foi para o vetor de característica B4, que permitiu uma classificação equilibrada entre as classes. Obteve-se 74,09% de taxa de acerto, tendo 71,43% de acertos para as lesões regulares e 74,68% para as lesões irregulares.




Figura 6.5: Resultados da classificação de borda por diferentes vetores de características utilizando o *kernel* de intersecção por histograma.

O resultado apresentado pela utilização do vetor B4, foi considerado com melhor generalização, mesmo os vetores B1 e B2 obtendo uma quantidade maior de acertos para a classe irregular, pois não obtiveram bons resultados na classificação da classe regular. Essa dificuldade em classificar as lesões com bordas regulares, ocorre devido a pouca quantidade de imagens representando essa característica, que possui apenas 69 imagens, enquanto há 316 imagens com lesões de borda irregulares. O vetor B3 se mostrou um bom classificador para a classe irregular, atingindo 100% de acertos, mas não obteve resultados significativos para o reconhecimento das bordas regulares.

6.2.3 Cor

Para a classificação da característica de cor das lesões de pele, que é representada pelas classes uniforme e não uniforme, foram utilizados pela SVM os vetores C1, C2, C3 e C4 (Subseção 5.5.3), com as características extraídas. Na Tabela 6.6 têm-se os resultados obtidos na classificação pelos kernels: gaussiano e intersecção por histograma, ambos a partir de um conjunto de treinamento com 50% de imagens, onde obtiveram melhores resultados.

Tabela 6.6. Resultados da classificação de cor utilizando o *kernel* gaussiano e a intersecção por histograma.

Vetores de características	Gaussiano			Intersecção por histograma		
	Uniforme	Não uniforme	Taxa de acerto	Uniforme	Não uniforme	Taxa de acerto
C1	43,75%	73,45%	70,98%	50%	79,66%	77,20%
C2	43,75%	73,45%	70,98%	50%	79,10%	76,68%
C3	43,75%	75,71%	73,06%	56,25%	75,14%	73,58%
C4	43,75%	75,71%	73,06%	56,25%	75,14%	73,58%

Considerando a média das taxas de acerto de cada *kernel*, a intersecção por histograma também obteve melhores resultado para a classificação dessa característica, conforme visto na Tabela 6.6. Os resultados obtidos por este *kernel* são apresentados no gráfico da Figura 6.6.




Figura 6.6: Resultados da classificação de cor por diferentes vetores de características utilizando o *kernel* de intersecção por histograma.

A característica de cor não obteve um bom resultado na classificação da classe uniforme, onde teve 56,25% de acertos. Mas a taxa de acerto da classificação foi de 73,58%, para os vetores C3 e C4, devido à quantidade de acerto da classe não uniforme, que obteve 75,14%. Esses resultados são provenientes da pequena quantidade de imagens da classe

uniforme, que corresponde a 31 imagens, enquanto a classe não uniforme possui 354, onde o conjunto de imagens de treinamento não permitiu representar melhor esta classe. Os resultados foram iguais tanto para o vetor C1 e C2, quanto para o C3 e C4, devido à representação das características no vetor. O vetor C2 possui 3 características iguais as do vetor C1 e mais outra característica de cor. Isso não influenciou na mudança da classificação. O mesmo ocorreu para os vetores C3 e C4, que possuem 9 e 10 características, respectivamente. O intuito era analisar se a característica adicional melhoraria o resultado.

6.2.4 Textura

As classes regular e irregular foram consideradas para representar a característica de textura. Diferentes características foram extraídas e representadas pelos vetores T1, T2, T3 e T4, vistos na Subseção 5.5.4. Os vetores de características foram utilizados pela SVM para classificar as lesões nas suas determinadas classes. Por meio da análise de resultados, foram utilizadas 30% das imagens para treinamento nos testes com o *kernel* gaussiano e com o *kernel* de intersecção por histograma. Na Tabela 6.7 têm-se os resultados obtidos para a classificação da textura.

Tabela 6.7. Resultados da classificação de textura utilizando o *kernel* gaussiano e a intersecção por histograma.

Vetores de características	Gaussiano			Intersecção por histograma		
	Regular	Irregular	Taxa de acerto	Regular	Irregular	Taxa de acerto
T1	61,69%	64,10%	62,73%	60,39%	69,23%	64,21%
T2	91,56%	26,50%	63,47%	68,18%	51,28%	60,89%
T3	87,01%	30,77%	62,73%	60,39%	68,38%	63,84%
T4	65,58%	59,83%	63,10%	64,94%	63,25%	64,21%

Os resultados da Tabela 6.7, observa-se que a média das taxas de acerto da classificação com o *kernel* de intersecção por histograma, é um pouco maior comparada com o *kernel* gaussiano. Considerando que a irregularidade é uma característica importante para identificar as lesões do tipo ceratose seborréica, o resultado do *kernel* de intersecção por histograma, utilizando o vetor T1, permitiu classificar melhor a textura irregular, com 69,23% de acerto, apesar de não ter obtido um bom resultado na classificação das lesões regulares,

obtendo-se 60,39% de acerto, como pode ser visto na Figura 6.7, onde o classificador obteve 64,21% de taxa de acerto. A dificuldade em classificar a textura das lesões deve-se a dificuldade do classificador em diferenciar as duas classes por meio das características extraídas pelo descritor de textura.




