



INSTITUTO SUPERIOR TÉCNICO
Universidade Técnica de Lisboa

Sistema Automático para Diagnóstico de Lesões Cutâneas Baseado em Imagens Dermoscópicas

Luís Filipe Caeiro Margalho Guerra Rosado

Dissertação para obtenção do Grau de Mestre em

Engenharia Biomédica

Júri

Presidente: Prof. Patrícia Figueiredo
Orientadores: Prof. Jorge Marques
Prof. Paulo Filipe
Prof. Teresa Mendonça
Vogal: Prof. Maria Margarida Silveira

Outubro de 2009

Agradecimentos

Este trabalho fecha um ciclo de cinco anos da minha vida, e portanto quero aproveitar esta oportunidade para agradecer a todos aqueles que me ajudaram não só na elaboração deste trabalho mas também durante todo este percurso através do seu apoio, disponibilidade e amizade.

Em primeiro lugar quero agradecer ao Professor Jorge Salvador Marques por me ter dado a oportunidade de desenvolver este trabalho. Estarei sempre grato pela inesgotável dedicação com que empregou o seu conhecimento, supervisão e incentivo em todas as etapas deste trabalho, sem excepção.

Ao Dr. Paulo Filipe, que prontamente se disponibilizou para co-orientar esta tese. A sua contribuição na classificação das lesões cutâneas foi essencial para a criação do sistema implementado. Também essencial foi a contribuição já numa fase final da Dra. Joana Antunes, que apesar do curto espaço de tempo disponível se empenhou na criação deste modelo.

À Professora Teresa Mendonça, também co-orientadora deste trabalho, por ter sido um dos elementos impulsionadores do desafio proposto nesta tese, e ao Doutor José Rozeira por ter facultado as imagens dermoscópicas utilizadas neste estudo.

A todos os meus amigos e colegas, por todos os bons momentos que partilhámos juntos durante estes anos. Foi com a vossa amizade que cresci e aprendi a ser uma pessoa melhor.

E como os últimos são sempre os primeiros, o maior agradecimento vai para a minha família, em especial para os meus pais, Joaquim e Margarida, que sempre deram tudo por mim e sem o seu apoio nada disto teria sido possível. Um agradecimento especial também para a minha irmã Célia, com a qual eu sei que posso sempre contar.

Abstract

This work aims to develop a prototype capable of segmenting skin lesions in dermoscopy images and classify them based on visual characteristics, particularly in detecting melanomas and separate them from other lesions. This work took as starting point the ABCD rule, which is based on 4 visual features, and for which was developed algorithms to detect and quantify them.

This work is divided into three distinct stages: 1) Segmentation: implementation of a segmentation algorithm of dermoscopy images in order to determine the border of the lesion, based on the analysis of the peaks and valleys of the histogram. 2) Feature extraction: definition of the features to use (asymmetry, color, border and differential structures) and development of routines for their automatic detection. 3) Classification: development of methods for automatic classification of dermoscopic images. The images were classified through a supervised method (classification is made taking into account the image analysis by a specialist), using a thresholding method, a k-nearest neighbors classifier and a Support Vector Machines classification.

The prototype was implemented in MATLAB, and was used a database of 68 dermoscopic images, courtesy of Dr. Jorge Rozeira of Hospital Pedro Hispano.

Keywords: Dermoscopy, ABCD rule, Segmentation, Feature extraction, Classification.

Resumo

Com este trabalho pretendeu-se desenvolver um protótipo capaz de segmentar lesões cutâneas em imagens dermoscópicas e classificá-las com base em características visuais, em particular detectar melanomas e separá-los das restantes lesões. Tomou-se como ponto de partida a regra ABCD, a qual se baseia na utilização de 4 características visuais, e para as quais se desenvolveram algoritmos de detecção e quantificação.

Este trabalho está dividido em três etapas distintas: 1) Segmentação: implementação de um algoritmo de segmentação de imagens dermoscópicas com vista à determinação da fronteira da lesão, com base na análise dos picos e vales do histograma da imagem. 2) Características: definição das características a utilizar (assimetria, cor, fronteira e estruturas diferenciais) e desenvolvimento de rotinas para o cálculo automático destas características. 3) Classificação: desenvolvimento de métodos de classificação automático de imagens dermoscópicas. Nesta etapa optou-se por classificar as imagens através de um método supervisionado (a classificação é feita tendo em conta a análise das imagens por parte de um especialista), com recurso a um método de limiarização, um classificador de k-vizinhos mais próximos e uma classificação através de máquinas de vectores de suporte.

O protótipo foi implementado em MATLAB, tendo sido utilizada uma base de dados de 68 imagens dermoscópicas gentilmente cedidas pelo Dr. Jorge Rozeira do Hospital Pedro Hispano.

Palavras-Chave: Dermoscopia; Regra ABCD; Segmentação; Extração de características; Classificação.

Índice

Agradecimentos	i
Abstract	ii
Resumo	iii
Índice	iv
Lista de Figuras.....	vi
Lista de Tabelas.....	viii
Lista de Abreviações.....	ix
1. Introdução	1
1.1 Motivação.....	1
1.2 Objectivos.....	2
1.3 Conjunto de Imagens.....	2
1.4 Estrutura da Tese.....	3
1.5 Contribuições da Tese	4
2. Algoritmos de Diagnóstico	5
2.1 Método de Análise de Padrões.....	5
2.2 Regra ABCD.....	5
2.2.1 Assimetria.....	6
2.2.2 Fronteira	7
2.2.3 Cor.....	7
2.2.4 Estruturas Diferenciais	8
2.3 Método dos 7 Pontos	9
2.3.1 Rede Atípica Pigmentada	10
2.3.2 Véu Azul-Esbranquiçado.....	10
2.3.3 Padrão Vasculoso Atípico.....	10
2.3.4 Estrias Irregulares	11
2.3.5 Pontos e Glóbulos Irregulares.....	11
2.3.6 Pigmentação Irregular	11
2.4 A Evolução dos Sistemas Automáticos de Diagnóstico de Melanoma.....	12
3. Extração das Características	14
3.1 Descrição da notação utilizada	14
3.2 Pré-processamento	14
3.2.1 Conversão para Imagem Monocromática.....	14
3.2.2 Filtragem	15
3.3 Segmentação	17

3.4	Assimetria.....	23
3.4.1	Centróide.....	23
3.4.2	Momento Geométrico.....	23
3.4.3	Momento Central.....	24
3.4.4	Orientação da Imagem.....	24
3.4.5	Rácios de Assimetria	25
3.5	Fronteira.....	26
3.5.1	Rácio de Média e Rácio de Desvio Padrão	28
3.6	Cor.....	29
3.7	Estruturas Diferenciais.....	31
3.7.1	Análise da Textura	31
3.7.2	Análise Estrutural	32
3.7.3	Rácio de área e Desvio Padrão das Intensidades.....	33
4.	Classificação.....	35
4.1	Classificação de Dados.....	35
4.1.1	Classificador de Bayes.....	35
4.1.2	Aprendizagem utilizando um Conjunto de Treino.....	35
4.2	Classificador K-Vizinhos Mais Próximos.....	36
4.2.1	Normalização	37
4.2.2	Cálculo de K.....	37
4.3	Máquinas de Vectores de Suporte.....	37
4.4	O Modelo de Classificação Proposto.....	39
5.	Resultados e Discussão	41
5.1	Segmentação	41
5.1.1	Discussão dos Resultados obtidos para a Segmentação	42
5.2	Extracção de Características	44
5.2.1	Assimetria.....	46
5.2.2	Fronteira.....	49
5.2.3	Cor.....	51
5.2.4	Estruturas Diferenciais.....	53
5.3	Classificação Final das Lesões.....	56
5.3.1	Discussão dos Resultados obtidos na Classificação Final.....	59
6.	Conclusões e Trabalhos Futuros.....	61
	Referências.....	63
	Apêndices.....	65

Lista de Figuras

Figura 1 – Exemplos de imagens suprimidas do estudo por: (a) a lesão não está inteiramente contida no espaço da imagem; (b) a presença de demasiado pêlo; (c) contraste insuficiente entre a lesão e a pele circundante.

