**Universidade de São Paulo
Instituto de Física de São Carlos**

David Antonio Sbrissa Neto

**Análise da assimetria e irregularidade de borda
entre lesões melanocíticas**

São Carlos
2015

David Antonio Sbrissa Neto

Análise da assimetria e irregularidade de borda entre lesões melanocíticas

Dissertação apresentada ao Programa de Pós-Graduação em Física do Instituto de Física de São Carlos da Universidade de São Paulo, para a obtenção do título de Mestre em Ciências.

Área de Concentração: Física Aplicada
Opção: Física Biomolecular
Orientador: Gonzalo Travieso

Versão Corrigida
(Versão original disponível na Unidade que aloja o programa)

São Carlos
2015

AUTORIZO A REPRODUÇÃO E DIVULGAÇÃO TOTAL OU PARCIAL DESTE TRABALHO, POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO PARA FINS DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

Ficha catalográfica elaborada pelo Serviço de Biblioteca e Informação do IFSC,
com os dados fornecidos pelo(a) autor(a)

Sbrissa Neto, David Antonio

Análise de assimetria e irregularidade de borda
entre lesões melanocíticas / David Antonio Sbrissa
Neto; orientador Gonzalo Travieso - versão corrigida
-- São Carlos, 2015.
127 p.

Dissertação (Mestrado - Programa de Pós-Graduação em
Física Aplicada Biomolecular) -- Instituto de Física
de São Carlos, Universidade de São Paulo, 2015.

1. Reconhecimento de padrões. 2. Diagnóstico
precoce. 3. Processamento de imagens. 4. Regra do
ABCD. 5. Melanoma. I. Travieso, Gonzalo, orient. II.
Título.

AGRADECIMENTOS

Agradeço ao Prof. Dr. Gonzalo Travieso pela orientação do trabalho, pelo seu tempo e dedicação em ajudar a realizar este projeto.

Agradeço também aos professores Dr. Luciano da Fontoura Costa, Dr. Vanderlei Salvador Bagnato e Dr^a. Cristina Kurachi pela co-orientação neste trabalho, e sobretudo a pela paciência e dedicação ao longo desta jornada.

Agradeço a Dra. Ana Gabriela Salvio pelo importante auxílio e na colaboração com a pesquisa, além de ceder as imagens para o trabalho. Também agradeço aos doutores Giselle Rezze e Roger Chammas por contribuírem com o andamento do projeto.

Agradeço a todo corpo de funcionários do IFSC que de maneira direta ou indireta contribuíram para a conclusão deste trabalho.

Agradeço a minha família pelo apoio irrestrito ao meu mestrado, em especial meu pai David Antonio Sbrissa Junior, minha mãe Elaine Aparecida Lucatti Sbrissa e minha avó Maria Aparecida Nogueira Sbrissa.

Agradeço a todos colegas de sala que sempre me apoiaram e ajudaram quando precisei. Dentre eles Vilson Viera, Renato Fabbri, Cesar Comin, Henrique Ferraz, Cynthia Martins, Carlos Doro, Débora Corrêa, Thomas Peron.

Agradeço ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio financeiro referente ano de 2013.

“Todas as vitórias ocultam uma abdicação.”

— SIMONE DE BEAUVOIR

RESUMO

SBRISSA NETO, D. A. *Análise de assimetria de irregularidade de borda entre lesões melanocíticas*. 2015. 127 p. Dissertação (Mestrado em Ciências) - Instituto de Física de São Carlos, Universidade de São Paulo, São Carlos, 2015.

Nos últimos anos, o desenvolvimento da computação tem auxiliado profissionais da saúde no tratamento, prevenção e diagnóstico de doenças. Um dos grandes desafios do campo tem sido o desenvolvimento de métodos para a discriminação do câncer de pele do tipo melanoma maligno em relação às outras lesões benignas. Para tal, pesquisadores usam técnicas de processamento e análise de imagens, explorando métricas baseadas na regra ABCD, para o desenvolvimento de métodos de diagnóstico de melanoma através de imagens. Enquanto diversos estudos abordam a coloração e textura do melanoma, um tratamento sistemático da irregularidade dos melanomas ainda não foi relatado. O presente trabalho traz um estudo dos fatores que influenciam a discriminação de lesões melanocíticas malignas e benignas, tomando como referência a assimetria das lesões e as irregularidades contidas em sua borda. Foram coletadas 143 imagens de casos clínicos de melanoma maligno, nevos regulares e nevos atípicos. Após tratamentos iniciais das imagens e posterior segmentação das lesões, extraiu-se 52 métricas referentes ao propósito do trabalho. A visualização da projeção LDA das três categorias revelou boa discriminação entre as categorias melanoma com relação às demais, reforçando a premissa original da acentuada irregularidade dos melanomas. Este resultado foi confirmado pela validação cruzada da projeção, com acertos da ordem de 75% para o grupo melanoma e 54% e 40% para os respectivos grupos nevo regular e nevo atípico. Deste resultado prevê-se uma das aplicações do sistema, na discriminação geral entre melanoma e as demais nevos. Para tal, uniu-se os grupos benignos em uma única categoria para a validação cruzada, gerando cálculos de sensibilidade e especificidade da ordem de 90% e 73% respectivamente. Outro importante resultado foi a comparação desses valores com as informações sobre o diâmetro das lesões. Conclui-se que ambas medidas (borda e tamanho) são igualmente relevantes no diagnóstico do melanoma, reflexo da própria patologia do melanoma, na qual acentuam-se ambas características em relação às demais lesões. Porém, a junção de ambas informações em um único processamento não melhora a qualidade do diagnóstico, que nos permite prever que possa ser mais vantajoso proceder duas validações distintas com pesos iguais para o diagnóstico final. Por fim, um teste realizado com clínicos gerais e especialistas em melanoma revelou uma importante contribuição do método no auxílio de triagens ambulatoriais de casos suspeitos, principalmente para médicos com baixa ou nenhuma experiência em diagnóstico de melanoma.

Palavras-chave: Reconhecimento de padrões. Diagnóstico precoce. Processamento de imagens. Regra do ABCD. Melanoma maligno

ABSTRACT

SBRISSA NETO, D. A. *Asymmetry and border irregularity analysis between melanocytic lesions*. 2015. 127 p. Dissertação (Mestrado em Ciências) - Instituto de Física de São Carlos, Universidade de São Paulo, São Carlos, 2015.

Recent development in computer science have helped health professionals in the health area in the treatment, prevention and diagnostic of illnesses. One of the leading challenges in this field has been the development of methods for the skin cancer discrimination between the types of malignant melanoma in relation to other benign lesions. For this, researchers have been using techniques of image processing and analysis, exploring metrics based on the ABCD rule, to the development of methods of diagnostic of melanoma through images. While plenty of studies are about the color and texture of the melanoma, a systematic treatment of the irregularity of the melanoma has not been reported yet. The present work presents a study of the factors which influence the discrimination among the malignant melanocytic and benign lesions, having as a reference the asymmetry of the lesions and the irregularities in their edges. It was collected 143 images of clinic cases of malignant melanoma, regular nevus and atypical nevus. After initial treatment of the images, followed by a segmentation of the lesions, it was extracted 52 metrics referent to the purpose of this study. The visualization of the projection LDA in three categories revealed a good discrimination among the categories of melanoma in relation to the others, reinforcing the original premise of the melanomas' sharp irregularity. This result was confirmed by the cross-validation of the projection, with successes of 75 % to the melanoma group and 54 %-40 % to the regular nevus group and atypical nevus group, respectively. This result predicts one of the applications of the system in the general discrimination between the melanoma and the other nevus. In this regard, it was joined together the benign groups in one category to the cross-validation, generating calculations of sensibility and specificity of 90 % and 73 % respectively. Another important result was the comparison among these metrics with the information about the diameter of the lesions. It was concluded that both measurements (edges and size) are equally relevant in the diagnostic of the melanoma, reflection of the melanoma's own pathology, in which both characteristics are enhanced in relation to the other lesions. However, the combination of both measurement in only one processing does not improve the quality of the diagnostic, which allows the prediction that it can be more advantageous to produce two distinct validations with the same weights to the final diagnostic. To sum up, an accomplished test with doctors who are general practitioner and specialists in melanoma revealed a significant contribution in the method to help in the triage of medical consultations in suspicious cases, mainly to doctors with little or no experience in the diagnostic of melanoma.

Keywords: Pattern recognition. Early diagnosis. Image processing. ABCD rule. Malignant melanoma

LISTA DE FIGURAS

Figura 1.1 - Exemplo de um dermatoscópio clínico.	24
Figura 1.2 - Imagens de lesões melanocíticas distintas sob efeito da fluorescência óptica. a) Queratose seborreica e b) Melanoma maligno.	25
Figura 1.3 - Distribuição de unidades básicas de saúde, segundo razão médico/habitante por Unidades da Federação — Brasil, 2013.	26
Figura 2.1 - Esquema da pele humana. A figura é ampliada na junção entre a derme e a epiderme. Nessa região existem os melanócitos, responsáveis pela produção da substância de pigmentação da pele, a melanina.	31
Figura 2.2 - Classificação de lesões melanocíticas quanto à sua origem.	32
Figura 2.3 - Classificação das lesões melanocíticas quanto a profundidade dos ninhos dos melanócitos. A figura (A) mostra uma pele saudável e em seguida (B), (C) e (D) representam as classes juncionais, compostos e intradermais.	33
Figura 2.4 - Os cinco estágios do melanoma maligno. O primeiro estágio é conhecido por melanoma <i>in situ</i> , onde a lesão apenas atingiu a derme e o prognóstico de cura é o maior possível. Conforme o melanoma cresce internamente, os prognósticos de cura diminuem. No último estágio, a metástase, o melanoma atingiu a corrente sanguínea e se espalhou pelo corpo.	34
Figura 2.5 - Melanoma assimétrico	35
Figura 2.6 - Melanoma com borda irregular	35
Figura 2.7 - Melanoma com cores diferentes	35
Figura 2.8 - Melanoma com diâmetro alterado	36
Figura 3.1 - Representação computacional de uma imagem digital. Nessa representação, y representa as linhas da imagem digital, enquanto x representa as colunas.	38
Figura 3.2 - Processo de quantização de imagem digital. a) a imagem contínua a ser quantizada e a posição de seus <i>pixels</i> , na qual será feita a quantização, b) a imagem quantizada, com cada um dos <i>pixels</i> preenchidos com seu valor adequado.	38
Figura 3.3 - Os efeitos da resolução espacial. Resoluções de 256×256 , 64×64 e 16×16 <i>pixels</i>	39
Figura 3.4 - Imagem em escala de cinza. Pode-se observar a região selecionada e os valores de cada um de seus <i>pixels</i>	39

Figura 3.5 - Imagem RGB e seus respectivos canais vermelho, verde e azul	40
Figura 3.6 - Obtenção de um histograma a partir de uma imagem em escala de cinza. a) Imagem em escala de cinza e b) seu respectivo histograma.	40
Figura 3.7 - Resultado da limiarização de uma imagem em escala de cinza. a) Imagem em escala de cinza e b) Resultado para o limiar de 150 da escala de cinza.	41
Figura 3.8 - A) Exemplo de uma imagem RGB e B) sua respectiva conversão para escala de cinza (<i>grayscale</i>).	43
Figura 3.9 - Exemplo de aumento de contraste por alargamento do histograma. a) Imagem original de baixo contraste. b) Histograma da imagem original. c) Resultado da aplicação do aumento de contraste por alargamento. d) Histograma da imagem realçada.	44
Figura 3.10 - As figuras de (A – C) mostram o resultado da aplicação do filtro gaussiano aplicados a uma mesma imagem <i>grayscale</i> para os respectivos valores de desvio padrão $a = 2$, $a = 3$ e $a = 5$. Nota-se que para valores altos, a suavização da imagem torna-se intensa.	46
Figura 3.11 - Histograma de uma imagem de lesão melanocítica. Os pontos (1) e (2) destacados na figura são os máximos locais referentes à pele e a lesão. O ponto (3) destacado refere-se a intersecção das duas regiões. O valor deste <i>pixels</i> é usado na limiarização.	47
Figura 3.12 - Resultado da aplicação da limiarização.	47
Figura 3.13 - Exemplos de elementos estruturantes numa vizinhança 3×3 . Ambos ES possuem no centro seu <i>pixel</i> -origem diferenciado. a) Elemento estruturante 4 – <i>conexo</i> . b) Elemento estruturante 8 – <i>conexo</i>	49
Figura 3.14 - Dilatação de uma imagem binária. A Imagem Original foi dilatada por um elemento estruturante 4 – <i>conexo</i> . Os <i>pixels</i> diferenciados na Imagem Dilatada são acrescidos à forma.	50
Figura 3.15 - Erosão de uma imagem binária. A Imagem Original sofreu erosão por um elemento estruturante 4 – <i>conexo</i> . Os <i>pixels</i> diferenciados na Imagem Erodida são retirados da forma.	50
Figura 3.16 - Resultado da aplicação dos Operadores Morfológicos. a) Imagem ruidosa, com buracos internos e regiões desconectas da imagem principal. b) Eliminação dos ruídos obtida por erosão e dilatação.	51
Figura 3.17 - A) Exemplo de uma imagem binária e a obtenção de seus eixos principais e B) sua respectiva rotação. Nota-se o alinhamento dos eixos principais, indicando a correta orientação.	53
Figura 3.18 - A) Extração do <i>bounding box</i> e B) <i>convex hull</i>	54
Figura 3.19 - Esquema ilustrativo do processo de suavização por filtro gaussiano de um sinal de entrada $s(t)$	61

Figura 3.20 - Figura A: Curvograma de uma imagem modelo de padrão estrelar com seus picos mais relevantes detectados e o limiar em destaque. Figura B: Plotagem da imagem modelo e seus picos relevantes marcados, tais como na Figura A. Nota-se claramente que todos os picos detectados são relevantes na caracterização da forma, enquanto pequenos ruídos, visíveis na Figura A, não foram selecionados.	64
Figura 3.21 - Ilustração de parte de uma forma qualquer e dois de seus picos assinalados (1) e (2). Entre os picos há duas características relevantes: o contorno entre os picos $C_{1 \rightarrow 2}$ e a distância euclidiana entre os picos $p_{1 \rightarrow 2}$	65
Figura 3.22 - Determinação da dimensão fractal de uma forma pelo método "Salsicha de Minkowsky". a) Transformada distância de uma forma binária e b) Gráfico ($\log A \times \log d$).	67
Figura 3.23 - Obtenção do esqueleto da imagem binária pela determinação dos discos máximos. Os círculos A , B e C são diâmetros máximos, logo seus centros definem o esqueleto da imagem. Círculo D não define um ponto do esqueleto, pois toca a borda da figura em apenas 1 ponto.	68
Figura 3.24 - Obtenção do esqueleto da forma em duas diferentes situações. a) Esqueleto determinado da imagem original. b) Esqueleto determinado da mesma imagem após a suavização.	69
Figura 3.25 - Esquema ilustrando a projeção LDA (v_{LDA}) num espaço de atributos formado por χ_1 e χ_2 . A direção da projeção é ilustrada pelo vetor sobre a reta. Importante notar a redução de dimensionalidade realizada no processo, na qual os dados, antes discriminados no espaço bidimensional, agora pode ser discriminados no espaço unidimensional.	71
Figura 3.26 - a) Os atributos χ_A e χ_B definem as Classes 1 e 2, bem como um ponto desconhecido a ser classificado. b) As 5 menores distâncias ao ponto desconhecido são mostradas, das quais 4 pertencem à Classe 1 e apenas 1 pertence à Classe 2. Esse resultado classifica o ponto desconhecido como pertencente à Classe 2.	73
Figura 3.27 - Esquema geral da disposição de uma matriz de confusão. As classes dos grupos de treino estão dispostos em colunas e os respectivos testes de cada classes dispostos em linhas.	74
Figura 4.1 - Recorte manual da região da lesão à ser adicionada ao escopo das lesões. A imagem original possui dimensão (3648×2736) pixels, enquanto que o recorte da lesão possui dimensão de (463×343) pixels.	78
Figura 4.2 - Sequência de etapas do processo de segmentação: A) Imagem Original obtida de uma câmera digital comum à ser segmentada. B) Aumento de contraste de 50% realizado na imagem. C) Conversão para escala de cinza. D) Aplicação do filtro Gaussiano de $a = 2$. E) Binarização efetuada com o limiar obtido do processo de segmentação (para maiores detalhes ver 3.3). F) Imagem finalizada da forma, com todos os ruídos eliminados (buracos preenchidos, pequenos segmentos eliminados e etc).	80
Figura 4.3 - Imagens com segmentação insatisfatória.	81

Figura 4.4 - Suavização feita para três diferentes valores de sigma (σ_G).	83
Figura 4.5 - A partir de uma imagem binária obtida da etapa de segmentação, é definido seu contorno e são extraídos os picos de interesse. No curvograma, observamos que apenas picos mais relevantes, ou seja, aqueles acima do limiar (linha tracejada) foram escolhidos. Os picos escolhidos foram marcados no contorno da figura. A presente imagem, construída para fins ilustrativos, foi obtida para os valores de $n = 3$ e $\sigma_G = 200$	84
Figura 4.6 - Exemplo Controle: A partir do algoritmo para obtenção da figura 4.5, implementou-se o mesmo para uma figura padrão sem picos relevantes, afim de obter uma validação para o método de detecção de picos. Podemos observar que, apesar do cálculo da curvatura apresentar ruídos, nenhum pico foi detectado. Os parâmetros usados para este controle foram os mesmos da figura 4.5.	85
Figura 4.7 - Análise dos parâmetros globais σ e n . Os gráficos mostram os valores de porcentagem de acerto em função de σ para diversos valores de n respectivamente.	86
Figura 4.8 - Exemplos da obtenção dos picos do contorno com relação aos parâmetros (σ, n)	87
Figura 4.9 - Distribuição dos valores da métrica $\mathcal{M}_{22}$. O gráfico superior dispõe os valores obtidos através de todas as 143 imagens do estudo. O gráfico inferior esquerdo apresenta o histograma normalizado dos dados e à direita a densidade do histograma.	88
Figura 4.10 - Distribuição dos valores da métrica $\mathcal{M}_{42}$	89
Figura 4.11 - Distribuição dos valores da métrica $\mathcal{M}_{47}$	89
Figura 4.12 - Distribuição dos valores da métrica $\mathcal{M}_{11}$	90
Figura 4.13 - Distribuição dos valores da métrica $\mathcal{M}_{23}$	91
Figura 4.14 - LDA realizado para as três categorias de lesões.	92
Figura 4.15 - Projeção da transformação LDA realizada para as classes Melanoma e Não Melanoma).	95
Figura 4.16 - Imagem de uma lesão melanocítica com sua respectiva escala. A partir dessa fotografia, pode-se obter as reais dimensões da lesão.	97
Figura 4.17 - Distribuição dos valores de Área e Perímetro para as categoriais Melanoma, Nevo Regular e Nevo Atípico.	98
Figura 4.18 - Compilação da densidade de distribuição de valores entre as três categorias juntas.	99
Figura 4.19 - Compilação dos valores sensibilidade, especificidade, acurácia e precisão para banco de imagens completo (143 imagens) em comparação com as três validações para imagens com escala (96 imagens).	102

Figura 4.20 - Resultado da aplicação do teste clínico. A média dos resultados mostra que o sistema obteve a maior porcentagem de acerto, com 73,6%. Médicos especialistas obtiveram 61%, enquanto que os clínicos gerais obtiveram 50% de acerto.	103
Figura A.1 - Distribuição das Métricas ($\mathcal{M}_0 \rightarrow \mathcal{M}_5$)	119
Figura A.2 - Distribuição das Métricas ($\mathcal{M}_6 \rightarrow \mathcal{M}_{11}$)	120
Figura A.3 - Distribuição das Métricas ($\mathcal{M}_{12} \rightarrow \mathcal{M}_{17}$)	121
Figura A.4 - Distribuição das Métricas ($\mathcal{M}_{18} \rightarrow \mathcal{M}_{23}$)	122
Figura A.5 - Distribuição das Métricas ($\mathcal{M}_{24} \rightarrow \mathcal{M}_{29}$)	123
Figura A.6 - Distribuição das Métricas ($\mathcal{M}_{30} \rightarrow \mathcal{M}_{35}$)	124
Figura A.7 - Distribuição das Métricas ($\mathcal{M}_{36} \rightarrow \mathcal{M}_{41}$)	125
Figura A.8 - Distribuição das Métricas ($\mathcal{M}_{42} \rightarrow \mathcal{M}_{47}$)	126
Figura A.9 - Distribuição das Métricas ($\mathcal{M}_{48} \rightarrow \mathcal{M}_{51}$)	127