Figura 6.7: Resultados da classificação de textura por diferentes vetores de características utilizando o *kernel* de intersecção por histograma.

O trabalho abordado no estado da arte [53], que avaliou a eficiência do algoritmo de classificação das características, e para isso foi utilizado o K-vizinhos mais próximos (K-NN), para classificar a assimetria (A), borda (B), cor (C) e estruturas diferenciais (D), que é exposto na Tabela 6.8, bem como os resultado do presente trabalho que utiliza a máquina de vetor de suporte (SVM) para classificar as características de assimetria (A), borda (B), cor (C) e textura (T). Na mesma são apresentadas as referências dos trabalhos, os anos de suas publicações, os métodos de segmentação, os classificadores utilizados, as características classificadas e suas taxas de acerto, respectivamente.

No trabalho de Rosado [53] a característica de assimetria (A) obteve 61% de taxa de acerto. A característica de borda (B) obteve 23% de acerto para as classes correspondentes. A característica cor (C) obteve 60% de acerto e a característica de estrutura diferencial (D) obteve 68% de acerto. No presente trabalho, o método proposto obteve 96,54% de acertos na classificação da assimetria, 74,09% de acertos na classificação da borda, 73,58% de acerto na classificação da cor e 64,21% de acerto na classificação da textura.

Tabela 6.8: Resultados dos trabalhos desenvolvidos para a classificação das características das lesões de pele.

Fonte	Ano	Segmentação	Classificador	Características	Taxa de acerto
Método proposto	2012	Modelo Chan-Vese	SVM	A	96,54%
				B	74,09%
				C	73,58%
				T	64,21%
[53]	2009	Análise do histograma	K-NN	A	61%
				B	23%
				C	60%
				D	68%

Apesar dos classificadores do presente trabalho ter obtido resultados melhores para as mesmas características avaliadas, ou seja, assimetria (A), borda (B) e cor (C), não foi possível realizar uma comparação entre os trabalhos, devido as imagens da base e a quantidade de classes utilizadas na classificação serem diferentes.

6.2.5 Lesões de pele

Considerando a importância de diferenciar lesões benigna de malignas, foram realizados testes para classificar lesões nevus e melanoma, por meio do classificador binário SVM. Também é importante diferenciar a ceratose seborréica (lesão benigna) do melanoma (lesão maligna), pois devido as suas semelhanças, muitas vezes são confundidas. Uma outra classificação é realizada para diferenciar os nevus da ceratose seborréica, que apesar de serem lesões benignas, possuem características diferentes, considerando que a ceratose seborréica não segue exatamente a regra ABCD.

O vetor de característica utilizado pela SVM para classificar as lesões de pele foi representado por 44 características que são: as características dos vetores que obtiveram melhores resultados na classificação das características de assimetria, borda, cor e textura. Na Figura 6.8, tem-se o vetor de característica utilizado para classificar as lesões de pele.




Figura 6.8. Vetor de característica para representar as características assimetria, borda, cor e textura.

Na Tabela 6.9, tem-se o resultado da classificação das lesões de pele, analisando os resultados obtidos pelo *kernels* gaussiano e intersecção por histograma. Considerando os melhores resultados obtidos, os conjuntos de treinamento para ambos os *kernels* foram estabelecidos por: na classificação de nevo x ceratose foram utilizadas 40% das imagens; no caso da classificação de nevo x melanoma, o treinamento foi realizado com 50% das imagens; já para a classificação de ceratose x melanoma, o conjunto de treinamento foi composto por 20% das imagens.

Tabela 6.9. Resultados da classificação das lesões de pele.

Vetores de características	Gaussiano			Intersecção por histograma		
	C1	C2	Taxa de acerto	C1	C2	Taxa de acerto
Nevo x ceratose (C1 x C2)	72,22%	73,33%	72,84%	77,78%	80%	79,01%
Nevo x melanoma (C1 x C2)	56,67%	73,02%	69,87%	76,67%	73,81%	74,36%
Ceratose x melanoma (C1 x C2)	60%	72,64%	69,73%	80%	72,64%	73,33%

A partir dos resultados obtidos na classificação, observou-se que o *kernel* de intersecção por histograma permitiu uma melhor generalização do classificador. No gráfico da Figura 6.9 tem-se a representação dos resultados obtidos.




Figura 6.9: Resultados da classificação das lesões de pele utilizando o *kernel* de intersecção por histograma.

O resultado da classificação do nevo e ceratose seborréica obteve 79,01% de taxa de acerto, permitindo classificá-las pelas características de assimetria, borda e cor da regra ABCD e pela textura, mesmo sendo dois tipos de lesões benignas. Isso foi possível devido a característica de textura das lesões, que permite diferenciá-las. A classe nevos obteve 77,78% de acerto e a classe ceratose seborréica obteve 80% de acerto.