Figura 2 – Lesão cutânea completamente simétrica (a); assimétrica num dos eixos (b); assimétrica em ambos os eixos (c) [8].

Figura 3 – Lesão cutânea (a): sem demarcações abruptas na fronteira de qualquer segmento (pontuação 0); (b): com demarcações abruptas em 3 segmentos, marcados com * (pontuação = 3) [8].

Figura 4 – Lesão cutânea com áreas homogêneas ou sem estruturas, estrias, pontos e glóbulos (pontuação = 4) [8].

Figura 5– Análise da lesão cutânea utilizando o Método dos 7 Pontos (pontuação=7) [8].

Figura 6 – Melanomas com: rede atípica pigmentada (a); véu azul-esbranquiçado (b) e padrão vascular atípico em torno da fronteira do melanoma - indicado pelas setas (c) [8].

Figura 7– Melanomas com: estrias irregulares (a); pontos e glóbulos irregulares (b); pigmentação irregular (c) e estruturas de regressão (d) [8].

Figura 8 – Imagem original (a) e respectivos componentes R (b), G (c) e B (d) em escala de cinzentos.

Figura 9 – Imagem original (a) e imagem após aplicação do filtro mediana (b).

Figura 10 – Imagem em escala de cinzentos (a), e respectivo histograma (b).

Figura 11 – Imagem original (a); máscara obtida após a aplicação o limiar (b) e máscaras obtidas através da aplicação da operação morfológica de fecho: uma operação de dilatação (c) seguida de uma operação de erosão (d).

Figura 12 – Resultado da segmentação do conjunto de imagens em estudo.

Figura 13 – Resultado da rotação da imagem original (a) de forma a alinhar os eixos principais (a azul, com intercepção no centróide da imagem) com os eixos da imagem (b), bem como a respectiva máscara em formato binário (c) e em escala de cinzentos (d).

Figura 14– Imagens originais (a, c) e respectivas máscaras das suas fronteiras (a amarelo), zonas periféricas interiores e zonas periféricas exteriores (b, d).

Figura 15 – Zona periférica interior e exterior da lesão da figura 14.a dividida em 8 segmentos iguais.

Figura 16 – Imagem original (a) e respectivas máscaras, em que o algoritmo detectou as seguintes cores: castanho-escuro (b); castanho-claro (c) e preto (d).

Figura 17– Diagrama de blocos do algoritmo de detecção das estruturas diferenciais.

Figura 18 – Imagens original (a) e respectiva: máscara de entropia (b); máscara das descontinuidades locais (c) e máscara das suas estruturas diferenciais (d).

Figura 19 – Exemplo de classificação segundo o método kNN. O objecto a classificar (círculo verde) será classificado como pertencente à classe dos quadrados azuis caso $K=1$ e classificado como pertencente à classe dos triângulos vermelhos caso $K=3$.

Figura 20– Classificação de duas classes linearmente separáveis (a) e não linearmente separáveis (b) [22].

Figura 21 – Diagrama de blocos do modelo de classificação de lesões cutâneas proposto neste trabalho.

Figura 22 – Exemplos de resultados de segmentação: com sucesso (a, b); e sem sucesso (c, d).

Figura 23 – Classificação da assimetria: Dispersão dos parâmetros A_1 e A_2 para o caso binário (a) e para a imagem em escala de cinzentos (b), com $k=3$ (“O” - classe 0; “*” - classe 1; e “+” classe 2).

Figura 24– Exemplos de resultados da classificação da assimetria: com sucesso (a, b); e sem sucesso (c, d).

Figura 25– Exemplos de resultados da classificação da fronteira: com sucesso (a, b); e sem sucesso (c,d).

Figura 26 – Exemplos de resultados da análise de cor: com sucesso (a, b); e sem sucesso (c, d).

Figura 27- Classificação de estruturas diferenciais: Dispersão dos parâmetros R_a e R_i para $k=5$.

Figura 28- Exemplos de detecção de estruturas diferenciais pelo algoritmo implementado.

Figura 29 – Exemplos de resultados de estruturas diferenciais: com sucesso (**a, b**); e sem sucesso (**c,d**).

Figura 30 – Valores PDT calculados a partir das pontuações dadas por um especialista segundo a regra ABCD.

Figura 31- Valores PDT calculados a partir das pontuações obtidas pelo sistema automático proposto.

Lista de Tabelas

Tabela 1 - Resumo dos vários métodos de análise de imagens dermoscópicas referido neste trabalho.

Tabela 2 - Cores que pretendemos detectar, e respectivos códigos RGB.

Tabela 3 - Funções de Kernel mais comuns [21].

Tabela 4 - Média e Variância obtidos para a métrica de Hammoude.

Tabela 5 - Comparação dos resultados obtidos com outros métodos [12] segundo a métrica de Hammoude.

Tabela 6 - Classificação da assimetria: Matrizes de confusão e respectivas probabilidades de erro

Tabela 7 - Classificação da fronteira: Matrizes de confusão e respectivas probabilidades de erro

Tabela 8 - Classificação da cor: Matrizes de confusão e respectivas probabilidades de erro

Tabela 9 - Classificação das estruturas diferenciais: Matrizes de confusão e respectivas probabilidades de erro

Tabela 10 - Matrizes de confusão e respectivas probabilidades de erro para cada um dos classificadores utilizados na classificação final.

Tabela 11 - Resumo dos resultados obtidos na classificação final.

Lista de Abreviações

MAP	Método de Análise de Padrões
PDT	Pontuação Dermoscópica Total
kNN	K vizinhos mais próximos
SE	Sensibilidade
SP	Especificidade
TDE	Transformada de Distância Euclidiana
IA	Inteligência Artificial
AM	Aprendizagem de Máquina
LOO	Leave-one-out
SVM	Máquinas de Vectores de Suporte

1. Introdução

1.1 Motivação

O cancro cutâneo é um dos tipos de cancro com maior crescimento nos últimos anos. Este tipo de cancro corresponde anualmente a cerca de um terço da totalidade dos cancros detectados em Portugal, afectando uma em cada 7 pessoas ao longo da vida. Estima-se que o Melanoma Maligno, neoplasia que cresce nos melanócitos (as células responsáveis pela pigmentação), corresponde apenas a 8% dos cancros da pele detectados em Portugal, sendo no entanto responsável por mais de 70% das mortes, valor que triplicou desde 1980. Segundo o Instituto de Oncologia, a taxa de incidência no nosso país está estimada em 8 casos por 100.000 habitantes/ano, o que dá cerca de 800 novos casos por ano [1].

Apesar da acentuada mortalidade do Melanoma Maligno, o diagnóstico precoce da doença desempenha um papel essencial na diminuição destes números, já que a percentagem de sucesso na cura deste tipo de cancros é bastante elevada caso este seja detectado durante as etapas iniciais do seu desenvolvimento (podendo passar por uma simples excisão do tumor). Por exemplo, pacientes com um melanoma de 0.75mm ou menos de espessura têm uma taxa de sobrevivência aos cinco anos superior a 93% [2].