LISTA DE TABELAS

Tabela 2.1 - Prognóstico de cura de melanoma maligno em cada um de seus estágios	33
Tabela 3.1 - Sumário dos atributos utilizados no projeto. Tais descritores fazem referência a geometria das formas, bem como a assimetria e curvatura.	52
Tabela 3.2 - Terminologia utilizada para matriz de confusão no estudo de uma classe específica.	75
Tabela 4.1 - Origem do banco de dados do trabalho. Disposição das 143 imagens obtidas, sua origem e a quantidade de cada categoria de lesão.	78
Tabela 4.2 - Validação cruzada para as três categorias	93
Tabela 4.3 - Tabela contabilizando porcentagens de acertos e erros para a validação cruzada realizada com a base de dados de 143 imagens	94
Tabela 4.4 - Resultado da validação cruzada entre as classes.	95
Tabela 4.5 - Medidas da matriz de confusão especificada para a categoria "Melanoma".	96
Tabela 4.6 - Disposição da quantidade de imagens usada em cada validação	97
Tabela 4.7 - Validação cruzada realizada com a transformação LDA utilizando atributos de dimensão	100
Tabela 4.8 - Validação realizada com a transformação LDA utilizando todos os atributos — dimensão, assimetria e irregularidade de borda	100
Tabela 4.9 - Validação de comparação, feita com atributos de assimetria e irregularidade de borda	100
Tabela 4.10 - Resultado detalhado do teste clínico. Na tabela são especificados a quantidade de erros e acertos para as imagem presentes no teste.	104

LISTA DE SÍMBOLOS

$\mathcal{M}_i$	i-ésimo atributo
$\bar{\mathbf{a}}$	Média de $\mathbf{a}$
$\sigma_{\mathbf{a}}$	Desvio padrão de $\mathbf{a}$
$cv_{\mathbf{a}}$	Coeficiente de variação de $\mathbf{a}$
$med(\mathbf{a})$	Mediana de $\mathbf{a}$
σ_G	Parâmetro global de suavização da gaussiana
α	Parâmetro global do limiar de picos
k	Curvatura
Skl	Esqueleto

SUMÁRIO

1	Introdução	p. 23
1.1	Motivação	p. 23
1.2	Problematização	p. 27
1.3	Objetivos	p. 28
1.4	Organização do Trabalho	p. 28
2	Pele Humana e Melanoma	p. 31
2.1	Pele Humana	p. 31
2.2	Lesões Melanocíticas	p. 32
2.3	Regra do ABCD	p. 34
3	Processamento de Imagens.....	p. 37
3.1	Conceitos Básicos	p. 37
3.1.1	Histograma	p. 39
3.1.2	Limiarização	p. 41
3.2	Pré-Processamento	p. 42
3.2.1	Conversão RGB para Escala de Cinza	p. 42
3.2.2	Aumento de Contraste	p. 43
3.2.3	Filtragem no Domínio Espacial	p. 44
3.3	Segmentação por Histograma	p. 45
3.4	Operadores Morfológicos	p. 48
3.4.1	Filtragem de Ruídos	p. 48
3.5	Extração de Atributos	p. 51
3.5.1	Atributos de Forma	p. 52
3.5.2	Momento de Uma imagem	p. 56
3.5.3	Curvatura Multi-Escala	p. 58
3.5.4	Detecção de Picos	p. 63
3.5.5	Dimensão Fractal	p. 66

3.5.6	Esqueleto	p. 68
3.6	Classificação	p. 70
3.6.1	Linear Discriminant Analysis	p. 70
3.6.2	Algoritmo kNN	p. 72
3.6.3	Validação Cruzada	p. 73
4	Metodologia e Resultados	p. 77
4.1	Obtenção e Tratamento das Imagens	p. 77
4.2	Resultados da Segmentação	p. 79
4.3	Resultados dos Atributos	p. 81
4.3.1	Análise dos parâmetros σ_G e α	p. 82
4.3.2	Análise dos Atributos	p. 87
4.4	Resultados da Classificação	p. 91
4.4.1	Considerações sobre o diâmetro de uma lesão	p. 96
4.5	Avaliação de Desempenho	p. 102
5	Conclusões e Trabalhos Futuros	p. 107
	REFERÊNCIAS	p. 111
	Apêndice A – Distribuição dos valores das métricas	p. 117

1 Introdução

1.1 Motivação

O câncer de pele é o tipo de tumor de maior incidência entre a população mundial — cerca de 25% dos cânceres do corpo humano são de pele. (1) O câncer de pele é definido pelo crescimento anormal e descontrolado das células que compõem a pele (ver Capítulo 2).

Os cânceres de pele podem ser divididos em câncer de pele dos tipos melanoma e não melanoma. Os casos de melanoma representam cerca de 4% do total mundial de casos. Apesar de seu percentual relativamente baixo em comparação com os demais tipos, estima-se que em 2015, cerca de 395.000 novos casos serão registrados em todo Brasil. Segundo o Instituto Nacional de Câncer de Pele (INCA) (1), é incontestável que o câncer de pele é um problema de saúde pública no Brasil, devendo ser priorizados o controle e tratamento em todas as regiões do país. Sendo assim, em um país com cerca de 200 milhões de habitantes e de dimensões continentais como o Brasil, é imprescindível que haja divulgação a respeito dos perigos do melanoma, bem como os meios de tratamento e prevenção.

Apesar de seu alto grau de letalidade, o melanoma maligno apresenta bom prognóstico de cura quando diagnosticado em seu estágio inicial. O prognóstico de cura depende da profundidade da lesão através da derme. Logo, o diagnóstico e tratamento numa fase inicial da doença é essencial para a cura. (1–3) Diagnóstico precoce do câncer requer, dentre outros cuidados, um primeiro auto-exame feito pelo próprio paciente. A identificação de lesões suspeitas bem como conhecimento a respeito dos perigos do melanoma aceleram a busca por tratamento por parte do paciente. Para a realização de auto exames, existem ”métodos” que analisam as principais características dos melanomas malignos e auxiliam a detecção dos mesmos. Dentre eles destaca-se a Regra do ABCD. A regra do ABCD é um mnemônico para as principais carac-

terísticas presentes no melanoma maligno: **A** para assimetria, **B** para borda irregular, **C** para coloração variada e **D** para diâmetro maior do que 6 *mm*. (2, 4)

A ampliação da lesão pode revelar informações antes não observáveis à olho nu, facilitando seu diagnóstico. Nos últimos anos, pesquisas tem sido realizadas no desenvolvimento de equipamentos de diagnóstico de melanoma, facilitado sua triagem e obtendo resultados mais rapidamente do que pelo método histopatológico tradicional. (5, 6) Outra vantagem é que tais técnicas não são invasivas, o que no caso do melanoma é extremamente importante, visto que as biópsias necessárias são agressivas ao tecido.

Na década de 1950, foram introduzidos por Johann Saphier (7) os primeiros dermatoscópios. Tais ferramentas têm auxiliado dermatologistas a realizar a triagem de lesões melanocíticas de maneira mais precisa. (8) Dermatoscópios ampliam a imagem da lesão cerca de 20× à 70×, dependendo do equipamento. A partir desse nível de ampliação, é possível reconhecer estruturas particulares do melanoma, possibilitando sua identificação. (9) A figura 1.1 apresenta um dermatoscópio clínico utilizado em consultas médicas e triagens de lesões melanocíticas.

Figura 1.1 – Exemplo de um dermatoscópio clínico.

Fonte: DERMATOSCOPY(10)

Além dos dermatoscópios, técnicas de microscopia confocal também vem sendo aplicadas à triagem de lesões melanocíticas. (11) Os microscópios confocais possuem poder de ampliação de até 1000× e podem se tornar poderosas ferramentas na identificação precoce do melanoma,

visto que suas imagens permitem obter informações da patologia analisada em nível molecular.

Equipamentos de fluorescência óptica também vêm ampliando as perspectivas de diagnóstico precoce do melanoma e outras patologias. Tais equipamentos incidem diferentes comprimentos de onda sobre a pele, possibilitando a fluorescência da mesma. As imagens de fluorescência revelam informações que não eram perceptíveis. (12) A figura 1.2 mostra duas patologias distintas, inicialmente indistinguíveis a olho nu, mas com estruturas distintas sob efeito da fluorescência. (13) A figura da direita apresenta um melanoma maligno e a da esquerda uma queratose seborreica, onde é possível identificar estruturas puntiformes esbranquiçadas, característicos da enfermidade.

Figura 1.2 – Imagens de lesões melanocíticas distintas sob efeito da fluorescência óptica. a) Queratose seborreica e b) Melanoma maligno.

Fonte: PANFILO(13)

Apesar dos equipamentos citados acima permitirem a realização de diagnósticos mais precisos e ampliarem as possibilidades de tratamento, alguns fatores sociais impedem a disseminação do uso dessas tecnologias. Um desses fatores é o elevado custo de sua aquisição. Os dermatoscópios são os aparelhos mais acessíveis hoje e custam em torno de R\$ 2.000,00 reais. Porém, sabemos que há países com acentuada desigualdade social, baixa distribuição de renda e recursos, que impossibilita a aquisição destes aparelhos sofisticados. Além disso, o uso dessa tecnologia implica especialização e treinamento de pessoas qualificadas para seu manuseio, sendo mais um impedimento a sua utilização, visto que muitas vezes a simples presença de um dermatologista nessas regiões é impossibilitada. A figura 1.3 mostra a distribuição de unidades básicas de saúde, segundo razão médico para cada 1000 habitantes por Unidades da Federação

no Brasil em 2013. Segundo os dados fornecidos pela pesquisa médica demográfica brasileira de 2013, as regiões norte e nordeste brasileira apresentam os menores índices de médicos para cada 1000 habitantes.

Figura 1.3 – Distribuição de unidades básicas de saúde, segundo razão médico/habitante por Unidades da Federação — Brasil, 2013.

Fonte: SCHEFFER(14)

Tendo em vista esse cenário, cada vez mais tem-se buscado técnicas acessíveis para detecção de melanomas. Em decorrência da recente revolução computacional e a alta capacidade de processamento de dados que as máquinas oferecem, *softwares* vem auxiliando médicos e pesquisadores a criar aparelhos de detecção de melanoma. Estes *softwares*, através rotinas computacionais, fazem o processamento e a análise de fotografias obtidas diretamente da pele lesionada (ver Capítulo 2). A vantagem do uso de algoritmos em análise de imagem é a alta velocidade dos cálculos feitos pelas máquinas e a capacidade de identificar padrões presentes nas lesões que o olho humano não consegue. Além disso, uso de *softwares* permite a obtenção de resultados padronizados, reduzindo a subjetividade humana na análise.

A partir de técnicas consagradas na literatura, pesquisadores processam bancos de imagens de diversas patologias, extraindo métricas para o reconhecimento de padrões nas mesmas, a fim de classificá-las em grupos, realizando a distinção entre imagens melanomas e não melanomas. Desde a década de 1990, diversos grupos de pesquisa tem trabalhado com essa temática nas

mais diversas frentes. Em (15–17), métodos de análise referentes à coloração das imagens são utilizados na discriminação de melanomas malignos de outros tipos de lesões. Em (18, 19) os autores utilizam consagradas técnicas de processamento de imagens para obter métricas referentes à regra do ABCD, utilizando em seguida processos de redução de dimensionalidade e classificação de grupos. Métricas relacionadas à textura das imagens também tem sido alvo de muitos pesquisadores (20, 21). Outro ramo de destaque na área são os artigos e trabalhos relacionados com o processo de segmentação (19, 22–24) (ver Seção 3.3), na qual busca-se maior acurácia nas técnicas para se extrair apenas a região de interesse das imagens.

1.2 Problematização

Conforme apresentado na seção anterior, o câncer de pele do tipo melanoma tem sido nos últimos anos um problema de saúde pública no Brasil. Porém, os prognósticos de cura são altamente positivos quando identificado em sua fase inicial. Apesar de existirem atualmente equipamentos que fazem a ampliação das lesões suspeitas — tornando mais fácil sua identificação —, tais ferramentas ainda são dispendiosas para diversas regiões ao redor do mundo, que não possuem aporte financeiro para tal investimento. Outra situação que ocorre com frequência em centros de tratamento de câncer fora das grandes metrópoles é a assiduidade de especialistas. Nesses casos, enfermeiros treinados pelos médicos registram os casos suspeitos por fotografias para posterior exame do especialista.

Sendo assim, surge a necessidade de desenvolver um equipamento que faça a análise computacional de imagens clínicas de lesões melanocíticas. Tais imagens podem ser obtidas facilmente por toda população, através de câmeras digitais comuns ou mesmo *smartphones*. Além de auxiliar médicos não especialistas na triagem clínica de lesões melanocíticas suspeitas, esse equipamento pode também servir como um primeiro diagnóstico para a população em geral, auxiliando a identificação dos casos suspeitos de melanomas mais rapidamente, facilitando seu tratamento.

A regra do ABCD para imagens clínicas traz 4 fatores importantes de serem analisados ao

se julgar uma lesão suspeita. Para o presente trabalho, escolheu-se trabalhar com apenas duas de suas características: A assimetria das lesões e a irregularidade de borda (letras **A** e **B** do mnemônico). Escolheu-se essas características por dois fatores: primeiramente, é necessário que o sistema a ser desenvolvido seja robusto e não sofra variações de resultados por problemas de coloração que possam acontecer devido à falta de padronização luminosa ou dimensional na obtenção de imagens. Além disso, há na literatura uma grande quantidade de trabalhos relacionados a coloração e textura das lesões, ao passo que pouco constatou-se trabalhos com a temática da irregularidade de borda e assimetria das lesões.

1.3 Objetivos

O presente trabalho pretende analisar um conjunto de imagens de lesões melanocíticas via algoritmo computacional. Em suma, busca-se:

1. Fazer coleta de imagens em hospitais e centros de tratamento de câncer de pele no Brasil, criando assim um banco de dados de imagens.
2. Utilizar-se de técnicas consagradas de processamento e análise de imagens, que envolve a extração de medidas morfológicas das imagens e aplicação de técnicas de reconhecimento de padrões entre as categorias a serem estudadas.
3. Realizar interação com clínicos gerais e dermatologistas, a fim de validar todos os procedimentos realizados no projeto.

1.4 Organização do Trabalho

Inicialmente, abordaremos aspectos biológicos e clínicos sobre as lesões melanocíticas estudadas no presente trabalho e seus tópicos relacionados, como a regra do ABCD por exemplo. Em seguida, há uma explanação sobre os conceitos referentes às técnicas computacionais

utilizadas, referentes ao processamento e análise de imagens. Na sequência, apresentamos a metodologia de trabalho utilizada e os principais resultados obtidos. A seção de resultados foi dividida em três partes distintas a fim de obter melhor organização do capítulo. O último capítulo traz as conclusões finais do trabalho.

2 Pele Humana e Melanoma

2.1 Pele Humana

A pele é o órgão do corpo humano responsável por diversas funções vitais como regulação da temperatura corporal e proteção dos órgãos e aparelhos internos. A pele humana é composta essencialmente por duas camadas: a epiderme (camada superficial) e a derme (camada interna). Na epiderme existem os melanócitos, células responsáveis pela produção de melanina, que definem a coloração da pele. (25) Nos indivíduos de pele mais escura, os melanócitos produzem mais melanina, porém a quantidade de melanócitos é praticamente idêntica a todas colorações de pele.

Figura 2.1 – Esquema da pele humana. A figura é ampliada na junção entre a derme e a epiderme. Nessa região existem os melanócitos, responsáveis pela produção da substância de pigmentação da pele, a melanina.

Fonte: NATIONAL... (26)

2.2 Lesões Melanocíticas

Lesões melanocíticas são alterações na fisiologia da pele que induzem a proliferação dos melanócitos. (27) As lesões melanocíticas podem ser classificadas em dois grupos: lesões malignas (que definem o câncer de pele do tipo melanoma) e benignas, que incluem as lesões regulares (comuns) e atípicas. (28) Lesões melanocíticas benignas são comumente chamadas de pintas ou nevos e podem surgir de maneira adquirida, quando estão presentes desde o nascimento, ou congênita, quando aparecerem a partir dos dois anos de idade.

Figura 2.2 – Classificação de lesões melanocíticas quanto à sua origem.

Fonte: Elaborada pelo autor.

Outra importante classificação dos nevos melanocíticos é baseada na localização do mesmo na pele. (27, 28) Quando localizado na camada mais externa da pele (epiderme) os nevos são classificados como juncionais. Nessa situação, o nevo geralmente se apresenta sobressaliente na pele. Há possibilidade do ninho névico nascer na epiderme e migrar em parte para a derme (camada mais interna). Nesse caso, o nevo é classificado como composto. O nevo é dito intradérmico quando suas células migram integralmente para a derme. A figura 2.3 mostra uma representação da pele e as respectivas posições para cada tipo de classificação.

Alguns nevos melanocíticos apresentam atipias estruturais com relação aos nevos regulares. Essas lesões são comumente chamadas de Nevos Atípicos (a literatura também reporta o termo *Clark Nevi*). (30) Tais nevos são diferentes histologicamente das demais lesões melanocíticas. (31) Apesar de sua classificação benigna, há reconhecida associação entre os nevos atípicos e o aparecimento de melanoma maligno (32), ou seja, tais nevos podem tornar-se melanomas. Segundo (33), não existe um consenso quanto ao diagnóstico clínico do nevo atípico, e a classi-

Figura 2.3 – Classificação das lesões melanocíticas quanto a profundidade dos ninhos dos melanócitos. A figura (A) mostra uma pele saudável e em seguida (B), (C) e (D) representam as classes juncionais, compostos e intradermais.

Fonte: INTRO... (29)

ficação dessa patologia ainda é discutida entre os especialistas. Contudo, a presença de atípias torna possível a identificação dos mesmos. Nevos atípicos são maiores que os nevos regulares, além de possuírem borda irregular e mal definidas e também apresentarem coloração mista. (28)

Melanoma é a forma maligna das lesões melanocíticas devido seu potencial de metástase. O termo melanoma *in situ* refere-se ao estágio inicial do melanoma, quando o mesmo ainda está situado na epiderme. Nesse estágio, o prognóstico de cura é altamente positivo. Quanto mais avançado o estágio do melanoma, mais difícil seu tratamento. A literatura reporta quatro estágios fundamentais do melanoma, que fazem referência a profundidade da lesão através da pele. A figura 2.4 mostra esquematicamente os estágios de infiltração que o melanoma alcançar, desde a derme (estágio 0) até atingir a corrente sanguínea, acarretando a metástase (estágio IV). (34) A tabela 2.1 mostra os prognósticos de cura para cada estágio do melanoma. (35)

Tabela 2.1 – Prognóstico de cura de melanoma maligno em cada um de seus estágios

Estágios	Classificação	Prognóstico de cura
0	Melanoma <i>in situ</i>	99,9%
I	Melanoma Invasivo	85 – 95%
II	Alto risco	45 – 79%
III	Metástase Local	24 – 70%
IV	Metástase Distante	7 – 19%

Fonte: Elaborada pelo autor.

Figura 2.4 – Os cinco estágios do melanoma maligno. O primeiro estágio é conhecido por melanoma *in situ*, onde a lesão apenas atingiu a derme e o prognóstico de cura é o maior possível. Conforme o melanoma cresce internamente, os prognósticos de cura diminuem. No último estágio, a metástase, o melanoma atingiu a corrente sanguínea e se espalhou pelo corpo.

Fonte: MELANOMA(35)

2.3 Regra do ABCD

O melanoma diferencia-se das demais lesões benignas pela replicação constante de suas células. Esse é o fator responsável pela metástase do câncer pelo corpo. O melanoma geralmente se inicia por uma lesão plana (*in situ*) que com o tempo pode formar nódulos ou feridas. Toda lesão pré-existente que sofrer alguma alteração deve ser prontamente examinada por um médico dermatologista, visto que o mesmo pode surgir de lesões pré-existentes. A Regra do ABCD é um guia de análise de lesões suspeitas para identificação do melanoma. Seu nome remete as principais características a serem analisadas na lesão, que são:

- **Assimetria**

Melanomas tendem a exibir assimetria em sua forma. Pode-se facilmente identificar essa característica comparando duas partes distintas da lesão. A figura 2.5 ilustra a assimetria de uma lesão. É possível identificar estruturas bem diferentes em partes distintas da lesão.

- **Borda irregular**

Os melanomas apresentam irregularidades nas bordas, com curvas suaves e abruptas.

Figura 2.5 – Melanoma assimétrico

Fonte: NATIONAL... (36)

Além disso, possuem final abrupto da pigmentação, como ilustra a figura 2.6.

Figura 2.6 – Melanoma com borda irregular

Fonte: NATIONAL... (37)

- **Coloração diferenciada**

Nos melanomas, predominam as cores escuras e/ou a presença de várias cores em uma mesma lesão (preto, marrom claro, marrom escuro, cinza-azulado, vermelho e branco), conforme a figura 3.5.

Figura 2.7 – Melanoma com cores diferentes

Fonte: NATIONAL... (38)

- **Diâmetro maior que 6 mm**

O crescimento rápido é uma das principais características do melanoma, o que leva a lesões de diâmetros maiores em relação a outras lesões. Como regra diâmetros maiores que 6 milímetros levam a uma suspeita maior de lesão maligna. A figura 2.6 ilustra esta característica.