Apesar da taxa de acerto da classificação de nevo e melanoma ser de 74,36% e os resultados entre as classes serem equilibrados, tendo 76,67% de acerto para a classe nevo e 73,81% de acerto para a classe melanoma, os resultados não foram muito bons, considerando que as características de assimetria, borda e cor analisadas em conjunto permitem obter uma clara diferenciação entre esses dois tipos de lesões. A taxa de erro de classificação para essas duas classes deve-se ao fato do banco possuir imagens com lesões que não seguem a regra utilizada no trabalho, como no caso das lesões da Figura 6.10, que são nevos melanocíticos e foram avaliados, pelo dermatologista, com bordas irregulares, cor não uniforme e também são lesões assimétricas, exceto a imagem (b) que é simétrica.

Na classificação da ceratose e melanoma, o resultado do classificador foi de 74,33% de taxa de acerto. No caso da classe ceratose seborréica o classificador obteve 80% de acerto e para a classe melanoma obteve 72,64% de acerto. Considerando que em alguns casos estas lesões são muito semelhantes, a textura é a principal característica que as diferenciam. O resultado se mostrou animador para a classificação desses tipos de lesões, mesmo a classificação da textura individual não ter obtido um bom resultado.




Figura 6.10: Exemplo de lesões com características que não seguem totalmente a regra ABCD.

Um resumo dos trabalhos abordados no estado da arte, que avaliaram a classificação de lesões de pele pode ser visto na Tabela 6.10, onde é apresentada as referências dos trabalhos, os anos de suas publicações, os métodos de segmentações, as características

extraídas, os classificadores utilizados, os tipos de lesões abordadas e suas taxas de acerto, respectivamente.

Tabela 6.10: Resultados dos trabalhos desenvolvidos para a classificação das lesões de pele.

Fonte	Ano	Segmentação	Características	Classificador	Imagens	Taxa de acerto
Método proposto	2012	Modelo Chan-Vese	ABC Textura	SVM	Nevo x ceratose	79,01%
					Nevo x melanoma	74,36%
					Ceratose x melanoma	74,33%
[3]	2009	Limiarização	ABCD	Correlação e modelo de regressão logística linear	Lesões pigmentadas	86%
[53]	2009	Análise do histograma	ABCD	Limiarização	Lesões não suspeitas	70%
					Lesões suspeitas	73%
[36]	2009	Não informado	ABCD Textura	SVM	Melanomas x nevos displásicos	100%
					Nevos displásicos x lesões não displásicos	76,08%
					Melanoma x nevos displásicos x lesões não displásicos	77,06%
[52]	2008	Limiarização	Cor Textura	SVM GML K-NN	Nevos comuns	62,50%
					Nevos displásicos	77,14%
					Melanomas	83,75%
[60]	2008	K-means	Cor Forma Textura	SVM	Melanomas	92,73%
					Benignas e não-melanomas	86%

No trabalho de Alcón et. al. [3] a classificação de lesões pigmentadas obteve 86% de taxa de acerto. No trabalho de Rosado [53] foram obtidos 70% de acertos para as lesões não suspeitas e 73% para as lesões suspeitas. No trabalho de Maglogiannis e Doukas [36], na classificação de nevos e melanoma obtiveram 100% de taxa de acerto, para os nevos displásicos e lesões não displásicas, a taxa de acerto foi de 76,08%, e no caso da classificação das três classes juntas, obtiveram 77,06% de taxa de acerto. No trabalho de Rahman, Bhattacharya e Desai [52] a classificação de nevos comuns obteve 62,50% de acertos, 77,14% de acertos para os nevos displásicos e 83,75% de acertos para os melanomas. No trabalho de Soares [60], a classificação do melanoma obteve 92,73% de acerto e para as lesões benignas e não-melanomas, obteve 86% de acerto.

No presente trabalho, o método proposto obteve 79,01% de taxa de acerto na classificação entre nevos e ceratose seborréica, tendo 77,78% de acerto para a classe nevo e

80% de acerto para a classe ceratose seborréica. Na classificação de nevo e melanoma, obteve-se 74,36% de taxa de acerto, sendo 76,67% de acerto para a classe nevo e 73,81% de acerto para a classe melanoma. Na classificação de ceratose seborréica e melanoma obteve-se 74,33% de taxa de acerto, tendo 80% de acerto para a classe ceratose seborréica e 72,64% de acerto para a classe de melanoma. Não foi possível realizar uma comparação entre os trabalhos, devido as imagens da base e o tipo de classificação serem diferentes, além das lesões de pele abordada não serem do mesmos tipos.

Os resultados apresentados no presente trabalho mostram que o método desenvolvido obteve resultados promissores na segmentação por meio do modelo Chan-Vese, e também com a utilização da SVM para a caracterização e classificação das lesões de pele dos tipos nevo melanocítico, ceratose seborréica e melanoma, a partir das características de assimetria, borda, cor e textura extraídas das lesões.

Considerando que a base de imagens do presente trabalho é heterogenia, os resultados da classificação podem ser prejudicados em alguns casos. Dessa forma, as características extraídas de algumas imagens não permitem representar corretamente a lesão, como a cor e a textura, que no caso de imagens onde a presença de muitos pelos, reflexos e luminosidade atrapalham a definição de informações corretas para essas características.