Com a crescente necessidade de encontrar métodos auxiliares para avaliar lesões cutâneas pigmentadas, vários métodos foram criados, sendo um dos mais eficazes a dermoscopia. A dermoscopia, também denominada dermatoscopia, microscopia de superfície cutânea, microscopia epiluminescente ou ELM, foi uma técnica introduzida em 1987 por Soyer *et al.* [3], e trata-se de um método não invasivo, de uso *in vivo*, que promove a magnificação da imagem da pele de tal forma que permite o reconhecimento de estruturas morfológicas não visíveis a olho nu. A técnica para a realização da dermoscopia consiste na utilização de instrumentação óptica, em que as amplificações desses instrumentos podem ir de 6x até 100x. Na prática médica, o aparelho mais utilizado é o dermatoscópio, através do qual é emitido um feixe luminoso por uma luz halogénea que incide na superfície cutânea, na qual previamente se colocou um fluído (óleo, água, gel, etc.) a fim de reduzir a reflexão da luz. Desta forma a luz penetra na pele mais eficazmente e conseqüentemente permite uma melhor visualização das estruturas pigmentadas nas diferentes camadas da pele, adquirindo-se desta forma imagens com um factor de resolução de até 10x. Vários estudos foram realizados para determinar a precisão da dermoscopia no diagnóstico de lesões cutâneas, sendo que um deles revelou que o recurso à dermoscopia, em conjugação com a análise clínica e historial do paciente resulta num aumento de 50% na precisão do diagnóstico [4].

A dermoscopia experienciou durante as últimas décadas uma crescente integração na prática hospitalar, sendo actualmente um método amplamente utilizado no diagnóstico e rastreio dermatológico. Conseqüentemente, novos instrumentos mais eficazes e de manuseio mais simples começaram a surgir.

Entre eles ganham especial relevância o recurso a luz polarizada, a qual se propaga apenas num plano e como tal não se reflecte em todas as direcções, eliminando desta forma a necessidade de utilizar fluidos. Por outro lado, o recurso à dermoscopia digital é um dos campos em maior expansão, através da qual as lesões pigmentadas podem ser monitorizadas ao longo do tempo e armazenadas sob a forma de imagem digital.

No início da década de 1990, vários grupos de cientistas começaram a estudar a utilidade da análise computacional no diagnóstico deste tipo de lesões. Desde então que os avanços a nível do processamento digital deste tipo de imagens se têm vindo a suceder, provando o seu potencial na avaliação de lesões melanocíticas. Um estudo recente comparou três sistemas comerciais actualmente no mercado no que toca à sua exactidão de diagnóstico, e foi concluído que todos eles têm tendência para classificar lesões melanocíticas suspeitas como melanomas [4], o que limita a sua utilização a nível clínico. Desta forma, é crucial continuar a investigar novos sistemas de diagnóstico, sendo esta a principal motivação para a realização desta dissertação.

1.2 Objectivos

O objectivo principal deste trabalho é o desenvolvimento de métodos para a classificação de lesões cutâneas. Concretizando, o trabalho inicialmente centrou-se no desenvolvimento de algoritmos capazes de extrair características de imagens dermoscópicas que se mostrem relevantes sob o ponto de vista de diagnóstico. Optou-se por escolher as características descritas pela regra ABCD, da qual fazem parte a assimetria, fronteira, cor e estruturas diferenciais.

Numa segunda fase desenvolveu-se um método de classificação baseado no sistema de pontuação da regra ABCD. O método de classificação proposto é supervisionado, ou seja, leva em consideração informação fornecida previamente por especialistas, mais concretamente a classificação das imagens pertencentes ao conjunto de treino feita por especialista.

1.3 Conjunto de Imagens

Para a realização deste trabalho recorreu-se a um conjunto de 68 imagens cedidas pelo Hospital Pedro Hispano e Faculdade de Ciências da Universidade do Porto, as quais apresentam uma resolução típica que varia entre 640x481 pixéis e 768x577 pixéis. Dado que não foi possível ter qualquer tipo de controlo na aquisição das imagens, foram omitidas as imagens que satisfizeram pelo menos um dos seguintes critérios: a lesão não está inteiramente contida no espaço da imagem (figura 1.a); a presença de demasiado pêlo (figura 1.b); contraste insuficiente entre a lesão e a pele circundante (figura 1.c). Este processo de selecção foi essencial para garantir uma eficaz segmentação e extracção de características,

após o qual restaram 48 imagens. Dentro deste conjunto de 48 imagens, 4 foram classificadas como melanomas e 7 como lesões suspeitas de serem melanomas por um especialista.




Figura 1 – Exemplos de imagens suprimidas do estudo por: (a) a lesão não está inteiramente contida no espaço da imagem; (b) a presença de demasiado pêlo; (c) contraste insuficiente entre a lesão e a pele circundante.

1.4 Estrutura da Tese

Este trabalho encontra-se dividido em duas partes.

Na primeira parte, este primeiro capítulo apresenta um carácter introdutório, sendo analisado o panorama actual de cancro cutâneo na população portuguesa, bem como a evolução dos seus métodos de diagnóstico. Neste capítulo são ainda referidas as motivações, objectivos e contribuições desta tese. No capítulo 2, os principais algoritmos de diagnóstico são apresentados, com especial relevância para a regra ABCD e o método dos 7 pontos. No final deste capítulo é apresentado um resumo da evolução dos sistemas automáticos de diagnóstico de melanoma.

A segunda parte está relacionada com a implementação do sistema de classificação automática de imagens dermoscópicas. No capítulo 3 são descritos os métodos de pré-processamento, bem como os algoritmos responsáveis pela extracção das características escolhidas. O capítulo 4 descreve o processo de classificação, sendo analisada a estrutura dos classificadores utilizados. No capítulo 5 são apresentados os resultados obtidos para o conjunto de imagens em questão, bem como a sua análise e discussão. Finalmente, o capítulo 6 enuncia as principais conclusões deste estudo, bem como a perspectiva de trabalhos futuros com vista ao melhoramento desta ferramenta.

1.5 Contribuições da Tese

As principais contribuições desta tese baseiam-se nos seguintes pontos:

- 1) Desenvolvimento de um sistema de classificação de lesões cutâneas baseado na regra ABCD.
- 2) Extração de características de alto nível baseadas na regra ABCD.
- 3) Avaliação do sistema proposto através de uma base de dados de imagens classificadas por especialistas.

2. Algoritmos de Diagnóstico

Estima-se que a precisão do diagnóstico clínico para melanoma cutâneo a olho nu é de apenas 60%. A dermoscopia tem vindo a provar que é um método bastante valioso no diagnóstico deste tipo de lesões, no entanto este requer tempo de treino suficiente e não é recomendado para utilizadores sem experiência [5]. Como tal, a utilização de algoritmos de diagnóstico que já provaram ser eficazes, bem como a sua utilização por especialistas com experiência no seu manuseamento, são aspectos essenciais para o sucesso da aplicabilidade clínica da dermoscopia.

2.1 Método de Análise de Padrões

Um dos algoritmos de diagnóstico mais antigos é o chamado *Método de Análise de Padrões* (MAP), o qual foi primeiramente descrito por Perhambberger *et al.* em 1987 [6]. Este método baseia-se na análise de padrões característicos, sendo a lesão cutânea inicialmente caracterizada como melanocítica ou não melanocítica segundo a presença ou ausência de determinadas características dermoscópicas. Após esta classificação, são utilizados critérios específicos que caracterizam cada tipo de lesão, permitindo desta forma obter-se um diagnóstico. O MAP é amplamente utilizado, aumentando o rácio de diagnóstico correcto de lesões cutâneas pigmentadas de 10% a 30%. No entanto, este algoritmo apresenta alguns problemas na fiabilidade e reprodutibilidade dos resultados devido à sua origem qualitativa, e como tal dois métodos de diagnóstico adicionais foram introduzidos de forma a aumentar a sensibilidade no diagnóstico: a regra ABCD e o Método dos 7 Pontos.

2.2 Regra ABCD

A regra ABCD foi introduzida por Stolz *et al.* em 1994 [7], e foi o segundo algoritmo desenvolvido após o método de análise de padrões, numa tentativa de simplificar e melhorar o processo. Este método teve origem numa análise rigorosa de 31 características dermoscópicas, das quais 4 foram consideradas cruciais para o diagnóstico de melanoma. Segundo Stolz, a regra ABCD trata-se apenas do primeiro de 2 passos, já que só deve ser aplicada quando a lesão pigmentada é classificada como melanocítica. Para tal, Stolz modificou um algoritmo proposto por Kreuzsch e Rassner em 1991, o qual permite classificar a lesão como melanocítica ou não melanocítica.