Figura 2.8 – Melanoma com diâmetro alterado

Fonte: NATIONAL... (39)

3 Processamento de Imagens

O processamento e análise de imagens é uma área da computação com aplicação em praticamente todas as áreas do conhecimento humano que envolva trabalho com imagens. As técnicas de processamento e análise de imagem envolvem toda e qualquer modificação aplicada à imagem a fim de se obter características significantes da mesma, ou de um conjunto de imagens semelhantes ou pertencentes à mesma categoria, a ponto de possibilitar uma classificação adequada da mesma com relação a demais. O processamento de imagens digitais envolve procedimentos normalmente expressos sob forma algorítmica, o que nos leva à necessidade de implementação de rotinas computacionais via software. (40)

As etapas do processamento e análise de imagens podem ser diferentes para cada finalidade. Na presente dissertação, convém diferenciar as etapas de processamento na seguinte ordem: pré-processamento, segmentação, extração de atributos, classificação e validação. A seguir, abordaremos os principais conceitos utilizados no trabalho referentes a processamento de imagens.

3.1 Conceitos Básicos

A interpretação computacional de uma imagem digital, seja ela uma imagem colorida ou em níveis de cinza — também chamada de imagem *grayscale* — se dá através da quantização do domínio espacial da imagem em *pixels*. Pode-se entender o *pixel* como sendo o elemento fundamental de uma imagem digital. No processo de quantização, determinam-se os *pixels* a partir da resolução da imagem digital — quanto maior a resolução, maior a quantidade de *pixels*. Costuma-se associar aos *pixels* valores entre 0 – 255 e são localizados em determinada posição na imagem. (41) É comum utilizar o sistema de coordenadas apresentado como na figura 3.1

onde a imagem é representado como $f(i, j)$, na qual i é a posição horizontal do *pixel* e j é a posição vertical do mesmo. Por exemplo, para a figura 3.1, temos $f(2, 3) = 22$, ou seja, o valor do *pixel* da coluna 2 com a linha 3 possui valor 22. Já na figura 3.2, apresentamos o processo de quantização de uma imagem digital.

Figura 3.1 – Representação computacional de uma imagem digital. Nessa representação, y representa as linhas da imagem digital, enquanto x representa as colunas.

	0	1	2	3	j
0	10	20	12	23	
1	17	100	25	95	
2	9	17	8	22	
3	16	89	19	92	
i					

Fonte: MOESLUND(41)

Figura 3.2 – Processo de quantização de imagem digital. a) a imagem contínua a ser quantizada e a posição de seus *pixels*, na qual será feita a quantização, b) a imagem quantizada, com cada um dos *pixels* preenchidos com seu valor adequado.

Fonte: MOESLUND(41)

Imagens em escala de cinza possuem apenas uma dimensão para seus *pixels*. Em processamento de imagens, o espaço que contém as posições dos *pixels*, bem como seu respectivo valor (representando determinada tonalidade) são chamados de canais. Sendo assim, enquanto imagens *grayscale* possuem apenas um canal, imagens coloridas possuem três canais de cores, cada qual referente às cores primárias vermelho, verde e azul. Popularmente, imagens digitais coloridas são conhecidas por imagens RGB — sigla para a escrita das cores no idioma inglês.

Figura 3.3 – Os efeitos da resolução espacial. Resoluções de 256×256 , 64×64 e 16×16 *pixels*.

Fonte: MOESLUND(41)

As Figuras 3.4 e 3.5 exemplificam imagens em escala de cinza e RGB respectivamente, bem como seus canais e os valores de *pixels*.

Figura 3.4 – Imagem em escala de cinza. Pode-se observar a região selecionada e os valores de cada um de seus *pixels*.

Fonte: MCANDREW(42)

3.1.1 Histograma

O histograma de uma imagem em escala de cinza é um gráfico de frequência relativa de ocorrência de cada valor de *pixel*. Pode-se construir seu histograma apenas contabilizando os *pixels* que possuem mesmo valor. Importante salientar que o histograma não leva em conta a posição dos *pixels*, simplesmente sua distribuição. A figura 3.6 exemplifica a obtenção de um histograma a partir de uma imagem em escala de cinza. (43)

Importante notar que as tonalidades escuras da imagem denotam valores baixos da escala

Figura 3.5 – Imagem RGB e seus respectivos canais vermelho, verde e azul

Fonte: MCANDREW(42)

Figura 3.6 – Obtenção de um histograma a partir de uma imagem em escala de cinza. a) Imagem em escala de cinza e b) seu respectivo histograma.

Fonte: Elaborada pelo autor.

de cinza, bem como tonalidades claras representam os valores altos da escala de cinza. Devido ao fato do histograma fazer a contabilidade dos *pixels*, a informação da localização dos mesmos é perdida, isso significa que *pixels* de mesmo valor serão computados igualmente, independente de pertencerem ou não ao mesmo objeto na imagem.

3.1.2 Limiarização

Já a limiarização é uma técnica de segmentação de imagens baseado na diferença dos níveis de cinza dos objetos que compõe uma imagem. A partir de um limiar estabelecido, geralmente referente às características do objeto que se deseja isolar, é possível distingui-lo do restante da imagem. O algoritmo da limiarização simplesmente divide a imagem em dois grupos: o grupo de *pixels* com níveis de cinza abaixo do valor limiar e o grupo de *pixels* com níveis de cinza acima do valor limiar. Em uma imagem limiarizada, atribui-se um valor fixo para todos os *pixels* de mesmo grupo. Portanto, a partir de uma imagem em escala de cinza e um limiar T , define-se uma imagem $L(i, j)$ limiarizada por:

$$L(i, j) = \begin{cases} 255, & \text{if } I(i, j) \geq T \\ 0, & \text{if } I(i, j) < T \end{cases}$$

onde $L(i, j)$ é o valor do *pixel* referente à imagem binária L na posição (i, j) . O resultado da limiarização é uma imagem binária. A figura 3.7 mostra o exemplo de aplicação da limiarização.

Figura 3.7 – Resultado da limiarização de uma imagem em escala de cinza. a) Imagem em escala de cinza e b) Resultado para o limiar de 150 da escala de cinza.

Fonte: Elaborada pelo autor.

Feita essa primeira abordagem inicial sobre imagens digitais, sua representação e algumas técnicas básicas, discutiremos a seguir as etapas do processamento de imagens realizadas no trabalho.

3.2 Pré-Processamento

As técnicas de processamento e análise de imagens são, em geral, aplicadas a um banco de dados, ou seja, um conjunto de imagens o qual se deseja estudar e analisar. O problema é que muitas vezes não há adequada padronização entre as imagens, o que acarreta resultados que diferem da realidade do problema. Sendo assim, dado um determinado conjunto de imagens, é necessário tratá-las adequadamente para melhorar a qualidade do processamento. Essa primeira modificação aplicada às imagens do estudo é conhecida por Pré-Processamento. O Pré-Processamento é um procedimento fundamental da análise de imagens. Há na literatura uma infinidade de técnicas de processamentos prévios, tais como aplicação de filtros extratores de ruídos, filtros de suavização, técnicas de realce de imagens (como aumento de contraste e equalização por histograma), dentre outros. A seguir especificamos as técnicas de pré-processamento utilizadas no presente trabalho.

3.2.1 Conversão RGB para Escala de Cinza

Conforme descrito na sessão inicial do presente capítulo, imagens digitais RGB são compostas por *pixels*, sendo que sua cor é formada da combinação das cores primárias vermelha, verde e azul e imagens são compostas por um único canal, cujos valores, igualmente para os canais de imagens coloridas, variam de 0 a 255. É possível obter-se uma imagem *grayscale* a partir de uma imagem RGB através de operações matemáticas entre os três canais de cores, resultando em um único canal. Existem diversos métodos de transformações de uma imagem RGB para escala de cinza, que podem levar em conta a luminosidade presente na imagem, o contraste, e outros fatores. (44) A transformação mais comumente utilizada faz uma mescla uniforme dos três canais de cores. Pode-se definir a transformação por:

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

onde Gr é o valor inteiro aproximado da transformação de cada *pixel* referente à escala de cinza, e R , G e B são os valores dos *pixels* para os canais vermelho, verde e azul respectivamente. A figura 3.8 ilustra a obtenção de uma imagem escala de cinza a partir da transformação utilizada.

Figura 3.8 – A) Exemplo de uma imagem RGB e B) sua respectiva conversão para escala de cinza (*grayscale*).

Fonte: Elaborada pelo autor.

3.2.2 Aumento de Contraste

Em tratamento e análise de imagens, é comum obter-se imagens com baixo contraste, principalmente em situações que envolvem iluminação não uniforme ou de baixa intensidade. Imagens com baixo contraste possuem valores de *pixels* muito próximos, varrendo uma pequena faixa do espectro. Pode-se então, obter um aumento no contraste de uma figura fazendo o "alargamento" — do inglês *stretch* — do seu histograma. (43, 45) Inicialmente define-se os valores extremos de *pixel* $h_{\min}$ e $h_{\max}$ contidos na figura. Para fazer o alargamento por todo espectro de cinza, de 0 à 255, aplica-se a seguinte operação:

$$I_{\text{saída}}(i, j) = \frac{I_{\text{entrada}}(i, j) - h_{\min}}{h_{\max} - h_{\min}} \times 255$$

onde a localização de cada *pixel* é dada por (i, j) , $I_{\text{saída}}$ é a imagem com contraste aumentado e I_{entrada} é a imagem original. A figura 3.9 trás o exemplo de uma imagem de baixo contraste e seu respectivo alargamento por histograma.

Figura 3.9 – Exemplo de aumento de contraste por alargamento do histograma. a) Imagem original de baixo contraste. b) Histograma da imagem original. c) Resultado da aplicação do aumento de contraste por alargamento. d) Histograma da imagem realçada.

Fonte: JÄHNE(45)

3.2.3 Filtragem no Domínio Espacial

Por vezes, imagens obtidas sem a correta padronização podem ser obtidas com algumas imperfeições, ou mesmo componentes indesejáveis como reflexos e manchas, que interferem na análise correta da imagem. Além disso, por diversas vezes há necessidade de se realçar certos aspectos de uma imagem a fim processá-la da forma mais eficiente possível. Nesse contexto apresentamos a Filtragem no Domínio Espacial, que se refere à obtenção de novas imagens filtradas — ou seja, eliminam-se determinados aspectos da mesma — a partir da manipulação direta dos *pixels* da imagem original. A obtenção da imagem filtrada é feita através da convolução entre a imagem original e seu filtro. A expressão da convolução é definida por

$$g_f(i, j) = g(i, j) * h(i, j)$$

onde $g_f(i, j)$ é a imagem filtrada, $g(i, j)$ é a imagem original e $h(i, j)$ é o filtro. A operação da convolução consiste em três operações básicas: deslocar o filtro, multiplicar seu valor pelo correspondente *pixel* da imagem e efetuar o somatório destas multiplicações. Para um filtro de tamanho $M \times M$, a convolução é dada por

$$g_f(i, j) = \sum_{x=-\frac{M}{2}}^{\frac{M}{2}} \sum_{y=-\frac{M}{2}}^{\frac{M}{2}} h(x, y) f(i - x, j - y)$$

Para maiores detalhes da filtragem de imagens, consultar. (40, 43, 46)

Filtro Gaussiano

A aplicação do Filtro Gaussiano é um artifício amplamente utilizado em processamento de imagens. Tal procedimento é importante nos estágios iniciais do processamento pois o mesmo ajuda a homogeneizar a imagem, fazendo uma eliminação de ruídos e imperfeições da mesma, facilitando as próximas etapas da análise. O Filtro Gaussiano, previamente elaborado a partir da função Gaussiana, faz uma média ponderada entre os *pixels* da imagem e a sua máscara. O resultado da aplicação do Filtro Gaussiano é uma imagem suavizada (ver Figura 3.10). A função Gaussiana é dada por:

$$G(x, y) = \frac{1}{\sqrt{2\pi}a} \exp\left(\frac{-d^2}{2a^2}\right)$$

onde $d = \sqrt{x^2 + y^2}$ sendo que x e y são as posições dos *pixels* da imagem e a é o desvio padrão da gaussiana no domínio espacial. O desvio padrão a da Gaussiana determina o alargamento da mesma, isso implica que quanto maior o valor de a , maior será a suavização da imagem. A figura a seguir mostra um exemplo da aplicação da filtragem gaussiana em uma imagem e as diferentes saídas em função dos valores de a .

3.3 Segmentação por Histograma

O processo de segmentação de uma imagem consiste em separar a região de interesse a ser estudada do restante da imagem. Quando se faz a segmentação da imagem de algum objeto

Figura 3.10 – As figuras de (A – C) mostram o resultado da aplicação do filtro gaussiano aplicados a uma mesma imagem *grayscale* para os respectivos valores de desvio padrão $a = 2$, $a = 3$ e $a = 5$. Nota-se que para valores altos, a suavização da imagem torna-se intensa.

Fonte: Elaborada pelo autor.

para estudá-la posteriormente, geralmente dois aspectos são pretendidos: tornar o processamento mais eficiente, evitando a análise de regiões sem interesse (redundância) e avaliar as propriedades dos contornos do objeto segmentado. (47) Tendo isso em mente, faz-se necessário buscar técnicas que sejam eficientes para cada tipo de problema, que dependerá do tipo de imagem trabalhada. Além disso, a segmentação deve ser feita de maneira automatizada pelo algoritmo, que garantirá um resultado padronizado, reduzindo assim a necessidade de análise subjetiva humana, gerando maior confiabilidade na classificação final.

Ao analisar o histograma de uma lesão melanocítica, observa-se um padrão bem definido para essa classe de imagens. Este padrão é formado por dois picos — que serão chamados de máximos locais — e um vale — que será designado por mínimo local. Este padrão de histograma é chamado de bi-modal. Os dois picos observados no histograma fazem referência a duas regiões claramente distintas da imagem, sendo o primeiro pico referente aos *pixels* pertencentes à lesão melanocítica e o segundo pico referente à pele saudável. Já o mínimo local observado no histograma, refere-se à intersecção das duas regiões. Esse mínimo local corresponde, de fato, ao local onde os *pixels* modificam sua coloração, deixando de ser pele saudável e tornando-se lesão. Sendo assim, pode-se obter um resultado razoável para segmentação da região de interesse (em nosso caso, a região correspondente às lesões melanocíticas) das imagens aplicando-se a limiarização, onde o valor do *pixel* correspondente ao mínimo local será utilizado como limiar.

Figura 3.11 – Histograma de uma imagem de lesão melanocítica. Os pontos (1) e (2) destacados na figura são os máximos locais referentes à pele e a lesão. O ponto (3) destacado refere-se a intersecção das duas regiões. O valor deste *pixels* é usado na limiarização.

Figura 3.12 – Resultado da aplicação da limiarização.

A figura 3.11 traz uma representação do funcionamento do algoritmo de segmentação. Os pontos (1) e (2) identificados são máximos locais, enquanto que o ponto (3) é um mínimo local. Ao identificar o mínimo local presente entre os dois máximos locais, assume-se esse valor da escala de cinza como o valor limiar e aplica-se o processo de limiarização. A figura 3.12 apresenta o resultado da limiarização da figura 3.10 (A) com o valor limiar obtido na figura 3.11.

Após essa etapa, é comum a imagem final apresentar falhas (ou ruídos) em sua estrutura.

Tais falhas podem interferir negativamente no processo de obtenção dos atributos. Portanto, apresentamos a seguir os métodos necessários para eliminar tais imperfeições da imagem segmentada.

3.4 Operadores Morfológicos

A morfologia matemática é um ramo do processamento de imagens que analisa a estrutura geométrica dos conjuntos de *pixels* presentes numa forma. Tal ferramenta é útil em problemas de segmentação, filtragem de ruídos, detecção e composição de formas dentre outros. (46, 48, 49)

A aplicação de operadores morfológicos (OMs) baseia-se na relação entre a imagem em estudo e um elemento estruturante (ES). Um elemento estruturante é um conjunto de *pixels* usado para identificar formas específicas no objeto. Se houver coincidência entre o ES e a forma uma transformação é realizada ou não, dependendo do OM. Na aplicação de um OM, basicamente varre-se o ES por toda imagem, marcando onde há ou não coincidência do mesmo de acordo com o propósito do operador.

Seja X uma imagem binária a ser analisada e B um elemento estruturante baseado na forma da imagem contida em X . Ao elemento estruturante B associamos um *pixel*-origem, representando a posição de referência para o resultado da aplicação do operador morfológico. A figura 3.13 mostra exemplos de elementos estruturantes de dimensão 3×3 , nas quais o *pixel*-origem está marcado.

3.4.1 Filtragem de Ruídos

O derradeiro processo da segmentação é a eliminação dos ruídos, que nesta etapa consiste em eliminar falhas de preenchimento e/ou pequenos grupos de *pixels* isolados da forma principal. Há necessidade de eliminar tais imperfeições para evitar que a extração de atributos leve

Figura 3.13 – Exemplos de elementos estruturantes numa vizinhança 3×3 . Ambos ES possuem no centro seu *pixel*-origem diferenciado. a) Elemento estruturante 4 – *conexo*. b) Elemento estruturante 8 – *conexo*.

Fonte: Elaborada pelo autor.

em conta ou calcule dados desses ruídos. O processo de eliminação de ruídos se dá através da utilização de dois operadores morfológicos: a **dilatação** e a **erosão**. A dilatação é útil para completar buracos dentro de uma forma, enquanto que a erosão atua eliminando pequenos objetos fora da forma. A dilatação de uma imagem binária X por um elemento estruturante B , definida por $X \oplus B$, é dada pela união de todos os pontos x de $\mathbb{R}^2$ tal que o elemento B centrado em x , chamado B_x , intercepta a imagem X em qualquer ponto. Assim:

$$X \oplus B = \{x \in \mathbb{R}^2, B_x \cap X \neq \emptyset\}$$

A figura 3.14 mostra um exemplo da aplicação do OM dilatação. O centro do ES escolhido é varrido por todos *pixels* da imagem e basta que um *pixel* do ES encontre a forma para o *pixels* central pertencer a forma na nova imagem, ou Imagem Dilatada, como no exemplo.

A erosão de X por B , definida por $X \ominus B$, é dada pelo conjunto de pontos x em $\mathbb{R}^2$, tal que B ao ser transladado para a posição x , chamado B_x , esteja completamente inserido no conjunto X . Assim:

$$X \ominus B = \{x \in \mathbb{R}^2, B_x \subset X\}$$

A figura 3.15 mostra um exemplo da aplicação do OM erosão. O centro do ES escolhido é varrido por todos *pixels* da imagem e são mantidos na forma aqueles que tenham ligantes da mesma forma que o ES, formando a Imagem Erodida.

Figura 3.14 – Dilatação de uma imagem binária. A Imagem Original foi dilatada por um elemento estruturante 4 – *conexo*. Os *pixels* diferenciados na Imagem Dilatada são acrescidos à forma.

Fonte: Elaborada pelo autor.

Figura 3.15 – Erosão de uma imagem binária. A Imagem Original sofreu erosão por um elemento estruturante 4 – *conexo*. Os *pixels* diferenciados na Imagem Erodida são retirados da forma.

Fonte: Elaborada pelo autor.

O resultado da aplicação dos OM para dilatação e erosão, como forma de eliminação de ruídos, é apresentado na figura 3.16

Figura 3.16 – Resultado da aplicação dos Operadores Morfológicos. a) Imagem ruidosa, com buracos internos e regiões desconectas da imagem principal. b) Eliminação dos ruídos obtida por erosão e dilatação.

Fonte: Elaborada pelo autor.

O capítulo seguinte tratará da aplicação de todos conceitos discutidos na extração dos atributos de cada uma das imagens utilizadas no projeto, a fim de classificá-las posteriormente.

3.5 Extração de Atributos

Antes de explorarmos os detalhes da obtenção dos atributos de cada imagem, cabe uma discussão sobre a eleição das mesmas. Conforme visto no Capítulo 2, o melanoma maligno possui reprodução constante de suas moléculas, produzindo algumas características que o diferenciam de outras lesões benignas. Tais características são reunidas na regra do ABCD (ver Capítulo 2). A escolha de quais características seriam utilizadas no trabalho ocorreu por observação e comparação de seus valores. Foram testadas diversos atributos, que se julgou serem eficazes para o trabalho. Feito isso, verificou-se que as informações presentes no contorno das lesões eram as mais adequadas.

A seguir apresentamos o conjunto de atributos utilizados no trabalho bem como o procedimento para sua obtenção a partir das imagens segmentadas. Foram 52 atributos obtidos do contorno das lesões, que fazem referência à assimetria e à irregularidade da borda. Para um sequenciamento lógico ao longo da dissertação, os atributos calculados serão representados pelo

símbolo $\mathcal{M}$. A tabela abaixo agrupa os atributos em classes.

Tabela 3.1 – Sumário dos atributos utilizados no projeto. Tais descritores fazem referência a geometria das formas, bem como a assimetria e curvatura.