CONCLUSÕES

Neste trabalho apresentou-se um método de detecção e caracterização de imagens fotográficas de lesões de pele, utilizando o modelo Chan-Vese e a máquina de vetor de suporte (SVM), com o objetivo de auxiliar o dermatologista no diagnóstico, disponibilizando informações sobre as características das lesões de pele. Para minimizar a presença dos ruídos nas imagens foi utilizando o filtro não linear de difusão anisotrópica. O modelo de contorno ativo sem borda foi aplicado com o intuito de estabelecer uma melhor borda para a lesão. Descritores foram utilizados para extrair as características assimetria, borda, cor e textura das lesões de pele que são utilizadas pela SVM para classificá-las.

Com a aplicação do filtro de difusão anisotrópica, realizou-se a suavização das imagens sem perder a irregularidade da borda. Os ruídos foram eliminados parcialmente, exceto nos casos com presença de reflexos e sombras. Este filtro foi fundamental para obter uma melhor segmentação das imagens com muitos pelos.

A segmentação das imagens por meio do modelo de contorno ativo sem borda (Chan-Vese) permitiu localizar a maioria das imagens com regiões próximas da cor da pele e também as imagens muito ruidosas, inclusive no couro cabeludo. No caso das imagens compostas por uma grande área de sombra ou reflexos externos a lesão ou sobre sua fronteira, o modelo Chan-Vese não possibilitou a detecção das lesões em algumas dessas imagens ou não definiu corretamente as bordas das mesmas.

Devido à diferença de tamanho das lesões nas imagens, ou seja, conforme sua proximidade no momento da aquisição, a definição da curva sobre a imagem na aplicação do modelo Chan-Vese, estabeleceu a precisão da detecção da borda da lesão. Quanto mais próxima a curva estiver da lesão, melhor será o resultado, pois além de detectar a lesão mais rapidamente, menor é a possibilidade de detectar bordas falsas, como as causadas por

reflexos. Desta forma, a definição de uma curva de 140×140 para as lesões grandes e de 40×40 para as lesões pequenas foi importante, pois influenciou nos resultados da detecção correta das lesões. Pode ser considerado um outro método para definir uma curva ideal para a segmentação de cada lesão específica, como a utilização de uma outra técnica de segmentação para estabelecer um contorno inicial mais próximo do formato e tamanho de cada lesão.

A partir da utilização dos filtros morfológicos para tratar as imagens segmentadas, com presença de ruídos externos, orifícios interiores e bordas muito serrilhadas, obteve-se uma melhor definição da lesão. No caso de algumas imagens com ruídos externos e orifícios interiores muito grandes, a aplicação dos filtros não permitiu sua eliminação, considerando que a definição do elemento estruturante não pôde ser muito grande para não prejudicar a irregularidade da borda.

O método desenvolvido neste trabalho permitiu a detecção e definição dos contornos das lesões de pele de forma animadora. Considerando a análise visual realizada pelo dermatologista, o método obteve 94,36% de taxa de acerto. A qualidade dos contornos das lesões detectadas também foi avaliada. Os contornos foram avaliados como bons em 91,43% das imagens e o restante foi considerado razoável.

As características de assimetria, borda, cor e texturas extraídas neste trabalho proporcionaram resultados animadores na classificação, possibilitando identificar cada característica, além de permitir a diferenciação entre as lesões do tipo nevo, ceratose seborréica e melanoma, a partir do classificador SVM.

Nos testes realizados para classificar cada característica, passando seus dados como entrada para o classificador SVM, a classificação da assimetria obteve 96,54% de taxa de acerto das imagens em suas determinadas classes: simétrica, com 89,29% de acerto e a assimétrica com 100% de acerto. A classificação da característica de borda obteve 74,09% de taxa de acerto, onde houve um equilíbrio no resultado entre as classes, tendo-se 71,43% de acerto para a classe regular e 74,68% de acerto para a classe irregular. Para a classificação de cor, o classificador obteve 73,58% de taxa de acerto, sendo 56,25% de acerto para a classe uniforme e 75,14% de acerto para a classe não uniforme. A classificação para a classe uniforme não obteve um bom resultado, devido a pouca quantidade de imagens para o treinamento, comparada a outra classe. Na classificação da textura a taxa de acerto foi de 64,21%, obtendo 60,39% de acerto para a classe regular e 69,23% de acerto para a classe irregular. Neste caso, as características extraídas pelo descritor de textura não possibilitou uma boa generalização do classificador.

Para a diferenciação entre os tipos de lesões de pele abordadas neste trabalho, a SVM obteve 79,01% de taxa de acerto para diferenciar os nevos da ceratose seborréica. Apesar desses dois tipos de lesões serem benignas, a SVM permitiu a separação das amostras nas duas classes de forma considerável, obtendo 77,78% de acerto para a classe de nevos e 80% de acerto para a ceratose seborréica.