Caso a lesão seja melanocítica, a regra ABCD deverá ser aplicada tendo em conta as seguintes características: assimetria; fronteira; cor; e estruturas diferenciais. Para cada um destes critérios é feita uma análise semiquantitativa segundo a sua presença na lesão cutânea através da atribuição de uma pontuação, a qual permitirá calcular a Pontuação Dermoscópica Total (PDT). Para o cálculo do PDT é

necessário ter em conta não só a pontuação de cada característica, mas também o factor de peso pelo qual são multiplicadas, como se mostra na seguinte equação:

$$PDT = [(A \times 1.3) + (B \times 0.1) + (C \times 0.5) + (D \times 0.5)], \quad (2.1)$$

na qual as letras representam a pontuação para as seguintes características: assimetria (*A*); fronteira (*B*); cor (*C*); estruturas diferenciais (*D*). Valores de PDT inferiores a 4.75 são indicadores de uma lesão melanocítica benigna; valores entre 4.8 e 5.45 indicam a presença de uma lesão suspeita, sendo recomendado um acompanhamento rigoroso; valores superiores 5.45 estão associados a lesões altamente suspeitas de melanoma.

2.2.1 Assimetria

Para determinar a pontuação de assimetria, a lesão é visualmente dividida através de dois eixos perpendiculares, e é então atribuída uma pontuação que varia de 0 a 2. Quando a lesão é completamente simétrica no que toca ao seu contorno, cor ou estrutura (figura 2.a) é atribuída a pontuação 0; atribui-se 1 ponto a lesões assimétricas em um eixo (figura 2.b), e um máximo de 2 pontos a lesões que são assimétricas em ambos os eixos (figura 2.c).

Quando os eixos visuais são criados mentalmente, eles devem ser traçados com o intuito de criar a pontuação mais baixa possível. Uma maneira simples de determinar a simetria de uma lesão é verificar se cada lado da lesão é uma imagem de espelho do outro para qualquer um dos critérios (contorno, cor ou estrutura). Se não é simétrico em qualquer um dos critérios segundo um determinado eixo, então a lesão seria considerada assimétrica nesse eixo e recebe 1 ponto.

A maioria dos melanomas apresenta pontuação 2, ao invés dos nevos benignos melanocíticos, dos quais apenas 25% apresentam a pontuação máxima. De notar que os melanomas precoces podem parecer simétricos quando examinados a olho nu, no entanto apresentam geralmente assimetria significativa de cores e/ou estruturas quando analisadas dermoscopicamente. Como se pode verificar na equação (2.1), esta característica apresenta um factor de peso bastante elevado, o que revela a importância crucial da sua análise no diagnóstico de melanomas.




Figura 2 – Lesão cutânea completamente simétrica (a); assimétrica num dos eixos (b); assimétrica em ambos os eixos (c) [8].

2.2.2 Fronteira

Para determinar a pontuação da fronteira, a lesão é visualmente dividida em oito segmentos iguais, sendo posteriormente contado o número de segmentos em que há um corte abrupto do padrão do pigmento nas margens. O padrão de pigmento nunca foi formalmente definido, no entanto está relacionado com critérios como a rede pigmentada, estrias ramificadas, pontos, glóbulos, ou pigmentação difusa. A pontuação pode variar de 0 a 8, sendo que a sua pontuação em melanomas varia predominantemente entre 3 e 8 (figura 3). No entanto, o seu baixo factor de peso no cálculo do PDT demonstra que a análise da fronteira neste método é relativamente secundário.




Figura 3 – Lesão cutânea (a): sem demarcações abruptas na fronteira de qualquer segmento (pontuação 0); (b): com demarcações abruptas em 3 segmentos, marcados com * (pontuação = 3) [8].

2.2.3 Cor

São analisadas um total de seis cores diferentes: branco, vermelho, castanho-claro, castanho-escuro, azul-cinza e preto. Para a presença de cada uma destas cores é atribuído um ponto, os quais são somados e posteriormente multiplicados pelo seu factor de peso de 0.5. A cor branca deve ser escolhido apenas se a área é mais clara que a pele adjacente. Quando todas as seis cores estão presentes, obtêm-se a pontuação máxima de 6, sendo 1 a pontuação mínima.

Os melanomas são normalmente caracterizados pela presença de três ou mais cores, e em cerca de 40% dos melanomas verifica-se a presença de cinco ou seis cores. Notavelmente, o espectro de cores em lesões melanocíticas é acentuado e intensificado através da execução de uma análise dermatoscópica.

2.2.4 Estruturas Diferenciais

Foram seleccionadas por Stolz as seguintes características estruturais para avaliação de estruturas diferenciais: rede pigmentada, áreas homogéneas ou sem estruturas, estrias, pontos e glóbulos. As áreas homogéneas ou sem estruturas devem representar pelo menos 10% da área da lesão. Estrias e pontos são contados somente quando mais de dois elementos são claramente visíveis. Para a contagem de glóbulos apenas é necessária a presença de um elemento na lesão. De notar que quanto maior o número destas estruturas diferenciais, maior a probabilidade da lesão ser um melanoma (figura 4). É atribuído um ponto para a presença de cada uma destas estruturas, sendo a pontuação máxima de 5 e a mínima de 1.




Figura 4 – Lesão cutânea com áreas homogéneas ou sem estruturas, estrias, pontos e glóbulos (pontuação = 4) [8].

2.3 Método dos 7 Pontos

Numa tentativa de encontrar um método de diagnóstico menos complexo, Argenziano *et al.* [9] propuseram em 1998 o *Método dos 7 Pontos*. Este método baseia-se em 7 características dermoscópicas, as quais foram escolhidas por serem frequentemente associadas a melanomas. As vantagens deste método prendem-se com o facto de recorrer a um menor número de características quando comparado com o MAP, sendo bastante simples o seu método de pontuação. Como é demonstrado no artigo em que este método foi proposto [9], este provou ter uma sensibilidade entre 85% e 93%, o que o torna um método bastante eficiente no diagnóstico de melanoma.

As sete características escolhidas estão organizadas em 2 grupos: características principais e secundárias. Provou-se que 3 destas 7 características têm um papel mais influente no diagnóstico de melanoma - rede atípica pigmentada; véu azul-esbranquiçado; e rede vascular atípica - sendo agrupadas na categoria principal, em que a sua presença numa lesão é pontuada com 2 valores e a sua ausência com 0. Por sua vez, as restantes 4 características – estrias irregulares; pigmentação irregular; pontos ou glóbulos irregulares; e estruturas de regressão - agrupam-se nas características secundárias, às quais se atribui 1 ponto caso estejam presentes e 0 na sua ausência.

Para o cálculo da pontuação final basta somar a pontuação de todas as características, e caso esta seja igual ou superior a 3, a lesão é classificada como melanoma, caso contrário como um nevo. Desta forma, para um melanoma ser diagnosticado é necessária a identificação de pelo menos 2 destas características (uma principal e uma secundário, ou 3 secundárias). A figura 5 mostra uma lesão em que várias destas estruturas estão presentes, sendo atribuídos 7 pontos.




Figura 5- Análise da lesão cutânea utilizando o Método dos 7 Pontos (pontuação=7) [8].

2.3.1 Rede Atípica Pigmentada

Uma rede pigmentada é caracterizada por uma rede regular de linhas de cor acastanhada sobre fundo castanho claro. No caso de esta apresentar um carácter atípico, a rede apresenta uma coloração preta, castanho-claro ou cinza, através de uma malha irregular e distribuída irregularmente na lesão. Geralmente, esta termina abruptamente na sua periferia, sendo as suas linhas frequentemente espessas (figura 6.a). Este critério é essencial neste método, já que apresenta uma especificidade bastante elevada no diagnóstico de melanoma.