$\mathcal{M}_i$	Descrição
$\mathcal{M}_0$	Razão entre altura e largura do <i>Bouding Box</i>
$\mathcal{M}_1$	Razão entre Área do <i>Bouding Box</i> pela Área total
$\mathcal{M}_2$	Razão entre Área do <i>Convex Hull</i> pela Área total
$\mathcal{M}_3$	Elongação da forma
$\mathcal{M}_4$	Razão entre o Eixo maior e o Perímetro
$\mathcal{M}_5$	Simetria em relação ao eixo x
$\mathcal{M}_6$	Simetria em relação ao eixo y
$\mathcal{M}_7$	Simétricos por Assimétricos em x
$\mathcal{M}_8$	Simétricos por Assimétricos em y
$\mathcal{M}_9$	Razão entre quadrado do Perímetro e Área total
$\mathcal{M}_{10 \rightarrow 16}$	<i>Hu Moments</i>
$\mathcal{M}_{17 \rightarrow 27}$	Histograma da Curvatura
$\mathcal{M}_{28 \rightarrow 30}$	Média, Desvio Padrão e Coeficiente de Variação da Distância Euclidiana dos picos
$\mathcal{M}_{31 \rightarrow 33}$	Média, Desvio Padrão e Coeficiente de Variação da Distância Perimetral dos picos
$\mathcal{M}_{34 \rightarrow 36}$	Média, Desvio Padrão e Coeficiente de Variação da Razão das Distâncias Perimetrais e Euclidianas dos picos
$\mathcal{M}_{37 \rightarrow 39}$	Média, Desvio Padrão e Coeficiente de Variação dos Valores dos picos
$\mathcal{M}_{40}$	Quantidade de picos
$\mathcal{M}_{41 \rightarrow 43}$	Média, Desvio Padrão e Coeficiente de Variação da Curvatura
$\mathcal{M}_{44}$	Mediana da Curvatura
$\mathcal{M}_{45}$	Entropia do Contorno
$\mathcal{M}_{46}$	Energia Normalizada do Contorno
$\mathcal{M}_{47}$	Dimensão Fractal
$\mathcal{M}_{48}$	Número de Ramos do Esqueleto
$\mathcal{M}_{49 \rightarrow 51}$	Média, Desvio Padrão e Coeficiente de Variação dos Ramos do Esqueleto

Fonte: Elaborada pelo autor.

3.5.1 Atributos de Forma

Caracterizar um objeto, ou uma forma, requer analisar os principais atributos referentes ao mesmo e identificar quais características são úteis na diferenciação entre diferentes formas. Passaremos a detalhar nessa sessão, um conjunto de atributos obtidos a partir de uma imagem binária, referentes a sua forma. Tais atributos são importantes na caracterização das imagens e foram utilizadas no trabalho.

Bounding Box e Convex Hull

O *Bounding Box* (*BB*) é o enquadramento da imagem binária em um retângulo de área mínima. É importante que as imagens cujo *BB* será calculado tenham a mesma orientação, pois diferentes orientações implicam em diferentes enquadramentos, logo, diferentes valores para o *BB*. Para evitar esse problema, antes da determinação da área mínima, foi feita a rotação em relação ao centro de massa de todas as imagens analisadas, a fim de que as mesmas alinhem seus maiores eixos igualmente. Esse procedimento garante que o *bounding box* será invariante da rotação da lesão. (50) A figura 3.17 ilustra a rotação de uma imagem binária — e por consequência sua validação, pois seu Eixo Principal está alinhado corretamente.

O *Convex Hull* (*CH*) é similar ao *bounding box*, porém, o enquadramento da imagem é feito pelo polígono de área mínima. Nesse caso não há necessidade de alinhamento das imagens, pois o *CH* enquadra a mínima área, independente de rotação. A figura 3.18 ilustra a obtenção do *convex hull* e do *bounding box* em uma imagem binária.

Figura 3.17 – A) Exemplo de uma imagem binária e a obtenção de seus eixos principais e B) sua respectiva rotação. Nota-se o alinhamento dos eixos principais, indicando a correta orientação.

Fonte: Elaborada pelo autor.

Os atributos utilizados referentes a essa sessão foram:

$$\mathcal{M}_0 = \text{Aspect Ratio} = \frac{w}{d}$$

$$\mathcal{M}_1 = \text{Extend} = \frac{w \cdot d}{A}$$

$$\mathcal{M}_2 = \text{Solidity} = \frac{A_{Hull}}{A}$$

Figura 3.18 – A) Extração do *bounding box* e B) *convex hull*.

Fonte: Elaborada pelo autor.

$$\mathcal{M}_9 = \frac{P^2}{A}$$

onde w e d são respectivamente a altura e o largura do BB , A_{Hull} corresponde a área do CH e A e P são respectivamente Área e Perímetro das formas.

Eixos Principais

Os eixos principais são importantes descritores para a diferenciação de uma imagem binária. Tais eixos fazem referência à duas importantes características da forma: a alongação do objeto, a qual definiremos a seguir, e a sua orientação, que será importante no cálculo da simetria da forma (ver 3.5.1). Basicamente são definidos dois eixos principais em uma forma bidimensional: o eixo maior, que inicia-se no centro de massa e se orienta ao longo da maior dispersão de *pixels* da imagem; e o eixo menor, que igualmente inicia-se no centro de massa e é perpendicular ao eixo maior, também fazendo referência à dispersão dos *pixels*. Os eixos principais são proporcionais aos **autovalores** e **autovetores** da matriz formada pelos pontos referentes à borda da imagem. (46) A figura 3.17 ilustra a disposição dos eixos principais de uma imagem binária. Os atributos referentes aos eixos principais são os seguintes:

- **Elongação**

A alongação (e) de uma forma é definida como a razão entre o módulo do eixo maior (E_{Maior}) pelo módulo do eixo menor (E_{Menor})

$$\mathcal{M}_3 = e = \frac{E_{Maior}}{E_{Menor}}$$

- **Razão de Elongação**

Outro importante atributo é definido razão do módulo do eixo maior (E_{Maior}) pelo perímetro (P) da imagem.

$$\mathcal{M}_4 = R = \frac{E_{Maior}}{P}$$

Simetria

Analisar a simetria de uma imagem binária é quantificar a coincidência de posições no espelhamento de um dos lados da forma em relação ao outro lado. O eixo maior da imagem é utilizado para definir os dois lados. Ao fazer o espelhamento de um lado sobre outro, haverá pontos que coincidirão com outros pontos — os quais são designados por **simétricos** (N_{Simet}) — o pontos que não coincidirão — designados por **assimétricos** ($N_{Assimet}$). Se a maioria dos pontos de uma região coincidir com pontos da outra região, a figura é altamente simétrica. Em contrapartida, se muitos pontos espelhados não coincidirem com pontos do outro lado, terá características assimétricas. Uma maneira de quantificar a simetria é comparando os pontos simétricos com relação a área total da forma. Quatro atributos são propostos em relação à essas características, calculadas pelo espelhamento do eixo x e y respectivamente:

$$\mathcal{M}_5 = \text{Simetria em X} = \frac{N_{Simet}^x}{A}$$

$$\mathcal{M}_6 = \text{Simetria em Y} = \frac{N_{Simet}^y}{A}$$

$$\mathcal{M}_7 = \text{Simetria 2 em X} = \frac{N_{Simet}^x}{N_{Assimet}^x}$$

$$\mathcal{M}_8 = \text{Simetria 2 em Y} = \frac{N_{Simet}^y}{N_{Assimet}^y}$$

Onde (N_{Simet}) corresponde ao número de pontos coincidentes, ou simétricos e A é a área da imagem binária — definida na sessão 3.5.2.

3.5.2 Momento de Uma imagem

O momento central e o momento espacial de uma imagem são propriedades estatísticas importantes que fazem referência à geometria da forma. (51, 52) Os momentos da imagem são obtidos através de médias ponderadas da intensidades dos *pixels* da imagem em relação às posições de cada *pixel*. Sendo $I(x,y)$ o valor de um *pixel* de uma imagem binária na posição (x,y) , o momento espacial M_{pq} de ordem $(p+q)$ é definido por:

$$M_{pq} = \sum_x \sum_y x^p y^q I(x,y)$$

A partir dos momentos espaciais, é possível extrair algumas características da imagem binária, tais como:

- **Área** A área de uma imagem binária representa a soma de todos os *pixels* referentes ao objeto de estudo.

$$M_{00}$$

- **Centro de Massa** O Centro de massa de uma imagem binária representa local geométrico de equilíbrio do objeto.

$$\{\bar{x}, \bar{y}\} = \left\{ \frac{M_{10}}{M_{00}}, \frac{M_{01}}{M_{00}} \right\}$$

Já o momento central é definido como:

$$\mu_{pq} = \sum_x \sum_y (x - \bar{x})^p (y - \bar{y})^q I(x,y)$$

onde $\bar{x}$ e $\bar{y}$ são as posições do centroide — ou centro de massa, conforme definido acima — da imagem. A partir do momento central, pode-se extrair propriedades importantes da imagem, tais como:

- **Matriz de Covariância**

A matriz de covariância de uma imagem traz informações a respeito da orientação e da disposição dos *pixels* da mesma. (53) É possível obter a matriz de covariância da imagem

binária a partir dos momentos centrais de primeira e segunda ordens.

$$\mu'_{20} = \frac{\mu_{20}}{\mu_{00}}$$

$$\mu'_{02} = \frac{\mu_{02}}{\mu_{00}}$$

$$\mu'_{11} = \frac{\mu_{11}}{\mu_{00}}$$

Logo, a matriz de covariância é definida por:

$$\text{cov}[I(x,y)] = \begin{bmatrix} \mu'_{20} & \mu'_{11} \\ \mu'_{11} & \mu'_{02} \end{bmatrix}$$

A partir da matriz da covariância $A_{n \times n}$, define-se os autovalores e autovetores da mesma a partir de uma transformação linear realizada a matriz de tal maneira que:

$$A_{n \times n} \mathbf{x} = \lambda \mathbf{x}$$

que também pode ser escrita por

$$A_{n \times n} \mathbf{x} = (\lambda I_n) \mathbf{x}$$

onde I_n é a matriz identidade, $\mathbf{x}$ são os autovetores e λ são os autovalores. A determinação dos autovalores λ_i é dado a partir da solução da equação

$$\det(\lambda I_n - A_{n \times n}) \mathbf{x} = 0$$

Para cada autovalor λ calculado, determinam-se os autovetores a partir da solução não trivial da equação

$$(\lambda I_n - A_{n \times n}) \mathbf{x} = 0$$

Esses são os autovetores de A associados ao autovalor λ .

- **Momentos invariantes de Rotação**

Momentos que são invariantes de translação, mudança de escala e rotação são comumente conhecidos como *Hu Moments*. (53) É possível calcular esses momentos em até n ordens,

dependendo da ordem dos momentos centrais calculados. A seguir detalhamos o cálculo de sete *Hu Moments* devido à 3º ordem dos momentos centrais. Estes atributos serão utilizados nos resultados da dissertação, os quais referenciaremos por $\mathcal{M}_{10-16}$:

$$\mathcal{M}_{10} = \mu_{20} + \mu_{02}$$

$$\mathcal{M}_{11} = (\mu_{20} - \mu_{02})^2 + 4\mu_{11}^2$$

$$\mathcal{M}_{12} = (\mu_{30} - 3\mu_{12})^2 + (3\mu_{21} - \mu_{03})^2$$

$$\mathcal{M}_{13} = (\mu_{30} + \mu_{12})^2 + (\mu_{21} + \mu_{03})^2$$

$$\begin{aligned} \mathcal{M}_{14} = & (\mu_{30} - 3\mu_{12})(\mu_{30} + \mu_{12})[(\mu_{30} + \mu_{12})^2 - 3(\mu_{21} + \mu_{03})^2] + \\ & (3\mu_{21} - \mu_{03})(\mu_{21} + \mu_{03})[3(\mu_{30} + \mu_{12})^2 - (\mu_{21} + \mu_{03})^2] \end{aligned}$$

$$\mathcal{M}_{15} = (\mu_{20} - \mu_{02})[(\mu_{30} + \mu_{12})^2 - (\mu_{21} + \mu_{03})^2] + 4\mu_{11}(\mu_{30} + \mu_{12})(\mu_{21} + \mu_{03})$$

$$\begin{aligned} \mathcal{M}_{16} = & (3\mu_{21} - \mu_{03})(\mu_{30} + \mu_{12})[(\mu_{30} + \mu_{12})^2 - 3(\mu_{21} + \mu_{03})^2] - \\ & (\mu_{30} - 3\mu_{12})(\mu_{21} + \mu_{03})[3(\mu_{30} + \mu_{12})^2 - (\mu_{21} + \mu_{03})^2] \end{aligned}$$

3.5.3 Curvatura Multi-Escala

O desenvolvimento do presente trabalho baseia-se na análise das irregularidades no contorno de lesões. Faz-se necessário então, o uso de características que retratem com fidelidade a informação presente no contorno de uma figura. Uma poderosa ferramenta matemática que satisfaz essa necessidade é a curvatura. Pode-se entender curvatura como uma medida da mudança de direção ocorrida na curva entre dois pontos consecutivos. Em (54), mostra-se que para uma curva paramétrica definida por $c(t) = [x(t), y(t)]$, sua curvatura $k(t)$ pode ser calculada através da expressão

$$k(t) = \frac{\dot{x}(t)\ddot{y}(t) - \dot{y}(t)\ddot{x}(t)}{(\dot{x}(t)^2 + \dot{y}(t)^2)^{\frac{3}{2}}} \quad (3.1)$$

onde $(\dot{x}(t), \dot{y}(t))$ $(\ddot{x}(t), \ddot{y}(t))$ são respectivamente as derivadas de primeira e segunda ordens dos parâmetros $(x(t), y(t))$

O cálculo dos valores para curvatura utilizados no trabalho baseiam-se nos valores obtidos em 3.1, sendo então necessário buscar técnicas de derivação via algoritmo computacional para resolvê-la. Tais técnicas devem ser robustas o suficiente de tal maneira que as aproximações necessárias durante o cálculo não interfiram no resultado global. Uma consagrada técnica de derivação computacional de funções é obtida através de uma propriedade da derivada da Transformada de Fourier, publicada pela primeira vez em (55) e sendo, desde então, amplamente utilizada na área de processamento e análise de imagens. Conforme descrito em (46), pode-se estimar o valor das derivadas de primeira $(\dot{x}(t), \dot{y}(t))$ e de segunda $(\ddot{x}(t), \ddot{y}(t))$ ordens utilizando-se o Teorema da Convolução (46, 56) conforme as seguintes expressões:

$$\dot{x} = \mathfrak{F}^{-1}\{i2\pi fX(f)\}$$

$$\ddot{x} = \mathfrak{F}^{-1}\{-(2\pi f)^2X(f)\}$$

onde $\mathfrak{F}^{-1}$ representa a transformada inversa de Fourier, $i = \sqrt{-1}$, f é a frequência do sinal $x(t)$ e por fim, $X(f)$ é a transformada de Fourier do sinal $x(t)$.

A diferenciação computacional do sinal através do cálculo da Transformada de Fourier pode acarretar efeitos indesejáveis durante o processo. O principal prejuízo obtido pela aplicação da transformada de Fourier são os ruídos de alta frequência gerados no processo. Esses ruídos são gerados devido à discretização do sinal e interferem significativamente no resultado. Tais defeitos podem ser minimizados através de um mecanismo de filtragem multi-escala (46) durante o processo do cálculo da curvatura. A ideia central desse mecanismo é a possibilidade de suavizar as funções diferenciadas durante o processo, fazendo a convolução de um filtro Gaussiano com o sinal a ser diferenciado. A seguir detalhamos o processo de suavização.

Seja $f(t)$ um determinado sinal no domínio espacial t . A aplicação da transformada de Fourier resulta na função $F(f)$ no domínio da frequência. Definimos Filtro Gaussiano $g(t)$ e

sua respectiva Transformada de Fourier $G(f)$ por:

$$g(t) = \frac{1}{a\sqrt{2\pi}} \exp\left(\frac{-t^2}{2a^2}\right)$$

$$G(f) = \frac{1}{\sqrt{2\pi}} \exp\left(\frac{-(2\pi f)^2}{2\sigma^2}\right)$$

sendo σ o desvio padrão da gaussiana no espaço de frequência. Cabe ressaltar que os desvios padrões nos domínios espaciais (a) e de frequência (σ) comportam-se de maneira inversa, ou seja, $a = \frac{1}{\sigma}$. Isso implica que para elevados valores de σ , o sinal apresenta-se pouco suavizado, enquanto que para baixos valores de σ , o sinal apresentará suavização intensa.

Dessa maneira, introduz-se o filtro Gaussiano ao sinal a ser diferenciado através do teorema da convolução:

$$H(f) = F(f)G_\sigma(f)$$

Por fim, obtêm-se o sinal suavizado calculando a transformada inversa de Fourier ao sinal $H(f)$:

$$h_\sigma(t) = \mathfrak{F}^{-1}H(f)$$

É importante notar que após a suavização, o sinal passa a ter dependência inversa do desvio padrão σ da gaussiana do domínio da frequência. Isso permite regular a suavização do processo, adequando aos valores de σ mais apropriados ao trabalho. A figura 3.19 exemplifica os passos necessários para a suavização de um sinal.

Sendo assim, podemos explicitar o cálculo da curvatura escrevendo a equação 3.1 de maneira generalizada, introduzindo o termo h_σ — referente à suavização — aos seus parâmetros:

$$k(t, \sigma) = \frac{\dot{x}_\sigma(t)\ddot{y}_\sigma(t) - \dot{y}_\sigma(t)\ddot{x}_\sigma(t)}{(\dot{x}_\sigma(t)^2 + \dot{y}_\sigma(t)^2)^{\frac{3}{2}}} \quad (3.2)$$

De posse dos valores da curvatura obtidos ponto a ponto do contorno, pode-se obter medidas estatísticas do conjunto de dados obtidos. Para as equações a seguir, supõe-se uma forma com i pontos em seu contorno e a curvatura em cada ponto é representada por k_i :

Figura 3.19 – Esquema ilustrativo do processo de suavização por filtro gaussiano de um sinal de entrada $s(t)$.

Fonte: Elaborada pelo autor.

• Média, Desvio Padrão e Coeficiente de Variação da Curvatura

A média da curvatura, pela própria definição, refere-se ao valor da média aritmética entre os valores da curvatura k_i :

$$\mathcal{M}_{41} = \bar{k} = \frac{1}{N} \sum_{i=1}^N k_i$$

O desvio padrão representa a dispersão, ou variação dos valores da curvatura em relação a sua média e é definido por:

$$\mathcal{M}_{42} = \sigma_k = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (k_i - \bar{k})^2}$$

O coeficiente de variação (cv_k) é obtido pela razão entre o desvio padrão e a média da curvatura:

$$\mathcal{M}_{43} = cv_k = \frac{\sigma_k}{\bar{k}}$$

• Mediana da Curvatura

A mediana é o valor numérico que separa a metade superior de uma amostra de dados a partir da metade inferior. Para o cálculo da mediana, inicialmente ordenam-se os dados e a partir disso, seleciona-se o valor central. No caso de i pontos do contorno ordenados crescentemente, seleciona-se o valor da mediana de acordo com as seguintes possibilidades:

$$\mathcal{M}_{44} = \begin{cases} k(\frac{i+1}{2}) & \text{se } n \text{ é ímpar} \\ \frac{k(\frac{i}{2}) + k(\frac{i+1}{2})}{2} & \text{se } n \text{ é par} \end{cases}$$

- **Energia Normalizada do Contorno**

A energia do contorno refere-se, basicamente, à quantidade de energia necessária para transformar um contorno fechado em um círculo. Sua medida é variante de escala, portanto, há de se ter cuidado de normalizar seu valor através do perímetro L e do número de pontos N (ver (46) para maiores detalhes).

$$\mathcal{M}_{45} = \frac{L^2}{N} \sum_{i=1}^N k_i^2$$

- **Histograma da Curvatura**

De posse dos valores de curvatura, é possível determinar outras importantes características referente ao padrão de distribuição dos valores de curvatura ao longo do contorno: o Histograma. O histograma dos valores da curvatura computa o número de aparições — ou a frequência relativa — com que determinado intervalo de valores aparecem numa forma. Sendo assim, cada forma terá um padrão de distribuição que será utilizado como característica na classificação. Tratando especificamente de um conjunto de diferentes imagens, são necessárias algumas precauções na determinação do histograma. A primeira delas é estipular os limites máximo e mínimo de valores para a divisão dos grupos. Esses valores devem garantir que os histogramas de todos os contornos possuam mesma escala. Sendo assim, inicialmente calcula-se a curvatura de todas as imagens, e dentre esses dados, elege-se o maior valor como máximo $d_{\text{máx}}$ e o menor valor como mínimo $d_{\text{mín}}$. Em seguida estipula-se o intervalo de valores:

$$\text{intervalo} = \frac{|d_{\text{max}} - d_{\text{min}}|}{F}$$

onde F , nesse caso, refere-se à quantidade de divisões do histograma, gerando $F + 1$ intervalos. Computa-se então, a frequência relativa com que os valores de curvatura se distribuem pelos intervalos, gerando os valores do histograma, ao qual nos referimos por *Hist.*

Outra precaução que se deve ter é com relação aos valores. Devido à diferença de tamanho entre os contornos, é possível que algumas imagens tenham uma quantidade de pontos muito superior à outras, isso pode influenciar de maneira significativa no resultado final da análise. Sendo assim, uma maneira simples de se corrigir esse problema é utilizar a frequência relativa dos valores, que é obtida basicamente fazendo a divisão de cada valor computado do histograma pelo total de pontos do contorno específico.