Para diferenciar os nevos dos melanomas o classificador alcançou 74,36% de taxa de acerto. Apesar de apresentar um equilíbrio de acerto entre as duas classes, tendo 76,67% de acerto para a classe nevo e 73,81% de acerto para a classe melanoma, esperavam-se resultados mais expressivos, visto que as duas classes possuem características bem diferentes, conforme a regra ABCD. A taxa de erro de classificação para essas duas classes deve-se a existência de algumas imagens no banco compostas por lesões que não seguem exatamente a regra utilizada no trabalho, como os nevos melanocíticos que são lesões benignas, mas as suas características de assimetria (A), borda (B) e cor (C) foram definidas pelo dermatologista, como assimétrica, irregular e não uniforme, respectivamente.

No caso da diferenciação da ceratose seborréica do melanoma a taxa de acerto foi de 74,33%. A classificação para a classe ceratose seborréica obteve 80% de acerto e para a classe melanoma obteve 72,64% de acerto. Considerando que estes dois tipos de lesões são muito semelhantes em algumas imagens da base, sendo a textura a principal característica que as diferenciam, o resultado foi animador, mesmo a classificação individual da textura não ter obtido um bom resultado.

O método desenvolvido se mostrou promissor para a detecção das lesões de pele, por meio do Chan-Vese, e também para a classificação das lesões de pele e suas características, pelo classificador SVM. As informações obtidas pelo método podem ser disponibilizadas ao dermatologista com o objetivo de auxiliá-lo no diagnóstico das lesões de pele.

As avaliações feitas pelo dermatologista para estabelecer as características e avaliar os resultados da segmentação podem influenciar nos resultados finais tanto da detecção, como na classificação das lesões de pele e suas características, caso sejam avaliadas por outros especialistas. Com o aprimoramento destas técnicas utilizadas, para solucionar os problemas encontrados, como a heterogeneidade das imagens da base, o método desenvolvido pode obter resultados mais expressivos dos que foram apresentados.

TRABALHOS FUTUROS

Considerando a necessidade de aperfeiçoamento dos problemas encontrados e a possibilidade de continuidade do método desenvolvido, as seguintes tarefas podem ser analisadas para o desenvolvimento de métodos relacionados às detecção e classificação de imagens médicas: estudo ou desenvolvimento de métodos que tratem reflexos e sombras, para que não haja restrição no momento da aquisição das imagens, possibilitando obtê-las até mesmo por dispositivos móveis, que possua boa qualidade de imagem. Considerar um método para definir uma curva próxima a lesão de pele, para que possa detectá-la mais rapidamente e de forma precisa, pela minimização de sua energia pelo modelo Chan-Vese. Analisar outra técnica de segmentação, como a utilização de lógica fuzzy, para ser comparada com o Chan-Vese. Utilizar outros descritores para extrair as características referentes à regra ABCD. Também abordar outros tipos de lesões de pele e analisar outras características, como a evolução (E), que foi recentemente inserida na regra ABCDE. Considerar outra técnica para analisar a textura para que possa representar melhor a lesão de pele. Analisar os resultados das classificações obtidas por outros classificadores, para verificar qual apresenta melhores resultados tanto na caracterização, como também na classificação de lesões de pele.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] ABBAS, Q.; FONDÓN, I.; RASHID, M. Unsupervised skin lesions border detection via two-dimensional image analysis. **Computer Methods and Programs in Biomedicine**, COMM-3090, p. 1-15, 2010.
- [2] AL-AKAIDI, M. **Fractal speech processing**. New York: Cambridge University Press, 2004.
- [3] ALCÓN, J. F.; CIUHU, C.; KATE, W. T.; HEINRICH, A.; UZUNBAJAKAVA, N. Automatic imaging system with decision support for inspection of pigmented skin lesions and melanoma diagnosis. **IEEE Journal of Selected Topics in Signal Processing**, v. 3, n. 1, p. 14-25, 2009.
- [4] ALVAREZ, L.; LIONS, P.-L.; MOREL, J.-M. Image Selective Smoothing and Edge Detection by Nonlinear Diffusion. **SIAM Journal on Numerical Analysis**, v. 29, n. 3, p. 845-866, 1992.
- [5] AMICO, M.; FERRI, M.; STANGANELLI, I. Qualitative asymmetry measure for melanoma detection. In: **IEEE International Symposium on Biomedical Imaging: Nano to Macro**, v. 2, 2004, p. 1155-1158, ISBN: 0-7803-8388-5.
- [6] ARAUJO, A. F. **Método para extração e caracterização de lesões de pele usando difusão anisotrópica, crescimento de regiões, watersheds e contornos ativos**. 2010. 100 f. Dissertação de Mestrado em Ciência da Computação, Instituto de Biociência, Letras e Ciências Exatas, Universidade Estadual Paulista, São José do Rio Preto, 2010.
- [7] ARAUJO, A. F.; TAVARES, J. M. R. S.; OLIVEIRA, R. B.; ROSSETTI, R. B.; MARRANGHELLO, N.; PEREIRA, A. S. Análise e Caracterização de Lesões de Pele para Auxílio ao Diagnóstico Médico. **Avanços em Visão Computacional**, Omnipax, 2012. p. 1-19.