2.3.2 Véu Azul-Esbranquiçado

O véu azul-esbranquiçado é uma pigmentação difusa com coloração que varia de cinza-azul a azul-esbranquiçado. O seu aparecimento está associado a alterações do pigmento da rede, pontos, glóbulos e ou estrias (figura 6.b).

O véu azul-esbranquiçado é quase exclusivamente encontrado em melanomas malignos e nevos de Spitz e Reed (os quais são lesões benignas). Sob o ponto de vista dermoscópico, até ao momento ainda não foram encontradas diferenças entre o véu em melanomas e este tipo de nevos, no entanto a presença de um véu azul-esbranquiçado é uma pista útil para distinguir melanomas de nevos de Clark, os quais não apresentam esta característica.

2.3.3 Padrão Vascular Atípico

Padrões atípicos vasculares podem incluir estruturas vermelhas lineares, pontilhadas ou globulares distribuídas irregularmente na lesão. Estes padrões normalmente aparecem associados a estruturas de regressão e alterações na rede de pigmentação (figura 6.c).

A detecção destas estruturas é bastante importante no diagnóstico de melanomas, dado que a angiogénese (crescimento de novos vasos sanguíneos a partir dos já existentes) é uma das etapas cruciais no crescimento de um tumor maligno.




Figura 6 – Melanomas com: rede atípica pigmentada (a); véu azul-esbranquiçado (b) e padrão vascular atípico em torno da fronteira do melanoma - indicado pelas setas (c) [8].

2.3.4 Estrias Irregulares

São estruturas irregulares de formato linear, que apresentam espessura variável e não estão claramente combinadas com linhas da rede pigmentada. A presença de estrias ocorre tanto em lesões melanocíticas benignas como malignas, no entanto as estrias irregulares são um forte indicador de malignidade da lesão (figura 7.a).

2.3.5 Pontos e Glóbulos Irregulares

Apresentam usualmente forma circular ou oval, com uma coloração que varia entre o preto, castanho e/ou cinzento, estando irregularmente distribuídos na lesão. São bastante comuns em melanomas, ocorrendo predominantemente na periferia através de diferentes tamanhos e formas (figura 7.b).

2.3.6 Pigmentação Irregular

A pigmentação irregular caracteriza-se pela presença de áreas pigmentadas pretas, castanhas e/ou cinzentas, com forma e/ou distribuição irregular. O seu significado a nível de diagnóstico é limitado devido à grande variabilidade de formatos que esta pode assumir, no entanto um aspecto difuso e irregular é normalmente interpretado como um sinal de malignidade (figura 7.c).

2.3.4 Estruturas de Regressão

As estruturas de regressão apresentam-se usualmente através de uma associação de zonas brancas com aspecto de cicatriz e zonas azuis (áreas ou múltiplos pontos azul-cinza). A combinação destas duas zonas é um indicador dermoscópico bastante específico para o diagnóstico de melanoma, no entanto estas estruturas podem ser ocasionalmente encontradas em nevos de Clark (nevos com risco bastante elevado de se tornarem em melanomas) (figura 7.d).




Figura 7– Melanomas com: estrias irregulares (a); pontos e glóbulos irregulares (b); pigmentação irregular (c) e estruturas de regressão (d) [8].

2.4 A Evolução dos Sistemas Automáticos de Diagnóstico de Melanoma

Um estudo levado a cabo por Cascinelli et al. em 1987 [10] viria a ser um dos primeiros trabalhos focados na utilização de métodos automáticos para a detecção de melanomas. Apesar do seu carácter pioneiro, os autores deixam já nessa altura bem clara a preocupação de analisar as características das imagens sob um ponto de vista cromático, da sua forma e textura.

Sendo a correcta separação da lesão da pele circundante um dos primeiros passos neste tipo de sistemas, levou a que a investigação na área da segmentação das imagens experienciasse avanços significativos ainda nesta etapa inicial. Green et al. [11] provaram em 1994 que a segmentação através da análise de histograma se processa de forma rápida e eficaz, tendo atingido uma taxa de 83.8% de segmentações correctas em 204 imagens. Desde então novos métodos de segmentação têm sido propostos, sendo que em 2007 Mendonça *et al.* [12] realizaram um estudo de comparação de vários algoritmos de segmentação. Os resultados deste estudo foram avaliados por um dermatologista experiente, o qual considerou que a taxa de sucesso dos 4 métodos avaliados se situou entre os 83.3% e os 97.9% num conjunto de 50 imagens, entre os quais se destacou a Lmiarização Adaptativa como o método que melhores resultados devolveu.

Quanto à extracção de características da imagem que permitam uma correcta classificação, a sua evolução têm sido mais lenta. A complexidade e variabilidade das estruturas que se pretende analisar é de facto bastante significativa, o que torna difícil a implementação de algoritmos que as detecte e quantifique correctamente. A maioria dos sistemas automáticos desenvolvidos até hoje são baseados na regra ABCD, tendo sido o trabalho realizado por Ganster *et al.* em 2001 [13] um dos primeiros a ter em conta as 4 características deste método, envolvendo um total de 122 parâmetros. Como classificador, foi escolhido nesse estudo o método dos “K vizinhos mais próximos” (kNN), o qual consiste em classificar a imagem através de um processo de votação baseado nos padrões de treino mais próximos.

Ao longo dos anos, outros sistemas igualmente baseados na regra ABCD foram propostos. Rubegni *et al.* [14] atingiu em 2002 uma sensibilidade (SE) de 94.3% e uma especificidade (SP) de 93.8% em 550 imagens (350 nevos e 200 melanomas) utilizando redes neuronais artificiais como classificador. Também modelos logísticos regressivos foram utilizados em 2004 nestes sistemas, tendo o trabalho de Blum *et al.* [15] reportado uma SE de 82.3% e SP de 86.9% num conjunto de 837 imagens (753 nevos e 84 melanomas). Recentemente, outros sistemas de classificação têm sido propostos e com resultados bastante positivos, como é o caso do trabalho de 2007 de Celebi *et al.* [16], que fazendo uso de máquinas de vectores de suporte e métodos de detecção da fronteira da lesão mais eficazes, provou conseguir classificar um conjunto de 564 imagens (476 nevos e 88 melanomas) com uma SE de 93.3% e SP de 92.3%.

Entretanto também já foram desenvolvidos sistemas de detecção automática baseados no método dos 7 pontos, pertencendo a Betta *et al.* [17] em 2006 a primeira tentativa de implementação deste método com vista à criação de um sistema automático. Neste trabalho os autores não

desenvolveram um classificador automático, mas apenas implementaram e testaram com sucesso dois dos critérios de maior importância neste método: a rede atípica pigmentada e a rede vascular atípica. Em 2008, Celebi *et al.* [18] realizaram um trabalho com vista à implementação de outro dos critérios mais relevantes no método dos 7 Pontos, o véu azul-esbranquiçado, o qual apresentou resultados bastante satisfatórios.

Em 2008 foi lançado por Iyatomi *et al.* [19] um sistema de classificação de melanomas via internet, através do qual qualquer pessoa com imagens dermoscópicas pode usufruir deste serviço. Para além de apresentar resultados bastante satisfatórios ao nível da classificação das lesões, com SE de 85.9% e SP 86.0%, este sistema funciona também como repositório público de imagens dermoscópicas. A tabela 1 resume as principais características dos métodos referidos.

Tabela 1- Resumo dos vários métodos de análise de imagens dermoscópicas referido neste trabalho.