Utilizou-se o valor $F = 10$ para a quantidade de divisões, gerando 11 atributos, referenciados por:

$$\mathcal{M}_{17 \rightarrow 27} = f_{rel}(Hist_{1 \rightarrow 11})$$

- **Entropia da Curvatura**

A entropia é uma medida da distribuição dos valores de curvatura através do contorno e está associada com o grau de desordem relacionada aos mesmos. (57) Sendo assim, a partir do histograma de frequência relativa de curvatura, é possível calcular a entropia a partir da equação

$$\mathcal{M}_{46} = - \sum_{i=0}^F p_i \log_2 p_i$$

onde p_i é a frequência relativa obtida pelo histograma.

3.5.4 Detecção de Picos

Uma importante característica associada à diferenciação entre distintas formas é a presença de picos relevantes em sua estrutura. Os picos de um contorno são todos os máximos e mínimos locais presentes no mesmo. Um determinado ponto do contorno será considerado máximo local se ele tiver o maior valor de curvatura para pontos próximos a ele. Analogamente, define-se mínimo local se o ponto tiver o menor valor de curvatura com relação aos seus vizinhos. A partir dessa definição é possível se obter todos os picos presentes numa forma analisando seus valores de curvatura. Portanto, sendo $k(t)$ o valor de curvatura no ponto t , se $k(t) > k(t-1)$

e $k(t) > k(t+1)$, então t é considerado um pico. Porém, o simples uso dessas duas condições acarretaria na detecção de pequenos ruídos presentes no contorno, que não são relevantes na caracterização da forma. Uma maneira simples de eliminá-los é utilizando um valor limiar α para que o pico seja considerado relevante. Logo, devemos ter que $k(t) > \alpha$. A estipulação desse valor limiar α será discutido mais adiante na sessão Resultados. Em suma, determina-se um pico pelas seguintes condições:

$$t \text{ é pico se } \begin{cases} |k(t)| > |k(t+1)| \\ |k(t)| > |k(t-1)| \\ |k(t)| > \alpha \end{cases}$$

A figura 3.20 ilustra a obtenção dos picos de uma imagem binária, a partir de um limiar adotado exclusivamente para fins ilustrativos.

Figura 3.20 – Figura A: Curvograma de uma imagem modelo de padrão estrelar com seus picos mais relevantes detectados e o limiar em destaque. Figura B: Plotagem da imagem modelo e seus picos relevantes marcados, tais como na Figura A. Nota-se claramente que todos os picos detectados são relevantes na caracterização da forma, enquanto pequenos ruídos, visíveis na Figura A, não foram selecionados.

a) Curvograma

b) Detecção dos picos relevantes

Fonte: Elaborada pelo autor.

Determinados os picos relevantes de cada forma, calculam-se atributos que possam ser utilizados na classificação das imagens. Para melhor visualização, propomos a simbologia presente na figura 3.21

Figura 3.21 – Ilustração de parte de uma forma qualquer e dois de seus picos assinalados (1) e (2). Entre os picos há duas características relevantes: o contorno entre os picos $C_{1 \rightarrow 2}$ e a distância euclidiana entre os picos $p_{1 \rightarrow 2}$.

Fonte: Elaborada pelo autor.

A figura ilustra parte de uma forma com dois de seus picos representados por (1) e (2). A menor distância entre os dois picos — distância euclidiana — é simbolizada por $p_{1 \rightarrow 2}$ e o comprimento do contorno entre os picos — distância perimetral — é simbolizado por $C_{1 \rightarrow 2}$.

Assim sendo, obtem-se três diferentes informações para cada forma: número de picos relevantes n , as distâncias perimetrais entre cada pico C e as distâncias euclidianas entre cada pico d . Foram calculados os seguintes atributos:

- **Média, Desvio Padrão e Coeficiente de Variação da Distância Euclidiana d dos Picos**

$$\begin{aligned}\mathcal{M}_{28} &= \bar{d} = \frac{1}{n} \sum_{i=1}^n d_i \\ \mathcal{M}_{29} &= \sigma_d = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (d_i - \bar{d})^2} \\ \mathcal{M}_{30} &= cv_d = \frac{\sigma_d}{\bar{d}}\end{aligned}$$

- **Média, Desvio Padrão e Coeficiente de Variação da Distância Perimetral C dos Picos**

$$\begin{aligned}\mathcal{M}_{31} &= \bar{C} = \frac{1}{n} \sum_{i=1}^n C_i \\ \mathcal{M}_{32} &= \sigma_C = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (C_i - \bar{C})^2}\end{aligned}$$

$$\mathcal{M}_{33} = \text{cv}_C = \frac{\sigma_C}{\bar{C}}$$

- **Média, Desvio Padrão e Coeficiente de Variação da Razão $R = \frac{C}{d}$ dos Picos**

$$\mathcal{M}_{34} = \bar{R} = \frac{1}{n} \sum_{i=1}^n R_i$$

$$\mathcal{M}_{35} = \sigma_R = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (R_i - \bar{R})^2}$$

$$\mathcal{M}_{36} = \text{cv}_R = \frac{\sigma_R}{\bar{R}}$$

- **Média, Desvio Padrão e Coeficiente de Variação dos Valores dos Picos**

$$\mathcal{M}_{37} = \bar{V} = \frac{1}{n} \sum_{i=1}^n V_i$$

$$\mathcal{M}_{38} = \sigma_V = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (V_i - \bar{V})^2}$$

$$\mathcal{M}_{39} = \text{cv}_V = \frac{\sigma_V}{\bar{V}}$$

- **Quantidade de picos**

$$\mathcal{M}_{40} = n$$

3.5.5 Dimensão Fractal

Dimensão fractal de uma forma está associada com seu grau de complexidade. Uma das maneira de se calcular este atributo é através do método conhecido por Salsicha de Minkowski. O cálculo da dimensão fractal através deste método consiste em realizar sucessivas dilatações do contorno e computar a área cumulativa interna de cada dilatação em relação ao seu respectivo raio. Uma dilatação é feita de tal maneira que os pontos do contorno resultante da dilatação tenha a mesma distância para a forma original. Para tal, faz-se percorrer um círculo de raio d através da forma ao qual se deseja calcular a dimensão fractal. A região coberta por esses

círculos através do contorno resulta numa área em função de d , chamada de $A(d)$. A realização dessas sucessivas realizações resulta numa figura conhecida por transformada distância.

A partir da transformada distância realizada, a dimensão fractal é estimada analisando o gráfico di-log das áreas $A(d)$ em relação aos respectivos raios d . Os pontos desse gráfico são interpolados por uma reta através de uma regressão linear. Dessa reta obtém-se sua inclinação α . A dimensão fractal é obtida pela expressão:

$$\mathcal{M}_{47} = D_{frac} = 2 - \alpha$$

na qual o número 2 é o espaço euclidiano onde o contorno está localizado — em nosso caso, o espaço bidimensional. A figura 3.22 ilustra as etapas do cálculo da dimensão fractal

Figura 3.22 – Determinação da dimensão fractal de uma forma pelo método "Salsicha de Minkowsky".
a) Transformada distância de uma forma binária e b) Gráfico $(\log A \times \log d)$.

Fonte: Elaborada pelo autor.

Analisando o gráfico $\log - \log$ apresentado, observa-se que o valor da regressão linear é caracterizado substancialmente pelos valores mais altos da escala logarítmica. O erro de regressão para os pontos iniciais é devido à não uniformidade desta escala, que cria lacunas na função, efeito da falta de pontos nesta região. Uma maneira de evitar essa falha seria desconsiderando os pontos iniciais do gráfico. Porém, constata-se que a diferença de valores para dimensão fractal é irrisória quando se considera ou não os tais pontos. Portanto, a fim de manter uma padronização dos resultados, os valores de dimensão fractal calculados no trabalho foram feitos considerando-se todos os pontos do gráfico.

3.5.6 Esqueleto

O esqueleto de uma imagem, pela própria definição, está relacionado com sua estrutura primordial. O esqueleto de uma imagem pode apresentar características fundamentais para a discriminação entre grupos distintos. A determinação do esqueleto, ou esqueletonização, consiste em representar as formas através de linhas representativas, em outras palavras, seria o traço essencial de uma forma. Existem diversas definições formais para o esqueleto, sendo que uma delas é dada pelo conceito de discos máximos. (46, 58)

Seja um disco D_z cujo centro é o ponto z e o mesmo esteja contido na forma A a ser esqueletonizada. O disco máximo $D_z^{\text{máx}}$ é tal que esteja inteiramente contido na forma A e não exista outro disco maior com o mesmo centro z . Além disso, o disco máximo deve tocar a borda da forma em pelo menos dois pontos distintos. Sendo assim, todos os centros dos discos máximos definem o esqueleto $Sk(A)$ da imagem. A figura 3.23 ilustra a ideia de discos máximos e consequentemente a obtenção do esqueleto da figura.

Figura 3.23 – Obtenção do esqueleto da imagem binária pela determinação dos discos máximos. Os círculos A , B e C são diâmetros máximos, logo seus centros definem o esqueleto da imagem. Círculo D não define um ponto do esqueleto, pois toca a borda da figura em apenas 1 ponto.

Fonte: Elaborada pelo autor.

O exemplo da figura 3.23 ilustra discos máximos tangentes a pelo menos dois pontos da borda da imagem. Deste exemplo, pode-se prever que as quinas presentes nas formas sempre

serão detectadas pelo esqueleto, seja ela uma dobra relevante ou um ruído do contorno. Isso produz efeitos indesejáveis ao processo, como o número excessivo de ramos do esqueleto proveniente de ruídos da borda. Certamente tais ruídos não são relevantes para serem detectados e devem ser eliminados. Um procedimento útil para eliminar esses ruídos é aplicar uma suavização ao contorno, de tal maneira que elimine ramos excessentes e influencie pouco nos ramos principais. A figura 3.24 mostra o efeito da suavização na qualidade do esqueleto obtido.

Figura 3.24 – Obtenção do esqueleto da forma em duas diferentes situações. a) Esqueleto determinado da imagem original. b) Esqueleto determinado da mesma imagem após a suavização.

Fonte: Elaborada pelo autor.

Foram calculados 4 atributos a partir do esqueleto da forma. Adotando a nomenclatura b para os m ramos presentes no esqueleto, obtêm-se:

- **Número de ramos**

$$\mathcal{M}_{48} = m$$

- **Média, Desvio Padrão e Coeficiente de Variação dos Ramos do Esqueleto**

$$\mathcal{M}_{49} = \bar{b} = \frac{1}{m} \sum_{i=1}^m b_i$$

$$\mathcal{M}_{50} = \sigma_b = \sqrt{\frac{1}{m-1} \sum_{i=1}^m (b_i - \bar{b})^2}$$

$$\mathcal{M}_{51} = \text{cv}_b = \frac{\sigma_b}{\bar{b}}$$

3.6 Classificação

A seguir apresentamos os principais tópicos utilizados no trabalho com relação a classificação dos dados. Inicialmente apresentamos a técnica *Linear Discriminant Analysis* (LDA) para redução da dimensionalidade dos dados. Em seguida apresentamos o classificador *k Nearest Neighbor* (kNN) e a técnica validação cruzada (*cross validation*), utilizados na validação do resultado do LDA.

3.6.1 Linear Discriminant Analysis

Geralmente, técnicas de processamento e análise de imagens resultam em uma vasta quantidade de atributos obtidos, a partir de uma também ampla quantidade de amostras. Isso significa que, para cada amostra analisada, existem diversas características da mesma, sendo que cada uma dessas medidas irá contribuir para a distinção final entre as classes. Porém, a visualização desse resultado torna-se inviável devido à grande quantidade de dimensões presentes na análise. É necessário então, recorrer a técnicas de redução de dimensionalidade do conjunto de amostras, tornando possível a visualização das classes. O método de classificação utilizado no trabalho foi o *Linear Discriminant Analysis* (LDA). A opção pelo uso do LDA se deu não apenas devido aos seus bons resultados obtidos no problema proposto, mas também por ser uma técnica de baixo custo computacional. (59, 60) O método LDA busca preservar o máximo de informação discriminatória possível dos dados originais. Da aplicação do LDA, obtêm-se a direção na qual a discriminação entre as classes se mantém a maior possível, baseado nos dados originais. Pode-se então, fazer uma projeção de todos os dados sobre a direção obtida, tornando possível sua visualização. Sendo assim, podemos dizer que o LDA busca a direção da projeção

que melhor discrimina classes em uma dimensão reduzida. A figura 3.25 ilustra a aplicação do método.

Figura 3.25 – Esquema ilustrando a projeção LDA (v_{LDA}) num espaço de atributos formado por χ_1 e χ_2 . A direção da projeção é ilustrada pelo vetor sobre a reta. Importante notar a redução de dimensionalidade realizada no processo, na qual os dados, antes discriminados no espaço bidimensional, agora pode ser discriminados no espaço unidimensional.

Fonte: Elaborada pelo autor.

Para o cálculo do LDA, dois conceitos são importantes de serem citados: A matriz de dispersão dentro da própria classe, chamada de matriz *intra* S_w e a matriz de dispersão entre as classes, chamada de matriz *inter* S_b . Podemos expressar ambas matrizes da seguinte maneira:

$$S_w = \sum_{j=1}^c \sum_{i=1}^{N_j} (x_i^j - \mu_j)(x_i^j - \mu_j)^T$$

$$S_b = \sum_{j=1}^c (\mu_j - \mu)(\mu_j - \mu)^T$$

onde x_i^j é a i -ésima amostra (no nosso caso, imagem) da classe j , μ_j é a média da classe j e μ é a média de todas as classes, c é o numero de classes, N_j é o numero de amostras de cada classe. O subespaço criado pelo LDA é formado pelo conjunto de vetores obtidos pela maximização da matriz S_b e pela minimização da matriz S_w . Sendo assim, determinam-se os autovetores e autovalores da matriz $W = S_w^{-1} S_b$, através de:

$$W\mathbf{x} = \lambda\mathbf{x}$$

Desse resultado, ordena-se os autovalores em ordem decrescente

$$\lambda_1 \geq \lambda_2 \geq \lambda_3 \dots \lambda_{n-1}$$

de tal maneira que seus correspondentes autovetores são chamados de Componentes Principais. Esse resultado permite a visualização de um conjunto grande de dado com dependência de vários atributos, projetando-se apenas as duas maiores componentes principais, que contém a maior parte da informação da matriz de dados originais.

3.6.2 Algoritmo kNN

O algoritmo K vizinhos mais próximos (kNN) é um método de classificação que se baseia na proximidade entre um ponto desconhecido em relação a grupos estipulados. Este é um dos classificadores mais antigos de que se tem conhecimento, além de ser bastante difundido e utilizado na área da computação. (61) O kNN traz algumas facilidades para o processo global, tais como a facilidade de implementação, além da rápida obtenção dos resultados sem a necessidade de um treinamento prévio para sua realização.

Para a implementação do algoritmo kNN, estipula-se inicialmente os grupos padrões. A posição dos pontos desses grupos servirão como base para a classificação de um ponto desconhecido o qual deseja-se classificar. Calcula-se a distância euclidiana do ponto desconhecido para todos os pontos dos grupos padrões, de acordo com:

$$d_{O \rightarrow P} = \sqrt{(x_O^2 - x_P^2) + (y_O^2 - y_P^2)}$$

Em seguida ordena-se os valores obtidos de maneira decrescente, separando assim desde os próximos aos pontos mais afastados. Elegem-se então k primeiros pontos próximos para classificação. O ponto desconhecido será classificado como pertencente ao grupo que possuir mais valores próximos a ele. A figura 3.26 traz um exemplo, na qual duas classes são definidas a partir dos atributos χ_A e χ_B . É feita a implementação do algoritmo kNN e a posterior classificação

do ponto desconhecido, estipulando-se $k = 5$ para o exemplo dado.

Figura 3.26 – a) Os atributos χ_A e χ_B definem as Classes 1 e 2, bem como um ponto desconhecido a ser classificado. b) As 5 menores distâncias ao ponto desconhecido são mostradas, das quais 4 pertencem à Classe 1 e apenas 1 pertence à Classe 2. Esse resultado classifica o ponto desconhecido como pertencente à Classe 2.

Fonte: Elaborada pelo autor.

3.6.3 Validação Cruzada

Conforme citado no item acima, a técnica de LDA é método de classificação de dados supervisionado. Isso implica que a simples projeção dos dados não garante uma discriminação adequada, visto que para execução dos métodos supervisionados, informa-se previamente quais são os grupos a serem discriminados. Sendo assim, a classificação LDA necessita de um teste adequado para que seu resultado tenha validade. Nesse contexto, a validação cruzada dos dados fornece uma boa alternativa para a confirmação.

A Validação Cruzada, conhecida na literatura como *cross validation*, é um teste feito entre as categorias discriminadas da projeção LDA. Inicialmente definiu-se, para cada categoria, uma quantidade de amostras denominada **grupo de teste** e outro grupo denominado **grupo de treino**. Em seguida aplica-se a técnica LDA aos grupos de treino selecionados e aplica-se essa mesma projeção às amostras do grupo de teste. Por fim, utilizando-se o algoritmo kNN (ver 3.6.2), classificam-se as amostras do grupo de teste em relação aos grupos de treino. A visualização do

resultado da validação cruzada se dá através da construção da matriz de confusão.

Uma matriz de confusão dispõe os grupos de treino e teste em linhas e coluna, facilitando assim a interpretação dos resultados. A figura 3.27 ilustra a disposição de uma matriz de confusão para n classes. Importante notar que, numa matriz de confusão, a diagonal principal da matriz representam os acertos para cada classe, ou seja, os elementos do grupo de teste que foram corretamente classificados.

Figura 3.27 – Esquema geral da disposição de uma matriz de confusão. As classes dos grupos de treino estão dispostos em colunas e os respectivos testes de cada classes dispostos em linhas.

		GRUPO DE TREINO				
		C_1	C_2	C_3	...	C_n
GRUPO DE TESTE	P_{C_1}					
	P_{C_2}					
	P_{C_3}					
	P_{C_n}					

Fonte: Elaborada pelo autor.

Em certas situações, deseja-se analisar uma classe específica em relação às demais. Para tal, pode-se particularizar a matriz de confusão para uma classe específica, analisando seus erros e acertos e desprezando os demais valores. Esse tipo de matriz de confusão é muito difundida na área médica, quando se analisa, por exemplo, o diagnóstico de determinada patologia em relação a outras. Nesses casos, a matriz de confusão ganha uma terminologia particular, a qual abordaremos a seguir. A denominação da classe específica, a qual a matriz de confusão basear-se-à, é chamada de *verdadeiro*, enquanto classe diferente (ou classes diferentes) é chamada de *falso*. Os acertos de cada classe tem a denominação *positivo*, enquanto que os erros tem denominação *negativo*. (62)

A partir dessa notação, pode-se calcular o percentual de acertos para da classe *verdadeiro* com relação a todo grupo de teste. Essa medida estatística é conhecida como **sensibilidade**

Tabela 3.2 – Terminologia utilizada para matriz de confusão no estudo de uma classe específica.

Simbologia	Descrição
<i>TP</i>	Verdadeiros Positivos (<i>True Positive</i>)
<i>FP</i>	Falso Positivo (<i>False Positive</i>)
<i>FN</i>	Falso Negativo (<i>False Negative</i>)
<i>TN</i>	Verdadeiros Negativo (<i>True Negative</i>)

Fonte: Elaborada pelo autor.

(**S**) e ela reflete a capacidade do teste de detectar *verdadeiros*. O percentual de acertos para da classe *falso* (**E**) é conhecido como **especificidade**, e analogamente à **sensibilidade**, essa medida estatística reflete a capacidade de detectar *negativos*.

$$\mathbf{S} = \frac{TP}{TP + FN}$$

$$\mathbf{E} = \frac{TN}{TN + FP}$$

Além dessas duas medidas estatísticas, diversas outras são possíveis de serem calculadas. Duas outras medidas merecem destaque: A **acurácia** (**A**), que está relacionada com a capacidade total de acertos, e a **precisão** (**P**), relacionada com a proporção de acertos para classe *verdadeiros* em relação seu total. Na literatura, o termo **precisão** também é encontrado como **valor preditivo positivo**.

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

$$\mathbf{P} = \frac{TP}{TP + FP}$$

4 Metodologia e Resultados

A seguir apresentamos a metodologia de trabalho desenvolvida, bem como os resultados obtidos. Este capítulo foi segmentado para melhor organização e compreensão de seus conteúdos. Primeiramente, relatamos as etapas iniciais do projeto, como aquisição das imagens, montagem do banco de dados e escolha dos algoritmos para o pré-processamento. Na sessão seguinte 4.2, apresentamos os métodos resultados obtidos da segmentação proposta. Em seguida, na sessão 4.3, há uma explanação sobre os atributos extraídos e sua relevância para a sessão seguinte 4.4, onde há uma discussão sobre a classificação dos grupos e suas considerações. A última sessão reporta uma avaliação de desempenho feita pelo protótipo no reconhecimento de lesões melanocíticas 4.5.