- [8] ARAUJO, A. F.; TAVARES, J. M. R. S.; OLIVEIRA, R. B.; MARRANGHELLO, N.; PEREIRA, A. S.; ROSSETTI, R. B. Uma Metodologia Híbrida para Segmentação de Lesões de Pele In: **VII Workshop de Visão Computacional**, In: VII Workshop de Visão Computacional. Curitiba, 2011. v.1. p. 173-178.
- [9] BABINI, M.; MARRANGHELLO, N. **Introdução às redes neurais artificiais**. São Paulo: Cultura acadêmica, 2007. 61 p.
- [10] BARCELOS, C. A. Z.; BOAVENTURA, M.; SILVA JUNIOR, E. C. A well-balanced flow equation for noise removal and edge detection. **IEEE Transactions on Image Processing**, v. 12, n. 7, p. 751-763, 2003.
- [11] BARCELOS, C. A. Z.; PIRES, V. B. An automatic based nonlinear diffusion equations scheme for skin lesion segmentation. **Applied Mathematics and Computation**, v. 215, p. 251-261, 2009.
- [12] BARLA, A. Histogram intersection kernel for image classification. In: **International Conference on Image Processing**. Italy, v. 2, 2003, p. 513-516.
- [13] BEUCHER, S.; LANTUÉJOUL, C. Use of watersheds in contour detection. In: **International Workshop on Image processing: Real-time Edge and Motion Detection/Estimation**. France, 1979.
- [14] BEUREN, A. T.; PINHEIRO, R. J. G.; FACON, J. Abordagem morfológica de segmentação do melanoma. In: **Workshop de Visão Computacional**, 7. Curitiba, 2011, p. 249-254.
- [15] BRASIL. Ministério da Saúde. Instituto Nacional de Câncer. **Estimativa 2010**: Incidência de câncer no Brasil. Rio de Janeiro: INCA, 2009. 98 p.
- [16] BRASIL. Ministério da saúde. Instituto Nacional de Câncer. **Estimativa 2012**: incidência de câncer no Brasil. Instituto Nacional de Câncer José Alencar Gomes da Silva, Coordenação Geral de Ações Estratégicas, Coordenação de Prevenção e Vigilância. Rio de Janeiro: INCA, 2011. 118 p.
- [17] BURGESS, C. J. C. A tutorial on support vector machines for pattern recognition. **Data Mining and Knowledge**, v. 2, p. 121-167, 1998.
- [18] CARVALHO, H. F.; BUZZATO, C. B. C. **Células**: uma abordagem multidisciplinar. 1. ed. Barueri, SP: Manole, 2005.

- [19] CELEBI, M. E.; KINGRAVI, H. A.; UDDIN, B.; IYATOMI, H.; ASLANDOGAN, Y. A.; STOECKER, W. V.; MOSS, R. H. A methodological approach to the classification of dermoscopy images. **Computerized Medical Imaging and Graphics**, v. 31, p. 362-373, 2007.
- [20] CHAN, T. F.; VESE, L. A. Active contours without edges. **IEEE Transactions on Image Processing**, v. 10, n. 2, p. 266-277, 2001.
- [21] CUCÉ, L. C.; FESTA NETO, C. (Org.) et al. **Manual de dermatologia**. 2 ed. São Paulo: Atheneu, 2001, 660 p.
- [22] CUDEK, P.; GRZYMALA-BUSSE, J. W.; HIPPE, Z. S. Melanocytic skin lesion image classification. Part I: Recognition of skin lesion. In: **Conference on Human System Interactions (HSI)**. 3rd, Rzeszow, Poland, 2010, p. 251-257.
- [23] DERMATLAS. Cohen, B. A.; Lehmann, C. U. **Johns Hopkins University - DermAtlas**. Disponível em Dermatology Image Atlas: <<http://dermatlas.med.jhmi.edu/>> Acesso em: 2012.
- [24] DERMATOLOGY DATABASE. Y. Suzumnura. **YSP Dermatology Image Database - Japan**. Disponível em YSP Dermatology Image Database: <<http://homepage1.nifty.com/ysh/indexe.html>>. Acesso: em 2012.
- [25] DERMIS. Diepgen TL, Yihune G et al. **Dermatology Information System - DermIS**. Disponível em Atlas Dermatológico Online: <<http://www.dermis.net/dermisroot/en/home/index.htm>>. Acesso em: 2012.
- [26] DERMNET, SKIN DISEASE ATLAS. Campbell Jr, J. L. **Nevi, melanoma**. Disponível em Malignant Melanoma e Melanocytic Nevi: <<http://www.dermnet.com/videos/nevi-melanoma/>>. Acesso: em 2012.
- [27] DERMNET, SKIN DISEASE ATLAS. Chapman, S. **Benign tumors**. Disponível em Seborrheic Keratosis: <<http://www.dermnet.com/videos/benign-tumors/>>. Acesso: em 2012.
- [28] FACON, J. **Morfologia matemática: teoria e exemplos**. Curitiba: Editora Universitária Champagnat da Pontífica Universidade Católica do Paraná, 1996. 320 p.