Fonte	Ano	Método de Segmentação	Extracção de Características	Classificador	SE	SP	Comentários
[13]	2001	Limiarização + Clustering de cores	122 parâmetros	K-vizinhos mais próximos	73%	89%	Escolha de características baseada na Regra ABCD.
[14]	2002	Limiarização	48 parâmetros	Redes Neurais Artificiais	94%	94%	Características agrupadas em 4 categorias (geometria, cor, textura e ilhas de cores).
[15]	2004	Não mencionado	64 parâmetros	Regressão Linear	82%	87%	-
[17]	2006	Crescimento de Região	Rede atípica pigmentada e padrão vascular atípico	-	-	-	Não é feito diagnóstico, apenas a detecção destas características baseadas no Método dos 7 Pontos.
[16]	2007	Crescimento de Região	437 parâmetros	Máquinas de Vectores de Suporte	92%	93%	11 características de forma, 354 de cor, e 72 de textura.
[18]	2008	Obtida manualmente com supervisão	Véu azul-esbranquiçado	Árvores de decisão	69%	90%	Não é feito diagnóstico, apenas a detecção desta característica baseada no Método dos 7 Pontos.
[19]	2008	Clustering + Crescimento de Região	428 parâmetros	Redes Neurais Artificiais	86%	86%	Escolha de características baseada na Regra ABCD.

3. Extracção das Características

Sendo o objectivo deste trabalho desenvolver um classificador automático para lesões cutâneas, o primeiro passo recaiu na escolha das características de interesse a extrair das imagens dermoscópicas. A sua escolha foi baseada na regra ABCD, já que as componentes a avaliar em cada uma das características são frequentemente de natureza geométrica ou cromática, o que torna mais fácil a sua detecção e quantificação a nível computacional.

Neste capítulo começa-se por introduzir a notação utilizada na descrição das imagens, sendo de seguida enunciadas as várias etapas de pré-processamento, e finalizando com a descrição dos algoritmos responsáveis pela segmentação e extracção de cada uma das características.

3.1 Descrição da notação utilizada

Para serem tratadas computacionalmente, as imagens terão de ser discretas, estando definidas numa malha de pontos de coordenadas inteiras $(m, n) \in \mathbb{Z}^2$. O valor da imagem digital I no ponto (m, n) é então definido por $I(m, n)$, sendo que $I \in \mathbb{R}$ caso seja uma imagem monocromática e $I \in \mathbb{R}^3$ caso seja uma imagem colorida.

3.2 Pré-processamento

Partindo de um conjunto de imagens sem qualquer tratamento prévio, é necessário submeter as imagens a determinados procedimentos de forma a eliminar artefactos (e.g. pêlos e regiões escuras nos 4 cantos da imagem) e compensar grandes variações de intensidade na fronteira dos objectos. Mais concretamente, as imagens foram convertidas para imagens monocromáticas, às quais se aplicou uma máscara para remoção dos bordos escuros, e posteriormente filtradas, como descrito de seguida.

3.2.1 Conversão para Imagem Monocromática

O primeiro passo de pré-processamento consistiu na conversão das imagens de cor para imagens em escalas de cinzento. Este passo apenas foi aplicado nas etapas do modelo em que a diminuição do espaço da imagem facilitou a sua implementação, como é o caso da segmentação ou da extracção de características como a assimetria.

Tendo em conta resultados experimentais anteriores [12], foi escolhido o canal correspondente à cor azul para processamento das imagens, já que este provou ser o componente RGB que permite uma melhor discriminação da lesão (figura 8).




Figura 8 – Imagem original (a) e respectivos componentes R (b), G (c) e B (d) em escala de cinzentos.

Devido às características das imagens dermoscópicas utilizadas neste trabalho, foi também necessário proceder à remoção das regiões escuras nos 4 cantos da imagem, a qual foi realizada através da aplicação de uma máscara a todas as imagens.

3.2.2 Filtragem

O objectivo da filtragem é a remoção de ruído, o qual no contexto deste trabalho pode ser definido como os pixéis que apresentam valores discrepantes quando comparados com os seus vizinhos e para os quais este não pode ser explicado tendo em conta o objecto a que pertencem, ou então como os pixéis que contêm informação indesejada e desnecessária na imagem. Dentro desta última categoria incluem-se artefactos como pêlos e bolhas de ar.

O leque de filtros que encaixam nas necessidades deste trabalho é enorme, tendo-se optado por utilizar um filtro de mediana, já que é bastante rápido e simultaneamente eficiente na eliminação de pontos espúrios (figura 9). O filtro de mediana, tal como o próprio nome indica, corresponde a atribuir a cada pixel de uma imagem o valor da mediana da imagem de entrada numa vizinhança do ponto considerado. O filtro de mediana é um filtro não linear, podendo ser descrito da seguinte forma:

Dada uma imagem de entrada I , a imagem de saída J obtida após a aplicação de um filtro mediana é dada por:

$$J(m, n) = \text{mediana}\{I(i, j), (i, j) \in W(m, n)\}, \quad (3.1)$$

na qual $W(m, n)$ representa a vizinhança escolhida centrada no ponto (m, n) . Foi escolhido este tipo de filtro devido à sua capacidade de atenuar a presença de elementos que afectem os limites da lesão, tais como a presença de pequenos pêlos e bolhas de ar, preservando no entanto os limites dos objectos.




Figura 9 – Imagem original (a) e imagem após aplicação do filtro mediana (b).

3.3 Segmentação

Antes de se começar a extrair informação sobre as características de interesse, é necessário distinguir os pixels que pertencem à lesão e que serão posteriormente processados, daqueles que pertencem à região de pele circundante à lesão.

O método de segmentação escolhido neste trabalho baseia-se na análise do histograma da imagem, o qual basicamente nos dá a distribuição das intensidades dos pixels da imagem, ou seja o número de pixels para cada intensidade luminosa (figura 10). Considerando uma imagem I em escala de cinzentos com valores de intensidade na gama $I(x,y) \in [0, K - 1]$ com K entradas, onde $K = 256$, o histograma da imagem é definido por [20]:

$$h(i) = \text{número de pixels em } I \text{ com valor de intensidade } i ,$$

para todo $0 \leq i < K$. Definindo de forma mais formal:

$$h(i) = \#\{(x,y) \mid I(x,y) = i\} \quad (3.2)$$

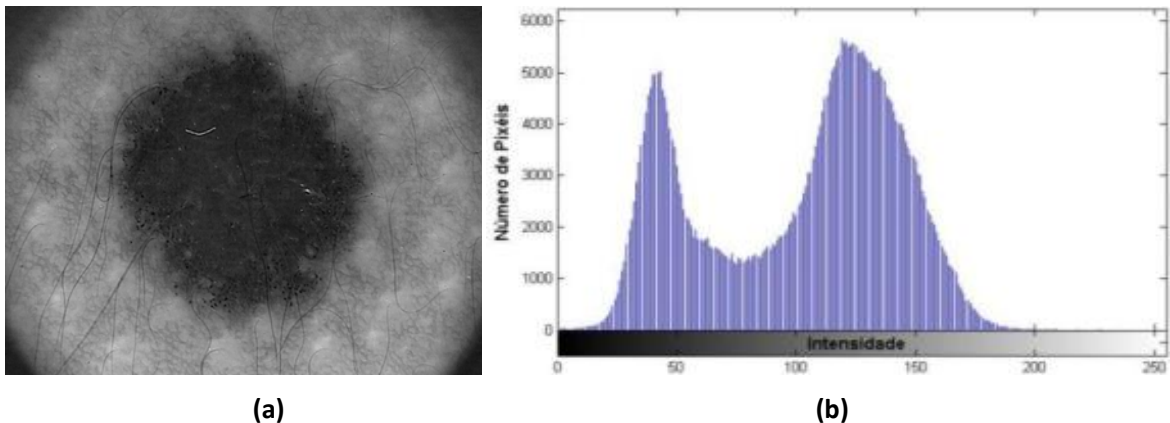


Figura 10 – Imagem em escala de cinzentos (a), e respectivo histograma (b).