4.1 Obtenção e Tratamento das Imagens

O banco de imagens do trabalho foi composto de 143 imagens. As imagens foram obtidas em parceria com dois hospitais do Estado de São Paulo que possuem tratamento específico de câncer de pele. O Hospital A. C. Camargo (São Paulo, São Paulo), que forneceu 104 imagens ao estudo e o Hospital do Câncer de Jaú (Jaú, São Paulo), fornecendo 39 imagens. Tais imagens foram coletadas de pacientes com casos suspeitos de câncer de pele, durante um período amostral de dois anos (2009 – 2011). No total, 69 das 143 imagens do banco de dados foram diagnosticadas como Melanoma Maligno, enquanto 43 eram Nevos Regulares e as 31 restantes eram Nevos Atípicos. Todas as imagens tiveram sua patologia confirmada através do exame histopatológico — biópsia. A tabela 4.1 mostra a obtenção de cada patologia estudada e sua respectiva origem.

As imagens adquiridas para a formação do banco de dados possuíam um caráter docu-

Tabela 4.1 – Origem do banco de dados do trabalho. Disposição das 143 imagens obtidas, sua origem e a quantidade de cada categoria de lesão.

	A. C. Camargo	Hospital do Câncer	Total
Melanoma Maligno	54	14	69
Nevo Regular	33	10	43
Nevo Atípico	17	14	31

Fonte: Elaborada pelo autor.

mental, ou seja, foram obtidas para controle no tratamento de pacientes. Isso significa que as imagens não possuem padronização de iluminação e/ou tamanho. Esse fato requer atenção aos atributos que serão utilizados, pois a falta de normalização acarreta erros de classificação (ver sessão 4.4.1). Do total, 75% das imagens possuem algum tipo de escala que permita obtenção do tamanho real da lesão.

Todas as 143 imagens foram recortadas manualmente, a fim de que a posição da lesão desejada estivesse ajustada no centro da figura. Esse procedimento inicial facilita o posterior tratamento e análise das imagens, visto que reduz a redundâncias de dados, tornando mais rápido o processamento e eliminando objetos indesejáveis que poderiam interferir na segmentação da lesão. A figura 4.1 mostra a obtenção da imagem recortada da original.

Figura 4.1 – Recorte manual da região da lesão à ser adicionada ao escopo das lesões. A imagem original possui dimensão (3648×2736) pixels, enquanto que o recorte da lesão possui dimensão de (463×343) pixels.

Fonte: Elaborada pelo autor.

Em seguida foram feitos pré-processamentos nas imagens recortadas, a fim de realçar a parte lesionada e facilitar a posterior segmentação. A saber, três procedimentos foram aplicados nessa etapa: a conversão da imagem RGB para escala de cinza, a aplicação do filtro gaussiana e o aumento de contraste. A transformação para escala de cinza é necessária para o cálculo do histograma. Já as duas últimas operações melhoram a qualidade da segmentação posterior (ver 4.2).

4.2 Resultados da Segmentação

A segmentação é uma das principais etapas do processamento de imagens. Apesar de reconhecermos a importância de se minimizar erros em todas etapas do trabalho, dedicou-se à segmentação um cuidado adicional, afinal, o projeto baseia-se substancialmente em sua análise. A partir do momento que pretende-se analisar as irregularidades presentes na borda de uma lesão, bem como sua assimetria, é necessário que se consiga definir adequadamente os limites entre pele saudável e pele lesionada. Quanto maior for a eficiência da segmentação, maior será a validade do projeto, pois estaríamos mais próximo da realidade do problema estudado.

No caso de imagens clínicas de lesões em pele, mesmo dermatologistas experientes divergem suas opiniões quanto a delimitação das bordas de uma lesão. Sendo assim, não se busca uma segmentação livre de erros, mas sim uma segmentação que consiga representar a lesão da melhor maneira possível e que possa retratar o problema adequadamente. Por isso, parte do projeto destinou-se a otimizar o processo de segmentação, de maneira a deixá-lo mais robusto e preciso, segmentando adequadamente a maioria das imagens e minimizando erros. Houve também cuidado ao checar a segmentação de cada imagem, fazendo uma comparação visual do resultado obtido com a imagem original. Considerou-se segmentação satisfatória quando o resultado da mesma gerou um contorno semelhante ao da figura original.

Do total de 143 imagens contidas em nosso banco de dados: 60 dos 69 melanomas malignos foram corretamente segmentados; 42 dos 43 nevos regulares foram corretamente segmentados e 30 dos 31 nevos atípicos foram corretamente segmentados. No geral, cerca de 92% das imagens

Figura 4.2 – Sequência de etapas do processo de segmentação: A) Imagem Original obtida de uma câmera digital comum à ser segmentada. B) Aumento de contraste de 50% realizado na imagem. C) Conversão para escala de cinza. D) Aplicação do filtro Gaussiano de $\sigma = 2$. E) Binarização efetuada com o limiar obtido do processo de segmentação (para maiores detalhes ver 3.3). F) Imagem finalizada da forma, com todos os ruídos eliminados (buracos preenchidos, pequenos segmentos eliminados e etc).

Fonte: Elaborada pelo autor.

foram corretamente segmentadas através da segmentação pelo histograma. As demais imagens não conseguiram definir um contorno fechado e por isso foram segmentadas manualmente.

As 11 imagens que tiveram segmentação insatisfatória foram checadas e constatou-se duas particularidades entre as mesmas: algumas destas eram pouco pigmentadas, ou seja, havia pouca distinção visual entre a lesão e a pele saudável. Este fato interfere diretamente no padrão do histograma, que torna inviável sua obtenção se a curva não for característica. Outro problema encontrado foi a falta de iluminação e padronização adequada para a obtenção da imagem. Algumas imagens possuíam sombras indesejáveis ou mesmo baixa resolução. A figura 4.3 traz dois casos na qual houve segmentação insatisfatória. Apesar desses fatores, houve alta porcentagem de acerto de segmentações, mesmo o conjunto de imagens não sendo destinado para fins acadêmicos.

Figura 4.3 – Imagens com segmentação insatisfatória.

a) Iluminação não uniforme e falta de contraste

b) Lesão pouco pigmentada

Fonte: Elaborada pelo autor.

4.3 Resultados dos Atributos

Ao se julgar uma lesão melanocítica a fim de classificá-la como melanoma ou outra patologia, faz-se necessário analisar as características presentes na lesão e associá-las à patologia correta.

Conforme apresentado no Capítulo 3, vimos que o melanoma maligno possui um conjunto de características que tornam possível sua diferenciação visual de outras lesões melanocíticas. Este conjunto de características é conhecido por regra do ABCD (ver 2.3). No presente trabalho, abordamos a assimetria e irregularidade da borda das lesões como fatores nessa distinção através da visão computacional e a contribuição dessas medidas no correto diagnóstico do melanoma maligno. Para que isso fosse possível, foi necessário reconhecer quais ferramentas (matemáticas e computacionais) são mais apropriadas para o estudo.

Antes de apresentarmos as análises obtidas em nosso estudo, faremos uma importante ressalva com relação à qualidade das imagens. O banco de dados utilizado foi composto de imagens sem fins acadêmicos, mas sim caráter documental, de controle e observação da evolução do quadro clínico. O principal problema encontrado foi a ausência de escala em parte das imagens. Cerca de 25% do total das imagens não tinham uma escala definida. Sendo assim, uma

importante característica do melanoma, seu tamanho, não pôde ser considerada no escopo do projeto. Há de se constar também que não houve padronização na distância entre a lente e a pele na obtenção das imagens¹, que impossibilita de vez o uso do fator tamanho no trabalho. Sabendo disso foi realizado uma normalização pela área ou perímetro de todos os dados que dependessem dessa medida. Os cálculos relacionados a curvatura, por exemplo, mostram que imagens de dimensões reduzidas possuem altos valores de curvatura, enquanto figuras de grandes dimensões possuem curvatura baixa. De fato, em (54) mostra-se que o valor teórico para curvatura de um círculo é dado por

$$k = \frac{1}{r}$$

sendo r seria o raio da circunferência. Portanto, é necessário determinar uma normalização para os valores de curvatura. Para tal, utilizou-se a seguinte relação de normalização:

$$k' = k \sqrt{\frac{Area}{\pi}}$$

onde k' é a curvatura normalizada, k é a curvatura calculada e $Area$ é o número de *pixels* contidos na lesão segmentada. Os demais atributos que também possuem dependência do tamanho — tais como esqueleto, valores e distâncias entre picos — foram normalizadas por relações similares.

Feita essa ressalva, apresentamos na próxima sessão uma análise da qualidade dos atributos obtidos e na sessão seguinte há uma explanação sobre a obtenção dos parâmetros globais desvio padrão da gaussiana σ_G no espectro de frequência e o limiar de detecção dos picos α .

4.3.1 Análise dos parâmetros σ_G e α

Dentre todos os atributos propostos e utilizados no trabalho, a curvatura do contorno e suas derivações obtiveram grande destaque pela sua capacidade de discriminação das classes.

Contudo, a utilização da curvatura implica a estipulação de dois parâmetros cruciais: O des-

¹ Mesmo se houvesse esse cuidado, seria muito arriscado confiar nessa padronização, pois um simples milímetro de diferença pode ser responsável por erro de milhares de *pixels*.

vio padrão (σ_G) da gaussiana na análise multi-escala (ver 3.5.3) e o limiar (α) para a detecção de picos (ver 3.5.4).

A primeira parte da análise da curvatura das lesões é a escolha de um valor adequado para o desvio padrão da gaussiana utilizado nos cálculos da curvatura (σ_G). O desvio padrão representa uma opção de análise multi-escala do contorno, na qual pode fornecer informações específicas (detalhes) ou gerais do contorno. É necessário então, buscar um valor adequado para σ_G , de tal maneira que otimize a discriminação do LDA. A figura 4.4 apresenta os resultados da extração do contorno e da consecutiva suavização para 3 valores diferentes para o desvio padrão.

Figura 4.4 – Suavização feita para três diferentes valores de sigma (σ_G).

Fonte: Elaborada pelo autor.

Analisando os resultados presentes na figura 4.4, percebe-se que para valores de σ_G baixos, a imagem obtida é extremamente suavizada, que nos mostra o comportamento geral da imagem (informações globais), mas por outro lado acarreta perda nos detalhes do contorno, o que não é favorável ao estudo. Em contrapartida, para altos valores de σ_G , a suavização é baixa e revela muitos detalhes presentes nos contornos (informações locais), o que também não é interessante para a análise pois incorpora ruídos presentes no contorno. Cabe então, determinarmos quais valores de σ_G serão favoráveis para utilizar no trabalho. Podemos entender o valor σ_G como sendo um parâmetro global, pois definiu-se um valor único para todo projeto.

A segunda parte da análise é a escolha de um limiar adequado para a determinação dos picos presentes no curvograma, e consequentemente, a obtenção dos picos encontrados na figura. Conforme visto anteriormente (ver 3.5.4), um ponto do contorno é considerado pico se o valor

de sua curvatura for maior que os pontos posterior e anterior e também deve ser maior que um certo valor limiar (para o qual adotaremos o símbolo α), a fim de evitarmos que pequenos ruídos sejam considerados picos relevantes.

Devido à diferença de tamanho e de resolução entre as lesões, é inviável determinar um único valor global de α para o problema, tal qual pôde foi feito para o valor do desvio padrão da curvatura. Sendo assim, determinou-se para cada figura, um valor de limiar que seja útil ao problema. Sabendo que o limiar deve ser capaz de separar valores altos de curvatura (referentes a curvas acentuadas) de valores baixos (correspondentes à trechos lineares), o método proposto para a determinação do limiar levou em conta a **mediana** dos valores da curvatura. Sendo assim, espera-se que os picos relevantes na figura sejam determinados e os picos insignificantes (referentes a ruídos ou a curvas pouco acentuadas) não sejam considerados. O método para o cálculo foi o seguinte:

$$\alpha = n.Med(k)$$

onde $Med(k)$ refere-se ao valor da mediana dos valores de curvatura e n um parâmetro global (tal qual σ) estipulado para o trabalho (ver Figuras 4.5 e 4.6).

Figura 4.5 – A partir de uma imagem binária obtida da etapa de segmentação, é definido seu contorno e são extraídos os picos de interesse. No curvograma, observamos que apenas picos mais relevantes, ou seja, aqueles acima do limiar (linha tracejada) foram escolhidos. Os picos escolhidos foram marcados no contorno da figura. A presente imagem, construída para fins ilustrativos, foi obtida para os valores de $n = 3$ e $\sigma_G = 200$.

Fonte: Elaborada pelo autor.

A determinação de ambos parâmetros globais (σ, n) foi feita analisando quais valores, ou faixa de valores, garantiriam os melhores classificações para cada grupo. Para tal, executamos

Figura 4.6 – Exemplo Controle: A partir do algoritmo para obtenção da figura 4.5, implementou-se o mesmo para uma figura padrão sem picos relevantes, afim de obter uma validação para o método de detecção de picos. Podemos observar que, apesar do cálculo da curvatura apresentar ruídos, nenhum pico foi detectado. Os parâmetros usados para este controle foram os mesmos da figura 4.5.

Fonte: Elaborada pelo autor.

o algoritmo principal do projeto diversas vezes, fazendo pequenas variações nos parâmetros globais, a fim de obter o par (σ, n) com o melhor desempenho de classificação final. Foram feitas 6 implementações para valores de $n = 1,5; 2,0; 2,5; 3,0; 3,5; 4,0$ e $50 \leq \sigma \leq 450$ com variações de 25 entre os valores. Os resultados desse procedimento são apresentados na figura 4.7 (Para maiores detalhes da obtenção dos resultados de classificação, ver Sessão 4.4).

A análise da figura 4.7 mostra certa uniformidade nos resultados, com relação à variação do parâmetro global n . Importante notar que valores $\sigma \leq 50$ a suavização é extrema e as formas do contorno perdem suas informações relevantes. Valores na faixa de $50 \leq \sigma \leq 150$, os acertos são baixos para as três categorias, implicando que a suavização dessa faixa de valores acarreta perda de informações substanciais das bordas da figura. A partir de valores em torno de $\sigma \geq 150$ há um aumento no percentual de acerto para maioria das combinações (σ, n) , onde visualmente nota-se regiões com os maiores percentuais de acertos variando entre $300 \leq \sigma \leq 450$. A figura 4.8 apresenta diversos exemplos de suavizações e seus respectivos picos detectados com relação ao parâmetro n .

Sendo assim, concluímos que a variação do parâmetro n altera pouco o resultado final da classificação dos grupos, pois há certa uniformidade entre os gráficos e a faixa de valores $300 \leq \sigma \leq 450$ contém os maiores acertos percentuais. Para a sequência do trabalho, estipulou-

Figura 4.7 – Análise dos parâmetros globais σ e n . Os gráficos mostram os valores de porcentagem de acerto em função de σ para diversos valores de n respectivamente.

Fonte: Elaborada pelo autor.

se os valores $n = 2,0$ e $\sigma = 350$.

Figura 4.8 – Exemplos da obtenção dos picos do contorno com relação aos parâmetros (σ, n) .

Fonte: Elaborada pelo autor.

4.3.2 Análise dos Atributos

Uma informação vital para o entendimento do nosso objeto de estudo é a qualidade dos atributos. Ou seja, a discriminação adequada entre as classes dependerá dos valores dos atributos obtidos das imagens. É importante que tais valores variem significativamente de uma classe para outra, atribuindo pesos diferentes para cada classe e contribuindo para a discriminação das mesmas. Essa análise pode ser feita verificando a distribuição dos valores dos atributos em relação as imagens. Dessa distribuição de valores pode-se extrair um histograma de frequência relativa dos valores. A forma dos histogramas de cada classe ajuda a visualizar variação de seus valores.

A seguir, apresentamos alguns exemplos. Inicialmente, discutimos três atributos e sua respectiva distribuição de valores, sendo que os mesmos apresentaram boa distinção entre seus

histogramas. A saber, selecionamos:

1. Histograma dos valores de curvatura - 6° parte (Hist 6) $\rightarrow \mathcal{M}_{22}$
2. Desvio padrão dos valores de curvatura (σ_k) $\rightarrow \mathcal{M}_{42}$
3. Dimensão fractal ($\mathcal{D}_{fractal}$) $\rightarrow \mathcal{M}_{47}$

Figura 4.9 – Distribuição dos valores da métrica $\mathcal{M}_{22}$. O gráfico superior dispõe os valores obtidos através de todas as 143 imagens do estudo. O gráfico inferior esquerdo apresenta o histograma normalizado dos dados e à direita a densidade do histograma.

Fonte: Elaborada pelo autor.

A figura 4.9 ilustra como é feita a análise da relevância de cada métrica. O gráfico superior mostra a disposição dos valores da métrica em questão através de todas as imagens. Em seguida, no gráfico inferior esquerdo é calculado o histograma normalizado dos valores da métrica. A disposição desse histograma ilustra a região de concentração dos valores bem como sua distribuição. Certamente, quando maior for a diferença entre a forma dos histogramas, maior a variação dos atributos entre as classes e consequentemente, maior o peso deste atributo para a discriminação final. O gráfico inferior direito traz a interpolação do histograma para uma função gaussiana, ilustrando a densidade do mesmo.

Figura 4.10 – Distribuição dos valores da métrica $\mathcal{M}_{42}$.

Fonte: Elaborada pelo autor.

Figura 4.11 – Distribuição dos valores da métrica $\mathcal{M}_{47}$.

Fonte: Elaborada pelo autor.

Analisando a figura 4.9, percebe-se que os histogramas tem disposições diferentes para as três classes. Tanto o grupo Melanoma como os grupos Nevo Regular e Nevo Atípico estão diferenciados através da densidade do histograma. Isto significa que tal métrica possui informações relevantes na discriminação das três classes. As figuras 4.10 e 4.11, apresentam distribuições que diferenciam satisfatoriamente os melanomas, porém, pouco diferenciam os nevos regulares e atípicos, visto que as distribuições gaussianas de ambas são semelhantes. Pode-se esperar que tais características sejam úteis na discriminação de melanomas das demais classes. Por outro lado, alguns atributos apresentaram uma distribuição pobre de dados, com valores muito próximos e igualmente distribuídos entre as três classes. Certamente estas características pouco contribuem para os resultados finais de classificação. A seguir apresentamos dois desses atributos. A saber, selecionamos:

1. 2º Hu Moment (Hu_2) $\rightarrow \mathcal{M}_{11}$
2. Histograma dos valores de curvatura - 7º parte (Hist 7) $\rightarrow \mathcal{M}_{23}$

Figura 4.12 – Distribuição dos valores da métrica $\mathcal{M}_{11}$.

Fonte: Elaborada pelo autor.

Figura 4.13 – Distribuição dos valores da métrica $\mathcal{M}_{23}$.

Fonte: Elaborada pelo autor.

A análise dos gráficos das figuras 4.12 e 4.13 mostram distribuição de valores similar para os atributos, com histogramas parecidos. Portanto, conclui-se que tais características contribuirão pouco na distinção das classes. À saber, foram selecionadas apenas estes atributos para evitar redundância de dados no decorrer da dissertação, porém, a disposição de todos os atributos é apresentado no apêndice A.

4.4 Resultados da Classificação

A proposta do trabalho é elaborar um algoritmo capaz de extrair características relevantes baseadas em assimetria e irregularidade de borda de lesões em pele e diferenciar satisfatoriamente melanomas malignos de outras lesões melanocíticas — no presente trabalho, escolheu-se nevos atípicos e nevos regulares. A partir destes atributos, aplicam-se técnicas de redução de dimensionalidade, a fim de visualizar disposição dos grupos analisados num espaço bi-dimensional. A técnica escolhida no trabalho foi o *Linear Discriminant Analysis* (LDA).

Conforme descrito em 3.6.1, a partir da aplicação do LDA ao conjunto de dados, obtém-se a direção onde a projeção dos dados apresenta a máxima dispersão entre as classes. A figura 4.14 apresenta a projeção das duas maiores componentes principais da matriz LDA calculada, a partir dos atributos de assimetria e irregularidade de borda.

Figura 4.14 – LDA realizado para as três categorias de lesões.

Fonte: Elaborada pelo autor.

A análise da figura 4.14 acima evidencia uma distinção significativa entre os grupos estudados. Esse resultado visual sugere que, de fato, assimetria e irregularidades na borda das lesões apresentam informações relevantes na discriminação entre as três classes. Porém, pelo fato do LDA ser uma técnica de reconhecimento de padrões supervisionada, a simples projeção dos dados não é garantia de uma boa discriminação. Faz-se necessário então, avaliar se tais resultados são confiáveis de fato e se reportam bem a realidade do problema. Um procedimento amplamente utilizado para tal confirmação é a aplicação da validação cruzada entre as três categorias.