- [29] FANTINATO, P. C. **Segmentação de voz baseada na análise fractal e na transformada wavelet**. 2008. 123 f. Dissertação de Mestrado em Física, Instituto de Física de São Carlos, Universidade de São Paulo, São Paulo, 2008.
- [30] GONZALEZ, R. C.; WOODS, R. E. **Digital image processing**. 2. ed. New Jersey: Prentice Hall, 2002. 793 p.
- [31] HOSPITAL A. C. CAMARGO. Equipe médica, **Tudo sobre o câncer**. Disponível em: < <http://www.hcanc.org.br> >. Acesso em: 2012.
- [32] INCA. Instituto Nacional De Câncer. **Tipos de câncer: Pele melanoma e pele não melanoma**. Disponível em: < <http://www2.inca.gov.br> >. Acesso: em 2012.
- [33] KASS, M.; WITKIN, A.; TERZOPOULOS, D. Snakes: Active contour models. **International Journal of Computer Vision**, v. 1, n.4, p. 321-331, 1988.
- [34] LEO, G. D.; PAOLILLO, A.; SOMMELLA, P.; FABBROCINI, G. Automatic diagnosis of melanoma: a software system based on the 7-point check-list. In: **International Conference on System Sciences**. 43rd, 2010, p. 1-10.
- [35] LORENA, A. C; CARVALHO, A, C. P. L. F. UMA INTRODUÇÃO ÀS *SUPPORT VECTOR MACHINES*. **Revista de Informática teórica e aplicada**, v. XIV, n. 2, p. 43-67, 2007.
- [36] MAGLOGIANNIS, I. Overview of advanced computer vision systems for skin lesions characterization. **IEEE Transactions on Information Technology in Biomedicine**, v. 13, n. 5, p. 721-733, 2009.
- [37] MARQUES FILHO, O.; VIEIRA NETO, H. **Processamento Digital de Imagens**. 1. ed. Rio de Janeiro: Brasport, 1999. 307 p.
- [38] MEDED. J. L. Melton, & MD, Editores. Skin Cancer and Benign Tumor Image - **Loyola University - Chicago**. Disponível em Loyola University Dermatology Medical Education: <<http://www.meddean.luc.edu/lumen/MedEd/medicine/>>. Acesso em 2012.
- [39] MENDOZA, C. S.; SERRANO, C.; ACHA, B. Scale invariant descriptors in pattern analysis of melanocytic lesions. In: **IEEE International Conference on Image Processing (ICIP)**, 16th, 2009, Cairo, p. 4193-4196.

- [40] MUMFORD, D. SHAH, J. Optimal approximations by piecewise smooth functions and associated variational problems. **Communications on Pure and Applied Mathematics**, v. XLII, p. 577-685, 1989.
- [41] NORDSTRÖM, K. N. Biased anisotropic diffusion: a unified regularization and diffusion approach to edge detection. In: **Proceedings of The First European Conference on Computer Vision**, 1990, New York. p. 18-27.
- [42] NORTON, K. -A.; IYATOMI, H.; CELEBI, M. E.; SCHAEFER, G.; TANAKA, M.; OGAWA, K. Development of a novel border detection method for melanocytic and non-melanocytic dermoscopy images. In: **Annual International Conference of the IEEE EMBS**, 32nd. Buenos Aires, Argentina, 2010, p. 5403-5406.
- [43] OLIVEIRA, R. B.; ARAUJO, A. F.; TAVARES, J. M. R. S.; MARRANGHELLO, N.; ROSSETTI, R. B.; PEREIRA, A. S. **Extraction of Skin Lesions Contours using Anisotropic Difusion and active Contour Model without Edges**, In: 10th World Congress On Computational Mechanics, WCCM. Computational Bioimaging and Visualization, São Paulo, 2012, p. 1-18.
- [44] OLIVEIRA, R. B.; CALDAS JÚNIOR, C. R. D.; GUIDO, R. C.; MARRANGHELLO, N.; PEREIRA, A. S.; ARAUJO, A. F.; TAVARES, J. M. R. S.; ROSSETTI, R. B. **Classificação de assimetria em lesões de pele por meio de imagens usando máquina de vetor de suporte**, In: VIII Workshop de Visão Computacional, WVC, Goiânia , 2012, p. 1-6.
- [45] OLIVEIRA, R. B.; CALDAS JÚNIOR, C. R. D.; PEREIRA, A. S.; GUIDO, R. C.; ARAUJO, A. F.; TAVARES, J. M. R. S.; ROSSETTI, R. B. **Characterization of Texture in Image of Skin Lesions by Support Vector Machine**, In: 7 Iberian Conference on Information Systems and Technologies, CISTI. First Workshop on Computational Biomedical Image Processing and Analysis, WCBIPA, Madrid, 2012, p. 1-2.
- [46] OLIVEIRA, R. B.; CALDAS JÚNIOR, C. R. D.; PEREIRA, A. S.; MARRANGHELLO, N.; ARAUJO, A. F.; TAVARES, J. M. R. S.; ROSSETTI, R. B. **Extração de características de lesões de pele a partir de imagens**, In: 34º Congresso Nacional de Matemática Aplicada e Computacional, CNMAC, Águas de Lindóia, 2012, p. 1 -2.
- [47] OLIVEIRA, R. B.; GUIDO, R. C.; MARRANGHELLO, N.; ARAUJO, A. F.; TAVARES, J. M. R. S.; ROSSETTI, R. B.; PEREIRA, A. S. Caracterização de lesões de pele em imagens digitais a partir da máquina de vetor de suporte. **Interciência e sociedade**, p. 1-12, 2012.