Como podemos verificar na figura 10, os histogramas resultantes de imagens dermoscópicas são frequentemente bimodais, ou seja apresentam 2 picos correspondentes à zona da lesão e da pele circundante. Desta forma é considerada uma boa aproximação para o limiar de separação entre estas duas zonas o vale entre os dois principais picos.

Apesar da maioria dos histogramas deste tipo de imagens apresentar este carácter bimodal, algumas destas imagens apresentam histogramas difíceis de processar. Desta forma o algoritmo responsável pela segmentação proposto neste trabalho funciona da seguinte forma:

→ **Aplicação de um filtro de média**: O filtro de média é um filtro linear, sendo desta forma aplicável através do teorema da convolução:

A convolução da imagem I de dimensão $N \times M$ com a imagem h de dimensão $S \times T$, de forma a produzir a imagem J de dimensão $N \times M$, é dada por:

$$J[i, j] = x * h = \sum_{k=0}^{S-1} \sum_{l=0}^{T-1} h[k, l] I[i - k, j - l], \quad (3.3)$$

com $i = 1, \dots, N$, e $j = 1, \dots, M$. A imagem h representa a resposta impulsiva do sistema, a qual para o caso do filtro de média está centrada no ponto (i, j) e pode ser dada por $h(k, l) = \frac{1}{S \times T}$. Isto verifica-se quando todos os elementos de h apresentam coeficientes semelhantes, sendo a saída do filtro de mediana dada por:

$$J[i, j] = \frac{1}{S \times T} \sum_{k=0}^{S-1} \sum_{l=0}^{T-1} I[i - k, j - l] \quad (3.4)$$

Ou seja, basicamente a sua aplicação consiste em trocar o valor de cada pixel na imagem pela média aritmética do valor dos pixéis à sua volta presentes na janela considerada. Desta forma a sua aplicação irá reduzir a variação de intensidade entre um pixel e o próximo, consequentemente eliminando vários máximos e mínimos locais no histograma da imagem filtrada. De notar que se optou por este filtro em detrimento do filtro mediana pois este é mais sensível à presença de outliers, sendo desta forma mais eficaz na manutenção de máximos e mínimos do histograma com valores extremos.

→ **Cálculo dos máximos locais de interesse**: São calculados todos os máximos locais do histograma, e posteriormente ordenados consoante o número de pixéis pertencentes a cada valor de intensidade. Como só nos interessa os máximos representativos das duas regiões de interesse, ou seja a região da lesão e da pele circundante, aplicou-se um conjunto de condições que têm de ser satisfeitas pelos máximos locais para que sejam considerados máximos representativos.

Partindo dos dois máximos locais do histograma com maior número de pixéis, o algoritmo vai percorrendo todos os máximos locais por ordem decrescente de número de pixéis até se verificar estas condições, descartando o máximo de menor expressão em número de pixéis quando estas não são simultaneamente satisfeitas:

1) O máximo de menor intensidade tem de apresentar um valor inferior a H :

Seja I_1 e I_2 valores de intensidade que correspondem a dois máximos locais no histograma da imagem I . Para serem considerados como os picos representativos das duas regiões de interesse no histograma da imagem I , têm de verificar a seguinte condição:

$$\text{mínimo } \{I_1, I_2\} < H \quad (3.5)$$

Com o objectivo de assegurar que o limiar não se encontra numa zona demasiado clara, já que as lesões cutâneas apresentam normalmente uma intensidade escura, foi escolhido $H=170$, valor que foi estimado empiricamente. Em particular, este passo previne que o limiar seja determinado correctamente nos casos em que existem grandes áreas da pele circundante à lesão que reflectem a luz com uma intensidade bastante elevada.

2) A diferença de intensidade entre ambos os máximos têm de ser superior a Δ :

Seja I_1 e I_2 valores de intensidade que correspondem a dois máximos locais no histograma da imagem I . Para serem considerados como os picos representativos das duas regiões de interesse no histograma da imagem I , têm de verificar a seguinte condição:

$$|I_1 - I_2| > \Delta \quad (3.6)$$

Nesta condição foi escolhido $\Delta= 30$, valor novamente estimado empiricamente e que tem como objectivo garantir que ambos os pixéis não estão demasiado próximos, ou seja que não pertencem ao mesmo modo.

→ **Cálculo do limiar:** Achados os dois máximos locais representativos, o objectivo seguinte é encontrar o valor de intensidade no seu intervalo que represente a intensidade dos pixéis próximos da fronteira da lesão. Um dos problemas mais recorrentes neste passo é a existência de diversos mínimos locais nesta zona, não sendo desta forma trivial encontrar automaticamente o melhor limiar. Para tal começamos por achar todos os mínimos locais neste intervalo, sendo escolhido o limiar através dos seguintes critérios:

1) Caso seja detectado apenas um mínimo local no intervalo entre os dois máximos, este representará o valor do limiar.

2) Caso haja mais do que um mínimo local no intervalo entre os dois máximos, será escolhido o mínimo que tenha um número de pixéis bastante inferior comparativamente aos restantes mínimos. Nas situações em que o número de pixéis correspondentes a cada mínimo local não varia significativamente entre eles, será assumido como o limiar a média aritmética das intensidades dos mínimos locais.

Após calculado o limiar, cada pixel é classificado como activo caso tenha a mesma intensidade ou seja mais escuro que o limiar. Formalizando, dada uma imagem I e um limiar L , a imagem binária limiarizada I_L é dada por:

$$I_L(x, y) = \begin{cases} 1 & \text{caso } I(x, y) \leq L \\ 0 & \text{caso } I(x, y) > L \end{cases} \quad (3.7)$$

Desta forma obteremos uma imagem binária, na qual os pixéis de interesse terão valor unitário (figura 11.b). Dado que esta é uma condição aplicada ponto a ponto, é usual existirem zonas pertencentes à lesão que não são detectadas. Como tal são aplicadas algumas operações morfológicas de forma a garantir que zonas desconexas da lesão são unidas e detectadas como um todo. Foi escolhida a aplicação de uma operação de fecho devido ao papel preponderante da dilatação, através da qual se garante a união de determinadas zonas desconexas, especialmente na fronteira da lesão (figura 11). Esta operação foi realizada através de um elemento estruturante de dimensão 5x5 em forma de quadrado.




Figura 11 – Imagem original (a); máscara obtida após a aplicação o limiar (b) e máscaras obtidas através da aplicação da operação morfológica de fecho: uma operação de dilatação (c) seguida de uma operação de erosão (d).

Após a operação de fecho recorreu-se a um algoritmo para preencher os buracos existentes, sendo posteriormente escolhido o objecto com mais pixéis como a região da imagem que representa a lesão cutânea. As imagens binárias obtidas para o conjunto de imagens em estudo mostram-se na figura 12. A segmentação não teve sucesso em alguns casos, nos quais as máscaras devolvidas são bastante diferentes das obtidas por segmentação manual com a supervisão de um especialista. Estes casos estão assinalados na figura 12 com as margens a vermelho, e foram descartados de modo a evitar que estes erros se propaguem nas fases seguintes do modelo de classificação.




Figura 12 – Resultado da segmentação do conjunto de imagens em estudo.

3.4 Assimetria

A assimetria de uma lesão é baseada na distribuição de cores e formas das estruturas da imagem, segundo os dois eixos principais que se cruzam no centróide da lesão. A sua correcta detecção e quantificação são cruciais, já que desempenha um papel essencial na diferenciação de melanomas de lesões benignas. De seguida apresentam-se os passos realizados para a detecção desta característica.