A validação cruzada consiste em aplicar LDA a um grupo amostral restrito, chamado **grupo de treino**, e utilizar o resultado obtido para a projeção de outro grupo, chamado **grupo de teste**. De posse da projeção do grupo de teste computa-se, por proximidade, quais pontos pertencem

a cada grupo de treino. Por exemplo: se um melanoma do grupo de treino estiver próximo ao grupo dos melanomas, então é computado um acerto. Caso esse ponto esteja mais próximo de outro grupo, é computado erro.

Os critérios para se determinar os grupos de **treino** e de **teste** foram as seguintes: A partir das 143 imagens, seleciona-se uma porcentagem das imagens de cada uma das três categorias, estabelecendo-se assim o grupo de treino. O restante das imagens de cada grupo fará parte do grupo de teste. Sabendo que os resultados podem variar para cada validação, foram feitas 200 validações diferentes para cada caso, sorteando-se aleatoriamente os grupos e variando também a porcentagem do grupo de treino. Foram feitas 50 validações para cada valor: 60%, 65%, 70% e 75%. A Tabela 4.2 apresenta a média das validações cruzadas realizada entre as três classes, bem como os respectivos desvios padrões das médias.

Tabela 4.2 – Validação cruzada para as três categorias

	Melanoma	Nevo Regular	Nevo Atípico
Melanoma	25,02 ± 3,11	5,42 ± 2,49	2,56 ± 1,46
Nevo Regular	3,04 ± 2,04	7,93 ± 2,65	3,53 ± 1,79
Nevo Atípico	1,02 ± 1,06	5,15 ± 1,94	4,33 ± 1,72

Fonte: Elaborada pelo autor.

A seguir faremos uma breve explanação sobre a interpretação dessa matriz de confusão, que consequentemente valerá para as demais matrizes apresentadas na dissertação. Os grupos dispostos em linha representam as imagens do grupo de treino, enquanto que os grupos dispostos em colunas representam as imagens do grupo de teste. Logo, os elementos da diagonal principal da matriz de confusão — em notação matricial os elementos a_{11} , a_{22} e a_{33} — representam os acertos do teste. Os demais elementos da linha correspondem aos erros para determinado grupo. Por consequência, a soma de todos os elementos de uma linha representa o total de imagens testadas para determinado grupo. Logo, a porcentagem de acerto para um determinado grupo pode ser calculado por

$$\% \text{Acertos} = \frac{a_{jj}}{a_{j1} + a_{j2} + a_{j3}}$$

Sendo assim, a partir da tabela 4.2, podemos concluir que o total de melanomas testados corresponde a soma da primeira linha da matriz, ou seja: $25,02 + 5,42 + 2,56 = 33$. Desses 33

testes, em média 25,02 foram corretamente classificados, que representa 75,9% de acerto. Em contrapartida, $5,42 + 2,56 = 7,98$ foram erroneamente classificados e isso representa 24,1% do total. A mesma interpretação pode ser feita para os nevos regulares (dispostos na 2º linha) e para os nevos atípicos (dispostos na 3º linha). De maneira mais concisa, temos:

$$\frac{7,93}{3,04 + 7,93 + 3,53} = 54,7\%$$

ou seja, 54,7% de nevos regulares corretamente classificados e

$$\frac{4,33}{1,02 + 5,15 + 4,33} = 41,2\%$$

ou seja, 41,2% de nevos atípicos corretamente classificados.

Tabela 4.3 – Tabela contabilizando porcentagens de acertos e erros para a validação cruzada realizada com a base de dados de 143 imagens

	Acertos (%)	Erros (%)
Melanoma	75,9	24,1
Nevo Regular	54,7	45,3
Nevo Atípico	41,2	58,8

Fonte: Elaborada pelo autor.

Conforme verificamos nas tabelas 4.2 e na tabela 4.3, o método proposto é capaz de discriminar eficientemente melanoma das outras duas lesões melanocíticas, com porcentagem de acerto em torno de 75%. Esse resultado está de acordo com a proposta inicial do trabalho, na qual pressupõe que melanoma são, de fato, mais irregulares e assimétricos que outras lesões melanocíticas benignas, isso devido seu crescimento constante e randômico. Em contra partida, a diferenciação dos nevos atípicos e regulares mostrou-se fraca, com porcentagem de acertos relativamente baixa para ambas classes.

Com base no resultado obtido acima, é possível projetar a utilidade do método em diferenciar melanomas de outros tipos de nevos. Cabe então analisar qual a capacidade do algoritmo em fazer essa distinção simples entre melanomas e das demais patologias. Para tal, foi feita uma nova classificação entre a categoria Melanoma e a união dos grupos Nevo Regular e Nevo Atípico. O grupo formado pelos nevos benignos foi chamada de "Não Melanoma", por uma

simples questão de distinção. A figura 4.15 mostra a projeção LDA realizada para os grupos em questão.

Figura 4.15 – Projeção da transformação LDA realizada para as classes Melanoma e Não Melanoma).

Fonte: Elaborada pelo autor.

Da mesma maneira como foi feito para as três categorias, foi realizado a validação cruzada entre os grupos a partir da projeção LDA obtida. A tabela 4.4 mostra os resultados dessa validação.

Tabela 4.4 – Resultado da validação cruzada entre as classes.

	Melanoma	Não Melanoma
Melanoma	25,93 ± 4,56	8,4 ± 3,52
Não Melanoma	3,06 ± 2,26	13,56 ± 2,77

Fonte: Elaborada pelo autor.

Tomando nosso caso como exemplo, os melanoma corretamente classificados são os **verdadeiros positivos**, enquanto que os melanomas classificados de maneira incorreta são os **falsos positivos**. Analogamente, as lesões benignas corretamente classificadas são as **verdadeiros negativos**, enquanto que as imagens não melanomas classificados de maneira incorreta são os **falsos negativos**. Utilizando os dados apresentados na sessão 4.4, foram obtidos os seguintes resultados, dispostos na tabela 4.5

Tabela 4.5 – Medidas da matriz de confusão especificada para a categoria "Melanoma".

Métrica Estatística	Valor
Sensibilidade S	89,44%
Especificidade E	73,5%
Acurácia A	81,11%
Precisão P	75,53%

Fonte: Elaborada pelo autor.

Dentre todos estes resultados, merece destaque o valor da sensibilidade do teste, que trata a capacidade de identificar indivíduos com melanoma. Com 89,44% de sensibilidade, esse resultado está coerente com os principais resultados na área. (2, 63) Analisando trabalhos similares encontrados na literatura, observamos que os valores de sensibilidade estão na faixa de 80% à 96%, enquanto a especificidade varia entre 60% e 88%. Vale ressaltar que o presente trabalho foi baseado em imagens clínicas, sem nenhum tipo de escala ou qualquer outro tipo de padronização, o que reforça ainda mais sua validade, visto que os valores apresentados em trabalhos similares foram alcançados com imagens padronizadas. Além disso, a regra do ABCD para imagens clínicas reporta uma sensibilidade de 90% para dermatologistas e 55% para clínicos gerais. (64)

4.4.1 Considerações sobre o diâmetro de uma lesão

O tamanho de um lesão melanocítica, bem como suas medidas derivadas tais como perímetro, diâmetros maiores e menores e etc, são importantes atributos na sua identificação e correta discriminação. (4) De acordo com a regra do ABCD, lesões com diâmetro maior do que 6mm possuem chances de serem melanomas malignos. Conforme dito no início da seção de resultados, o tamanho da lesão não foi considerada no trabalho, devido à falta de padronização das imagens que compõem o banco de dados. Sendo assim, faz-se necessários analisarmos qual a influência da extensão real de uma lesão na discriminação do melanoma (para a presente base de dados estudada). Além disso, ao investigarmos a influência do tamanho da lesão, aumentamos a confiabilidade do processo proposto, tornando-o mais robusto.

Para tal, propomos nesta seção uma maneira de julgarmos a relevância do tamanho da lesão em comparação com os resultados do método proposto. Inicialmente foram coletadas fotografias de lesões melanocíticas com escala do nosso banco de dados. A figura 4.16 ilustra como as imagens se apresentam com a respectiva escala. A Tabela 4.6 mostra a quantidade de imagens utilizadas nessa etapa em comparação com o total.

Figura 4.16 – Imagem de uma lesão melanocítica com sua respectiva escala. A partir dessa fotografia, pode-se obter as reais dimensões da lesão.

Fonte: Elaborada pelo autor.

Tabela 4.6 – Disposição da quantidade de imagens usada em cada validação

	Melanoma	Nevo Regular	Nevo Atípico
Base de Dados	69	43	31
Com Escala	46	33	18

Fonte: Elaborada pelo autor.

De posse das imagem com escalas, é possível estimar valores reais dos atributos referentes ao tamanho da lesão. Estipulou-se as seguintes características à serem extraídas: Área, Perímetro, Diâmetro e Eixos Principais.

O procedimento para determinar os reais valores dos atributos de tamanho foi o seguinte: seleciona-se manualmente dois pontos (A e B) na escala da figura, sendo eles referentes à distância de 1 *cm*. Em seguida, calcula a distância entre os pontos A e B em unidades de *pixels* da própria figura. De posse dessas informações, efetua-se a conversão *Valor [pixel]* ↔

Valor $[cm/cm^2]$ de acordo com a seguinte relação:

$$D_{real} = \frac{D_{calculado}}{D_{padrão}} \times 1cm$$

onde D_{real} é o valor da métrica obtida em unidades $[cm]$, $D_{calculado}$ é o valor da métrica em unidades $[pixel]$ calculada na lesão e por fim $D_{padrão}$ é o valor padrão correspondente à $1cm$ em unidades $[pixel]$ para tal imagem. Os atributos **Perímetro**, **Maior Diâmetro** e **Eixos Principais** foram calculadas a partir dessa padronização. Para o calculo da **Área**, utilizou-se um sistema similar, com o cuidado de considerarmos valores bi-dimensionais. A relação utilizada para a conversão da métrica para $[cm^2]$ foi a seguinte:

$$D_{real} = \frac{D_{calculado}}{D_{padrão} \cdot D_{padrão}} \times 1cm^2$$

A seguir, apresentamos as análises dos atributos citados acima. Primeiramente, apresentamos as distribuições de valores de **Área** e **Perímetro** para cada classe de lesão na figura 4.17 suas respectivas densidades de distribuição na figura 4.18. As distribuições das demais características não foi apresentada pois os gráficos em questão se comportam de maneira análoga aos apresentados.

Figura 4.17 – Distribuição dos valores de Área e Perímetro para as categoriais Melanoma, Nevo Regular e Nevo Atípico.

Fonte: Elaborada pelo autor.

Figura 4.18 – Compilação da densidade de distribuição de valores entre as três categorias juntas.

Fonte: Elaborada pelo autor.

Pode-se notar na figura 4.18 que a classe dos melanomas possui uma distribuição diferenciada das demais classes. As imagens dessa categoria possuem um *range* maior distribuído do que as demais, o que implica que os tamanhos das lesões dessa categoria oscilam entre pequenos, médios e grandes. Essa análise reforça a projeção histopatológica da irregularidade dos melanomas. Já as categorias dos nevos benignos possuem maior parte de suas imagens em faixas de menores valores.

De posse dessas informações, cabe agora julgar qual a relevância da contribuição do tamanho das lesões na correta classificação dos grupos. Para tal, propomos duas diferentes validações com os atributos de dimensão. A primeira utilizando-se todos os dados, ou seja, atributos de assimetria e irregularidade de borda junto com as de tamanho, e a segunda apenas com atributos de tamanho. Além disso, faremos uma validação de controle utilizando as imagens com escala utilizando os atributos de borda. As validações propostas seguem os mesmos moldes das demais já realizadas no trabalho, ou seja, aplica-se LDA ao conjunto de dados e em seguida faz-se a validação cruzada. A seguir, descrevemos cada uma das validações e apresentamos seus respectivos resultados.

1º Validação Aplicação do LDA e validação dos resultados utilizando apenas atributos de ta-

manho. Pretende-se avaliar qual a contribuição das características de tamanho na discriminação entre as distintas categorias. Utilizou-se as 5 atributos de tamanho para o cálculo LDA.

Tabela 4.7 – Validação cruzada realizada com a transformação LDA utilizando atributos de dimensão

	Melanoma	Nevo Regular	Nevo Atípico	Acertos (%)
Melanoma	$12,41 \pm 3,97$	$4,16 \pm 2,01$	$> 0,01 \pm 0,07$	74,9
Nevo Regular	$2,39 \pm 1,46$	$9,66 \pm 3,22$	$> 0,01 \pm 0,07$	80,17
Nevo Atípico	$0,86 \pm 0,81$	$5,17 \pm 1,55$	0	0

Fonte: Elaborada pelo autor.

2º Validação Aplicação do LDA e validação dos resultados para todos os dados: atributos de tamanho, assimetria e irregularidade de borda. Pretende-se julgar qual a relação entre estas características na discriminação das lesões.

Tabela 4.8 – Validação realizada com a transformação LDA utilizando todos os atributos — dimensão, assimetria e irregularidade de borda

	Melanoma	Nevo Regular	Nevo Atípico	Acertos (%)
Melanoma	$12,13 \pm 3,96$	$2,79 \pm 1,86$	$1,95 \pm 1,54$	73,2
Nevo Regular	$3,48 \pm 2,11$	$5,89 \pm 2,52$	$2,68 \pm 1,84$	48,88
Nevo Atípico	$1,57 \pm 1,31$	$3,37 \pm 1,33$	$1,08 \pm 1,07$	20,4

Fonte: Elaborada pelo autor.

3º Validação Aplicação do LDA e validação dos resultados com os atributos de assimetria e irregularidade de borda. Pretende-se estabelecer um padrão para a análise, comparando as validações 1 e 2 com os atributos principais do trabalho.

Tabela 4.9 – Validação de comparação, feita com atributos de assimetria e irregularidade de borda

	Melanoma	Nevo Regular	Nevo Atípico	Acertos (%)
Melanoma	$11,62 \pm 3,85$	$3,01 \pm 1,93$	$1,94 \pm 1,47$	70,11
Nevo Regular	$3,31 \pm 1,77$	$5,98 \pm 2,6$	$2,76 \pm 1,95$	49,62
Nevo Atípico	$1,71 \pm 1,22$	$3,2 \pm 1,48$	$1,11 \pm 1,04$	18,44

Fonte: Elaborada pelo autor.

Os resultados apresentados nas tabelas de 4.7 à 4.9 nos permite algumas considerações. A primeira delas é a nulidade de classificação da tabela 4.7 para a categoria dos Nevos Atípicos e a alta porcentagem de acerto para as demais categorias. Uma explicação possível para esse fato é que o sistema pode ter interpretado ambas categorias de nevos como uma única classe. Tal fato é perfeitamente plausível, pois a análise dos histogramas dos atributos das figuras 4.17 e 4.18 mostra claramente uma distribuição diferenciada para os melanoma e semelhante para as demais. Além disso, há menos imagens na categoria Nevo Atípico, o que reforça essa hipótese de união de classes. Sendo assim, mais uma vez apresenta-se o argumento para a utilidade do presente método para a distinção robusta entre lesões malignas ou benignas.

Outra interessante consideração é a comparação entre os acertos das tabelas 4.8 e 4.9. Com resultados aproximadamente iguais (levando-se em conta o desvio padrão / erro gerado pelos cálculos), não há ganho de qualidade do processamento ao juntar todas as características. Isso nos leva a concluir que essas duas categorias de atributos possuem pesos semelhantes na triagem de uma lesão suspeita — o que reforça ainda mais a regra do ABCD. Em suma, pode apresentar resultados mais eficazes realizar não apenas uma validação com todos os atributos, mas sim duas classificações distintas, contabilizando o mesmo peso aos dois resultados.

Da mesma maneira como feito originalmente, podemos unir as categorias benignas em uma única e fazer a validação. Esse procedimento visar medir a capacidade dos atributos em discriminar lesões malignas e benignas. A seguir apresentamos na tabela 4.19 uma compilação de todos os resultados obtidos nesta sessão (com 96 imagens) com o resultado original (com 143 imagens).

Obviamente, a quantidade de imagens para aprendizado do sistema melhora a eficiência da classificação, visto que os maiores valores da sensibilidade e acurácia do método foram alcançados com o banco de imagem completo. As mesmas conclusões obtidas pelas tabelas 4.7 to 4.9 são mantidas para as medidas estatísticas, com valores próximos para as validações dos atributos de borda e de tamanho, sendo que não há ganho de classificação na junção das duas.

Figura 4.19 – Compilação dos valores sensibilidade, especificidade, acurácia e precisão para banco de imagens completo (143 imagens) em comparação com as três validações para imagens com escala (96 imagens).

Fonte: Elaborada pelo autor.

4.5 Avaliação de Desempenho

Os resultados do método proposto apresentaram porcentagens de acerto dentro do previsto para a regra do ABCD. Porém, apenas essa informação não é suficiente para medir a eficiência do método. Sendo assim, é importante avaliar o desempenho do presente sistema num teste clínico, ou seja, julgar sua capacidade de diagnóstico diante de uma lesão melanocítica suspeita e comparar com a avaliação das mesmas imagens feita por médicos.

Para tal, foi elaborado um teste com 20 imagens de lesões melanocíticas, das quais 10 eram melanomas malignos e 10 eram nevos regulares e atípicos. O teste foi aplicado a três clínicos gerais (médicos não especialistas) e a um dermatologista especialista em melanoma. Para o teste, os clínicos deveriam analisar cada uma das imagens, baseando-se em seus conhecimentos e experiência, e avaliá-las em **Melanoma** ou **Não Melanoma**. Além dos 4 médicos, nosso

sistema também avaliou cada uma das imagens, respondendo ao teste. Há de salientar que as imagens utilizadas no teste não pertenciam ao banco de imagens utilizado no projeto. O mesmo algoritmo utilizado no trabalho foi aplicado ao conjunto de imagens para a realização do teste. Isso garantiu a mesma qualidade na segmentação e no cálculo dos atributos. Utilizando os coeficientes do LDA obtidos da validação cruzada principal (ver 4.4), foi feita a classificação de cada uma das imagens do teste. A figura 4.20 mostra a porcentagem de acertos no teste para cada participante.

Figura 4.20 – Resultado da aplicação do teste clínico. A média dos resultados mostra que o sistema obteve a maior porcentagem de acerto, com 73,6%. Médicos especialistas obtiveram 61%, enquanto que os clínicos gerais obtiveram 50% de acerto.

Fonte: Elaborada pelo autor.

De posse dos testes aplicados, foi calculado o valor médio dos acertos para os participantes e os resultados estão dispostos na figura 4.20. Pode-se observar que o presente sistema obteve 73,6% de acerto, enquanto o clínico especialista obteve 61% e os não especialistas obtiveram 50%. Desses resultados, pode-se aferir ao sistema uma importante robustez, que obteve aproximadamente os mesmos 70% de acerto da validação cruzada principal do trabalho, porém utilizando-se imagens diferentes. Isso reforça mais uma vez a validade da análise de assimetria e irregularidade de borda ao se discriminar melanoma de outras lesões.

Contudo, apesar do sistema ter obtido maiores percentuais de acerto nesse teste em especí-

fico, certamente os clínicos poderiam ter resultados melhores se tivessem contato com a lesão *in situ*, pois outros fatores pesariam no diagnóstico, como maior resolução da imagem (que foi uma dificuldade para os participantes do teste), a localização da lesão no corpo e também o histórico familiar, todos esses fatores poderiam ser levados em conta no diagnóstico.

Outra conclusão interessante desse teste foram os baixos resultados obtidos por clínicos gerais com pouca ou nenhuma experiência. O resultado obtido foi de 50%, o que estatisticamente corresponde a escolhas randômicas das respostas. Esse resultado corresponde à valores inferiores ao mínimo de 55% referente à porcentagem mínima de acertos para a regra do ABCD, reportada na literatura. Sendo a regra do ABCD uma técnica de triagem *in situ*, valores inferiores à ela mostram que a qualidade do diagnóstico através de imagens feita por seres humanos é inferior do que o diagnóstico presencial.

Por fim, a tabela 4.10 traz detalhes dos resultados do teste realizado. Para fins de objetividade da análise, vamos comparar apenas os resultados do médico especialista e nosso sistema:

Tabela 4.10 – Resultado detalhado do teste clínico. Na tabela são especificados a quantidade de erros e acertos para as imagem presentes no teste.

	Melanoma			Não Melanoma		
	<i>Acertos</i>	<i>Erros</i>	<i>Não Analisadas</i>	<i>Acertos</i>	<i>Erros</i>	<i>Não Analisadas</i>
Especialista	8	-	2	-	5	5
Sistema	7	3	-	7	2	1
Clínico 1	5	5	-	6	4	-
Clínico 2	4	6	-	6	4	-
Clínico 3	4	6	-	5	5	-

Fonte: Elaborada pelo autor.