- [48] OSHER, S.; SETHIAN, J. A. Fronts propagating with curvature dependent speed: algorithms based on Hamilton-Jacobi formulations. **Journal of Computational Physics**, v. 79, p. 12-49, 1988.
- [49] OTSU, N. A threshold selection method from gray-level histograms. **IEEE Transactions on Systems, Man, and Cybernetics**, v. SMC-9, p. 62-66, 1979.
- [50] PERONA, P; MALIK, J. Scale-space and edge detection using anisotropic diffusion. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 12, n. 7, p. 629-639, 1990.
- [51] PIZARRO, P.; COMUNELLO, E.; MANTELLI, S. Segmentação por crescimento de região. In: WANGENHEIM, A. V. **Introdução à visão computacional**. Santa Catarina: UFSC, p. 35-64. Disponível em <<http://www.inf.ufsc.br/~visao/regiongrow.pdf>>. Acesso em: 2012.
- [52] RAHMAN, M. M.; BHATTACHARYA, P.; DESAI, B. C. A multiple expert-based melanoma recognition system for dermoscopic images of pigmented skin lesions. **BioInformatics and BioEngineering**, 2008. IEEE International Conference on. 8th, BIBE, p. 1-6, 2008.
- [53] ROSADO, L. F. C. M. G. **Sistema automático para diagnóstico de lesões cutâneas baseado em imagens dermoscópicas**. 2009. 72 f. Dissertação de mestrado em Engenharia Biomédica, Universidade Técnica de Lisboa, Portugal, 2009.
- [54] SAÚDE TOTAL. Artigos Dermatologia. **Manchas na pele**. Disponível em <http://www.saudetotal.com.br/artigos/dermatologia/tvescola_manchaspele.asp>. Acesso em: 2012.
- [55] SAÚDE TOTAL. **Câncer da Pele**: fotoproteção. Vida saudável com o sol. Disponível em <<http://www.saudetotal.com.br/prevencao/topicos/default.asp>>. Acesso em: 2012.
- [56] SBD. Sociedade Brasileira de Dermatologia. **Doenças de pele**. Disponível em: <<http://www.sbd.org.br/>>. Acesso: em 2012.
- [57] SCHÖLKOPF, B; SMOLA, A. J. (2002). **Learning with Kernels**. Cambridge/MA: The MIT Press, 2000.
- [58] SKIN CANCER GUIDE. **Melanoma**. Disponível em <http://www.skincancerguide.ca/melanoma/images/melanoma_images.html>. Acesso em: 2012.

- [59] SKIN CANCER GUIDE. **Skin cancer self-examination**. Disponível em: <http://www.skincancerguide.ca/prevention/self_examination.html>. Acesso: em 2012.
- [60] SOARES, H. B. **Análise e classificação de imagens de lesões da pele por atributos de cor, forma e textura utilizando máquina de vetor de suporte**. 2008. 160 f. Tese de Doutorado em Engenharia Elétrica e de Computação, Universidade Federal do Rio Grande do Norte, Natal, 2008.
- [61] SONKA, M.; HLAVAC, V.; BOYLE, R. **Image processing, analysis, and machine vision**. 2. ed. PWS, 1998, 800 p.
- [62] WOLFF, K.; JOHNSON, R. A.; SUURMONS, D. **Dermatologia: atlas e texto**. 5 ed. Rio de Janeiro: McGraw-Hill Interamericana do Brasil, 2006, 1092 p.
- [63] YUAN, X.; YANG, Z.; ZOURIDAKIS, G.; MULLANI, N. SVM-based textura classification and application to early melanoma detection. In: **IEEE EMBS Annual International Conference**, 28th, New York, USA, 2006, p. 4775-4778.
- [64] ZHANG, N.; ZHANG, J.; SHI, R. An Improved Chan-Vese model for medical image segmentation. In: **International Conference on Computer Science and Software Engineering**, Wuhan, Hubei, 2008, p. 864-867.
- [65] ZHAO, H. -K.; CHAN, T.; MERRIMAN, B. OSHER, S. A variational Level Set approach to multiphase motion. **Journal of Computation, Physics**, v. 127, n. 0167, p. 179-195, 1996.
- [66] ZHAO, J.; SHAO, F.; XU, Y.; ZHANG, X.; HUANG, W. An improved Chan-Vese model without reinitialization for medical image segmentation. In: **International Congress on Image and Signal Processing (CISP 2010)**, 3rd. Yantai, 2010, p. 1317-1321.
- [67] ZHOU, H.; SCHAEFER, G.; CELEBI, M. E.; IYATOMI, H.; NORTON, K.-A.; LIU, T.; LIN, F. Skin lesion segmentation using an improved snake model. In: **Annual International Conference of the IEEE EMBS**, Buenos Aires, Argentina, 2010, p. 1974-1977.