A análise destes dados revelam uma importante característica do diagnóstico clínico de lesões suspeitas: Médicos especialistas utilizam, além de sua experiência clínica, outras informações contidas na lesão, tais como a coloração, o diâmetro, além de outras informações que não remetem à regra do ABCD. Na falta dessas informações torna-se difícil o diagnóstico preciso. Há de se destacar, pela tabela 4.10, a identificação de 8 dos 10 melanomas pelo especialista, sendo que as outras duas imagens de melanomas restantes no teste não foram assinalados por falta de resolução. Em contrapartida, o sistema automático falhou em apenas 1 das 20 imagens

de todo teste e mesmo assim obteve resultados bastante consistentes quanto a classificação dos grupos, sendo 70% de acerto para melanomas e 77,8% para não melanomas.

As três últimas linhas da tabela 4.10 apresenta o resultado dos clínicos gerais. Constata-se certa homogeneidade nos valores, oscilando entre 50% a porcentagem de acertos. Esse resultado reflete a baixa experiência dos clínicos na análise das lesões e a dificuldade do diagnóstico realizado a partir da regra do ABCD aplicada a imagens. Sendo assim, uma possível contribuição que o sistema desenvolvido pode fornecer é o de auxiliar a população em geral e médicos com baixa ou nenhuma experiência no diagnóstico de melanomas, favorecendo-lhes uma segunda opinião na triagem de lesões melanocíticas suspeitas.

5 Conclusões e Trabalhos Futuros

Este trabalho propõe um método para discriminação entre lesões melanocíticas malignas (Melanoma Maligno) e benignas comuns, tais como Nevos Regulares e Nevos Atípicos. Como caso de estudo, aplicou-se tal método para uma base de dados de 143 imagens, obtidas de dois hospitais: A. C. Camargo, localizado em São Paulo e Amaral Carvalho, localizado em Jaú. Tais imagens foram obtidas de tratamentos realizados nestes hospitais, sendo que as imagens tinham caráter puramente documental, faltando padronização de luz e tamanho, o que por um lado dificultou o processamento e trouxe perda de qualidade, mas por outro lado forneceu robustez ao sistema, que o torna passível de aplicação em situações variadas. As técnicas de análise e processamento de imagens seguiram os moldes clássicos e consagrados na literatura, com técnicas reconhecidas e amplamente validadas. Baseando-se na regra do ABCD para imagens clínicas, e levando em conta a questão da falta de uniformidade entre as imagens, escolheu-se para o projeto a análise da assimetria e a irregularidade de borda como fator de discriminação entre as lesões. Foram extraídos 52 atributos de todas as imagens e a classificação final foi feita utilizando o *Linear Discriminant Analysis* (LDA) e a validação cruzada.

A segmentação das imagens foi feita através da limiarização pelo histograma, na qual obteve-se 92% de eficiência no processo. Conforme analisado, os resultados poderiam ter sido melhores com padronização de iluminação, visto que algumas imagens foram prejudicadas na segmentação por: iluminação não uniforme, falta de contraste e falta de resolução. Futuramente, problemas desta natureza poderão ser corrigidos através da transformação CIELab aplicada à imagem. Além do problema da luminosidade, alguns casos específicos não foram segmentados devido a falta de pigmentação da lesão.

A análise da distribuição dos valores dos atributos revelou que alguns são úteis na discriminação dos três grupos, como por exemplo a *sexta parte do histograma de curvatura*, pois sua

distribuição apresenta formas diferentes para cada classe. Além disso, outros atributos parecem úteis para discriminar o melanoma das demais classes, como por exemplo o *desvio padrão da curvatura* e a *dimensão fractal*, apresentando uma distribuição de valores diferenciada para o melanoma e semelhante para ambos nevus. Uma clara justificativa para esse resultado é o fato de que, pela sua própria fisiologia, os melanomas apresentam maior irregularidade e assimetria do que as demais lesões estudadas. Além desta análise, planeja-se posteriormente implementar outros métodos de seleção de atributos e mensurar a capacidade discriminatória de cada atributo.

Foi realizado o LDA para redução de dimensionalidade dos dados e posterior visualização, através da projeção das componentes principais obtidas. Desta projeção foi feita a validação cruzada, onde é possível mensurar o potencial de acertos para a projeção. A validação cruzada dos três grupos proporcionou resultados estáveis, com média de 76% de acerto para os melanomas, 51,7% e 41,2% para nevus regulares e atípicos, respectivamente. A interpretação destes dados revela que o método é relativamente eficiente na discriminação dos melanomas, porém perde informação na interpretação das lesões benignas, o que sugere uma possível aplicação do método na segregação de lesões de maneira mais geral, separando melanomas de lesões benignas. Essa hipótese foi testada unindo-se as classes Nevo Regular e Nevo Atípico num único grupo e fazendo a mesma validação dos dados. Esse experimento revelou resultados expressivos, com sensibilidade de 89,44% e especificidade de 73,5%.

Outro importante resultado foi a análise da influência do tamanho da lesão em comparação com o método proposto. Conforme sua fisiologia, melanomas possuem características irregulares e assimétricas em sua forma pelo mesmo motivo o qual são maiores que a maioria das lesões benignas. Buscou-se uma maneira de quantificar e comparar a presença dessa informação nos resultados finais. Dentro do banco de dados, cerca de 75% das imagens possuíam uma escala, o que permitiu o cálculo de atributos tais como área, perímetro e outras. Os resultados desta análise mostraram que ambos atributos, de irregularidade de borda / assimetria e tamanho contribuem de maneira similar na classificação das lesões. Além disso, conclui-se também que a qualidade da classificação do presente método independe de uma escala na imagem, visto que o

acréscimo dos descritores de tamanho não melhora a sensibilidade. Contudo, as informações a respeito da dimensão da lesão são tão importantes quanto os atributos de borda e irregularidade. Sendo assim, abre-se um precedente para o uso de ambas informações de maneira cooperativa, ou seja, fazendo validações separadas e utilizando-se ambas informações para o diagnóstico final. Também é possível concluir que a quantidade de imagens do banco de dados é um fator que pode melhorar os resultados finais da classificação, além de conferir ao sistema maior credibilidade. Pretende-se ampliar o banco de dados utilizado atualmente através de parcerias com centros de tratamento de câncer. Casos registrados e posteriormente confirmados pela biópsia poderiam ser acrescentadas ao escopo de imagens do protótipo, que traria em pouco tempo um aumento no banco de dados e maior precisão ao sistema.

A fim de julgar a relevância dos resultados, foi aplicado um teste a quatro médicos, sendo três clínicos gerais e um dermatologista especialista em melanoma. O teste consistia em analisar fotografias de lesões melanocíticas e classificá-las em maligna ou benigna. Os resultados deste teste mostram uniformidade dos resultados para o método desenvolvido, com acertos na faixa dos 70%, o que parece interessante, visto que as imagens do teste não pertenciam ao banco de dados utilizado no desenvolvimento do trabalho. A conclusão mais significativa desse teste foi a possibilidade de auxílio à médicos não especialistas no diagnóstico de lesões suspeitas, visto que os mesmos obtiveram índice de acerto mínimo. Outro emprego em potencial do método seria instaurá-lo hospitais que recebem um grande número de pacientes e não possuem especialistas fixos. Há uma prática comum nestes hospitais, que é o de registrar os casos que aparecem através de fotografias para posterior análise do especialista. Nesse viés, o método poderia dar um primeiro diagnóstico, otimizando as ações de enfermeiros e especialistas no tratamento adequado.

REFERÊNCIAS

- 1 BRASIL. Ministério da Saude. Instituto Nacional do Câncer. Incidência de Câncer no Brasil. 2014. Disponível em: <www.inca.gov.br/estimativa/2014/estimativa-24042014.pdf>. Acesso em: 15 fev. 2015.
- 2 RIGEL, D. S.; RUSSAK, J.; FRIEDMAN, R. The evolution of melanoma diagnosis: 25 years beyond the abcds. *CA: a cancer journal for clinicians*, v. 60, n. 5, p. 301–316, 2010.
- 3 BANDARCHI, B. et al. From melanocyte to metastatic malignant melanoma. *Dermatology Research and Practice*, v. 2010, 2010. doi: 10.1155/2010/583748.
- 4 FRIEDMAN, R. J.; RIGEL, D. S.; KOPF, A. W. Early detection of malignant melanoma: The role of physician examination and self-examination of the skin. *CA: a cancer journal for clinicians*, v. 35, n. 3, p. 130-151, 1985.
- 5 LEE, C. et al. Historical review of melanoma treatment and outcomes. *Clinics in Dermatology*, v. 31, n. 2, p. 141–147, 2013.
- 6 SOBER, A. J.; BURSTEIN, J. M. Computerized digital image analysis: an aid for melanoma diagnosis—preliminary investigations and brief review. *The Journal of Dermatology*, v. 21, n. 11, p. 885–890, 1994.
- 7 MOREIRA, R. R.; FRIEDMAN, H. Dermatoscopia: conceitos básicos e importância no diagnóstico de lesões pigmentadas. *Anais Brasileiros de Dermatologia*, v. 71, n. 1, p. 51–57, 1996.
- 8 MICALI, G.; LACARRUBBA, F. Possible applications of videodermatoscopy beyond pigmented lesions. *International Journal of Dermatology*, v. 42, n. 6, p. 430–433, 2003.
- 9 MAYER, J. Systematic review of the diagnostic accuracy of dermatoscopy in detecting malignant melanoma. *The Medical Journal of Australia*, v. 167, n. 4, p. 206–210, 1997.
- 10 DERMATOSCOPY. 2015. Disponível em: <<http://en.wikipedia.org/wiki/Dermatoscopy>>. Acesso em: 15 fev. 2015.
- 11 PELLACANI, G. et al. The impact of in vivo reflectance confocal microscopy for the diagnostic accuracy of melanoma and equivocal melanocytic lesions. *Journal of Investigative Dermatology*, v. 127, n. 12, p. 2759–2765, 2007.

- 12 ANDRADE, C. et al. Identification of skin lesions through aminolaevulinic acid-mediated photodynamic detection. *Photodiagnosis and Photodynamic Therapy*, v. 11, n. 3, p. 409–415, 2014.
- 13 PANFILO, B. M. L. *Técnicas de imagem para triagem de melanoma*. 2012. 69 p. Dissertação (Mestrado) — Faculdade de Medicina, Universidade Estadual Paulista "Júlio de Mesquita Filho", Botucatu, 2012.
- 14 MÉDICOS acompanham concentração de outros profissionais e de estabelecimentos de saúde. In: SCHEFFER, M. (Ed.). *Demografia médica no Brasil: cenários e indicadores de distribuição*. São Paulo: CFM, CREMESP, 2012. v. 2, p. 109–124.
- 15 COLOT, O. et al. A colour image processing method for melanoma detection. In: WELLS, W. M.; COLCHESTER, A.; DELP, S. (Ed.) *MEDICAL IMAGE COMPUTING AND COMPUTER-ASSISTED INTERVENTATION — MICCAI'98*. 1998, Cambridge. *Proceedings...* Cambridge: Springer, 1998. p. 562–569.
- 16 SCHAEFER, G. et al. Colour and contrast enhancement for improved skin lesion segmentation. *Computerized Medical Imaging and Graphics*, v. 35, n. 2, p. 99–104, 2011.
- 17 ABBAS, Q.; CELEBI, M. E.; FONDÓN, I. Computer-aided pattern classification system for dermoscopy images. *Skin Research and Technology*, v. 18, n. 3, p. 278–289, 2012.
- 18 ERCAL, F. et al. Neural network diagnosis of malignant melanoma from color images. *IEEE Transactions on Biomedical Engineering*, v. 41, n. 9, p. 837–845, 1994.
- 19 LEANDER, R. et al. Differentiation of melanoma from benign mimics using the relative-color method. *Skin Research and Technology*, v. 16, n. 3, p. 297–304, 2010.
- 20 STOECKER, W. V. et al. Detection of granularity in dermoscopy images of malignant melanoma using color and texture features. *Computerized Medical Imaging and Graphics*, v. 35, n. 2, p. 144–147, 2011.
- 21 GARNAVI, R.; ALDEEN, M.; BAILEY, J. Computer-aided diagnosis of melanoma using border-and wavelet-based texture analysis. *IEEE Transactions on Information Technology in Biomedicine*, v. 16, n. 6, p. 1239–1252, 2012.
- 22 ERKOL, B. et al. Automatic lesion boundary detection in dermoscopy images using gradient vector flow snakes. *Skin Research and Technology*, v. 11, n. 1, p. 17–26, 2005.
- 23 CELEBI, M. E. et al. Lesion border detection in dermoscopy images. *Computerized Medical Imaging and Graphics*, v. 33, n. 2, p. 148–153, 2009.
- 24 ABBAS, Q.; CELEBI, M.; GARCÍA, I. F. Hair removal methods: a comparative study for dermoscopy images. *Biomedical Signal Processing and Control*, v. 6, n. 4, p. 395–404, 2011.

- 25 BUXTON, P. K.; MORRIS-JONES, R. *ABC of dermatology*. Hoboken, N.J.: John Wiley & Sons, 2013.
- 26 NATIONAL CANCER INSTITUTE. *Melanoma treatment*. Disponível em: <<http://www.cancer.gov/cancertopics/pdq/treatment/melanoma/Patient/page1>>. Acesso em: 30 dez. 2014.
- 27 BURNS, T. et al. *Rook's textbook of dermatology*. Hoboken, N.J.: John Wiley & Sons, 2010. 4 v.
- 28 HABIF, T. P. *Dermatologia clínica: guia colorido para diagnóstico e tratamento*. Rio de Janeiro: Elsevier, 2012.
- 29 INTRO PIGMENT DISORDERS. Disponível em: <<http://quizlet.com/4581778/intro-pigment-disorders-flash-cards/>>. Acesso em: 30 dez. 2014.
- 30 ELDER, D. E. The dysplastic nevus. *Pathology*, v. 17, n. 2, p. 291–297, 1985.
- 31 ARUMI-URIA, M. Dysplastic nevus: the eye of the hurricane. *Journal of Cutaneous Pathology*, v. 35, n. s2, p. 16–19, 2008.
- 32 ANNESSI, G. et al. Correlation between clinical atypia and histologic dysplasia in acquired melanocytic nevi. *Journal of the American Academy of Dermatology*, v. 45, n. 1, p. 77–85, 2001.
- 33 REZZE, G. G.; LEON, A.; DUPRAT, J. A. Nevo displásico (nevo atípico). *Anais Brasileiros de Dermatologia*, v. 85, p. 863 – 871, 2010.
- 34 BALCH, C. M. et al. Final version of the american joint committee on cancer staging system for cutaneous melanoma. *Journal of Clinical Oncology*, v. 19, n. 16, p. 3635–3648, 2001.
- 35 MELANOMA. Disponível em: <<http://en.wikipedia.org/wiki/Melanoma>>. Acesso em: 30 dez. 2014.
- 36 NATIONAL CANCER INSTITUTE. *Asymmetrical melanoma*. Disponível em: <<https://visuals.nci.nih.gov/details.cfm?imageid=2362>>. Acesso em: 30 dez. 2014.
- 37 NATIONAL CANCER INSTITUTE. *Melanoma with uneven border*. Disponível em: <<https://visuals.nci.nih.gov/details.cfm?imageid=2363>>. Acesso em: 30 dez. 2014.
- 38 NATIONAL CANCER INSTITUTE. *Melanoma with color differences*. Disponível em: <<https://visuals.nci.nih.gov/details.cfm?imageid=2364>>. Acesso em: 30 dez. 2014.

- 39 NATIONAL CANCER INSTITUTE. *Melanoma with diameter change*. Disponível em: <<https://visuals.nci.nih.gov/details.cfm?imageid=2365>>. Acesso em: 30 dez. 2014.
- 40 MARQUES FILHO, O.; VIEIRA NETO, H. *Processamento digital de imagens*. Rio de Janeiro: Brasport, 1999.
- 41 MOESLUND, T. B. *Introduction to video and image processing: building real systems and applications*. New York: Springer, 2012.
- 42 MCANDREW, A. *An introduction to digital image processing with matlab notes for scm2511 image processing*. 2004. 229 p. Disponível em: <http://share.its.ac.id/pluginfile.php/371/mod_resource/content/1/An_Introduction_To_Digital_Image_Processing_With_Matlab.pdf>. Acesso em: 28 set. 2014.
- 43 SOLOMON, C.; BRECKON, T. *Fundamentals of digital image processing: a practical approach with examples in Matlab*. Hoboken, NJ: John Wiley & Sons, 2011. 63–64 p.
- 44 JENSEN, J. R. et al. *Introductory digital image processing: a remote sensing perspective*. Upper Saddle River, N.J: Prentice-Hall Inc., 1996.
- 45 JÄHNE, B. *Digital image processing*. New York: Springer, 2002.
- 46 COSTA, L. F.; CESAR JUNIOR, R. M. *Shape analysis and classification:: theory and practice*. Boca Raton: CRC Press, Inc., 2008.
- 47 PAL, N. R.; PAL, S. K. A review on image segmentation techniques. *Pattern Recognition*, v. 26, p. 1277–1294, 1993.
- 48 DOUGHERTY, E. R.; LOTUFO, R. A. *Hands-on morphological image processing*. Bellingham: SPIE Press, 2003.
- 49 SOILLE, P. *Morphological image analysis: principles and applications*. New York: Springer-Verlag, 2003.
- 50 FREEMAN, H.; SHAPIRA, R. Determining the minimum-area encasing rectangle for an arbitrary closed curve. *Communications of the ACM*, v. 18, p. 409–413, 1975.
- 51 DEMI, M.; PATERNI, M.; BENASSI, A. The first absolute central moment in low-level image processing. *Computer Vision and Image Understanding*, v. 80, p. 57–87, 2000.
- 52 TUCERYAN, M. Moment-based texture segmentation. *Pattern Recognition Letters*, v. 15, p. 659–668, 1994. Disponível em: <<http://cs.iupui.edu/~tuceryan/research/ComputerVision/moment-paper.pdf>>. Acesso em: 20 maio 2015.

- 53 HU, M.-K. Visual pattern recognition by moment invariants. *IRE Transactions on Information Theory*, v. 8, p. 179–187, 1962.
- 54 STEWART, J. *Multivariable calculus*. Belmont, CA: Cengage Learning, 2011.
- 55 PAPOULIS, A. *The Fourier integral and its applications*. New York: McGraw-Hill, 1962.
- 56 BRACEWELL, R. N.; BRACEWELL, R. *The Fourier transform and its applications*. New York: McGraw-Hill, 1986. 115 p.
- 57 RUSS, J. C. *The Image processing handbook*. New York: CRC Press, 2010.
- 58 GONZALEZ, R. C.; WOODS, R. E. *Digital image processing*. Upper Saddle River, N.J.: Prentice Hall, 2002.
- 59 TENENHAUS, A. et al. Detection of melanoma from dermoscopic images of naevi acquired under uncontrolled conditions. *Skin Research and Technology*, v. 16, p. 85–97, 2010.
- 60 WIGHTON, P. et al. Conditional random fields and supervised learning in automated skin lesion diagnosis. *Journal of Biomedical Imaging*, v. 2011. doi: 10.1155/2011/846312, year=2011.
- 61 DUDA, R. O.; HART, P. E.; STORK, D. G. *Pattern classification*. New York: John Wiley & Sons, 2012.
- 62 FAWCETT, T. An introduction to roc analysis. *Pattern Recognition Letters*, v. 27, n. 8, p. 861–874, 2006.
- 63 DAY, G. R.; BARBOUR, R. H. Automated melanoma diagnosis: where are we at? *Skin Research and Technology*, v. 6, n. 1, p. 1–5, 2000.
- 64 GRIN, C. M. et al. Accuracy in the clinical diagnosis of malignant melanoma. *Archives of Dermatology*, v. 126, n. 6, p. 763–766, 1990.

APÊNDICE A – Distribuição dos valores das métricas

Figura A.1 – Distribuição das Métricas ($\mathcal{M}_0 \rightarrow \mathcal{M}_5$)

Fonte: Elaborada pelo autor.

Figura A.2 – Distribuição das Métricas ($\mathcal{M}_6 \rightarrow \mathcal{M}_{11}$)

Fonte: Elaborada pelo autor.

Figura A.3 – Distribuição das Métricas ($\mathcal{M}_{12} \rightarrow \mathcal{M}_{17}$)

Fonte: Elaborada pelo autor.

Figura A.4 – Distribuição das Métricas ($\mathcal{M}_{18} \rightarrow \mathcal{M}_{23}$)

Fonte: Elaborada pelo autor.

Figura A.5 – Distribuição das Métricas ($\mathcal{M}_{24} \rightarrow \mathcal{M}_{29}$)

Fonte: Elaborada pelo autor.

Figura A.6 – Distribuição das Métricas ($\mathcal{M}_{30} \rightarrow \mathcal{M}_{35}$)

Fonte: Elaborada pelo autor.

Figura A.7 – Distribuição das Métricas ($\mathcal{M}_{36} \rightarrow \mathcal{M}_{41}$)

Fonte: Elaborada pelo autor.

Figura A.8 – Distribuição das Métricas ($\mathcal{M}_{42} \rightarrow \mathcal{M}_{47}$)

Fonte: Elaborada pelo autor.

Figura A.9 – Distribuição das Métricas ($\mathcal{M}_{48} \rightarrow \mathcal{M}_{51}$)

Fonte: Elaborada pelo autor.