3.4.1 Centróide

O centróide de uma imagem pode ser definido como o ponto no interior de uma imagem que define o seu centro geométrico. Considerando a região \mathcal{R} como sendo uma colecção de coordenadas de pontos no espaço bidimensional, o centróide $\bar{c} = (\bar{x}, \bar{y})$ de uma imagem binária representada por \mathcal{R} pode ser definido como a média aritmética das coordenadas na direcção x e y [20]:

$$\bar{x} = \frac{1}{|\mathcal{R}|} \cdot \sum_{(u,v) \in \mathcal{R}} u \quad (3.8)$$

$$\bar{y} = \frac{1}{|\mathcal{R}|} \cdot \sum_{(u,v) \in \mathcal{R}} v \quad (3.9)$$

3.4.2 Momento Geométrico

De notar que esta definição de centróide é apenas um caso especial de um conceito estatístico mais abrangente, o *momento*. O momento geométrico de uma imagem binária de ordem p, q pode ser definido por [20]:

$$m_{pq} = \sum_{(u,v) \in \mathcal{R}} u^p v^q \quad (3.10)$$

Assim sendo, é possível expressar a área da imagem binária como o momento de ordem zero:

$$A(\mathcal{R}) = |\mathcal{R}| = \sum_{(u,v) \in \mathcal{R}} 1 = \sum_{(u,v) \in \mathcal{R}} u^0 v^0 = m_{00}, \quad (3.11)$$

e conseqüentemente reformular as equações (3.7) e (3.8) do centróide \bar{c} para:

$$\bar{x} = \frac{1}{|\mathcal{R}|} \cdot \sum_{(u,v) \in \mathcal{R}} u^1 v^0 = \frac{m_{10}(\mathcal{R})}{m_{00}(\mathcal{R})} \quad (3.12)$$

$$\bar{y} = \frac{1}{|\mathcal{R}|} \cdot \sum_{(u,v) \in \mathcal{R}} u^0 v^1 = \frac{m_{01}(\mathcal{R})}{m_{00}(\mathcal{R})} \quad (3.13)$$

3.4.3 Momento Central

Com vista a tornar os momentos da imagem binária independentes da posição do objecto, a origem do sistema de coordenadas pode ser deslocada para o centróide $\bar{c} = (\bar{x}, \bar{y})$, sendo o momento central de ordem p, q definido em relação a esse ponto da seguinte [20]:

$$\mu_{pq} = \sum_{(u,v) \in \mathcal{R}} (u - \bar{x})^p \cdot (v - \bar{y})^q \quad (3.14)$$

3.4.4 Orientação da Imagem

Na análise da simetria de uma imagem é necessário começar por encontrar o eixo principal e secundário de inércia, os quais sabemos que são perpendiculares entre si e que se cruzam no centróide da imagem. Recorrendo aos momentos centrais μ_{pq} , a orientação do eixo maior é obtida através do ângulo $\theta_{\mathcal{R}}$ [20]:

$$\theta_{\mathcal{R}} = \frac{1}{2} \tan^{-1} \left(\frac{2 \cdot \mu_{11}(\mathcal{R})}{\mu_{20}(\mathcal{R}) - \mu_{02}(\mathcal{R})} \right) \quad (3.15)$$

O ângulo $\theta_{\mathcal{R}}$ apresenta um valor entre $\left[-\frac{\pi}{2}, \frac{\pi}{2}\right]$, o qual é utilizado para rodar imagem no sentido dos ponteiros do relógio de forma a alinhar os eixos principais com os eixos x e y da imagem (figura 13).




Figura 13 – Resultado da rotação da imagem original (a) de forma a alinhar os eixos principais (a azul, com intercepção no centróide da imagem) com os eixos da imagem (b), bem como a respectiva máscara em formato binário (c) e em escala de cinzentos (d).

3.4.5 Rácios de Assimetria

Sendo o objectivo analisar a simetria da lesão não só a nível geométrico, mas também a nível cromático, dois tipos de máscaras correctamente orientadas foram consideradas: uma máscara binária (figura 13.c) e uma máscara em escala de cinzentos (figura 13.d). Para cada uma destas máscaras, a imagem foi hipoteticamente dobrada segundo cada um dos eixos principais, sendo calculada a diferença da sua sobreposição. No caso da imagem binária, a quantificação da sua assimetria consiste simplesmente na diferença de área em relação ao eixo x (A_x) e a diferença de área em relação ao eixo y (A_y). Já para a máscara em escala de cinzentos, o valor de A_x e A_y consiste no somatório da diferença de intensidades entre cada pixel sobreposto, considerando novamente ambos os eixos principais.

Tendo em conta estes valores, duas medidas de assimetria foram consideradas [16]:

$$A_1 = \frac{\min(A_x, A_y)}{A} \times 100 \quad A_2 = \frac{A_x + A_y}{A} \times 100, \quad (3.16)$$

em que A representa a área da lesão no caso da análise binária, e o somatório da intensidade de todos os pixels pertencentes à lesão no caso da máscara de intensidades. Foram desta forma obtidos 4 parâmetros para analisar a assimetria da lesão, dois para quantificar a sua assimetria geométrica e outros dois para analisar a assimetria a nível de estruturas dentro da lesão.

3.5 Fronteira

Segundo a regra ABCD, o objectivo desta característica passa pela detecção de transições abruptas nas margens, o qual é usualmente um indício de malignidade. Para computar esta característica, começou-se por detectar as zonas periféricas da fronteira da lesão imediatamente interiores e exteriores a esta através de uma Transformada de Distância Euclidiana (TDE) [16]. Tomando uma imagem binária, o cálculo da TDE consiste na atribuição a cada pixel da distância entre esse pixel e o pixel não nulo mais próximo. Como o próprio nome indica, a métrica utilizada foi a distância Euclidiana, a qual pode ser definida da seguinte forma:

$$d(P_1, P_2) = \sqrt{(i_2 - i_1)^2 + (j_2 - j_1)^2}, \quad (3.17)$$

em que $P_1 = (i_1, j_1)$ e $P_2 = (i_2, j_2)$.

Na determinação destas zonas periféricas recorre-se à máscara da fronteira da lesão obtida através do processo de segmentação, ao qual se aplica a TDE. Vão ser desta forma definidas duas regiões para análise da fronteira da imagem, uma no interior e outra no exterior da lesão.

A região periférica exterior é delimitada por duas curvas de nível da imagem resultante da aplicação da TDE, correspondendo a regiões com áreas $1.1 \times A$ e $1.3 \times A$, em que A é a área original da lesão. O mesmo procedimento se aplica para o cálculo da região periférica interior, considerando neste caso regiões com áreas $0.7 \times A$ e $0.9 \times A$. De notar que não fazem parte das regiões periféricas as áreas imediatamente adjacentes à fronteira com uma área correspondente a 10% da área da lesão, de forma a proteger o cálculo desta característica de erros na segmentação da imagem [16].

Podem ser vistos na figura 14 alguns exemplos da determinação destas duas regiões periféricas.




Figura 14– Imagens originais (a, c) e respectivas máscaras das suas fronteiras (a amarelo), zonas periféricas interiores e zonas periféricas exteriores (b, d).

Segundo a regra ABCD, na análise desta característica a lesão é visualmente dividida em oito segmentos iguais, e em cada um destes é analisada a presença de cortes abruptos no padrão do pigmento nas margens. Como tal aplicaram-se um conjunto de 8 máscaras em cada imagem, as quais dividem a lesão em 8 segmentos tendo em conta o seu centróide (figura 15)




Figura 15 – Zona periférica interior e exterior da lesão da figura 14.a dividida em 8 segmentos iguais.

Para quantificar estes resultados recorreu-se a duas medidas estatísticas bastante comuns: a média e o desvio padrão.

Seja X uma variável aleatória e x_1, \dots, x_n n observações independentes. A média e o desvio padrão de X , \bar{x} e s , são definidos por:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = \frac{x_1 + x_2 + \dots + x_n}{n} \quad (3.18)$$

$$s = \sqrt{\frac{1}{n-1} \cdot \sum_{i=1}^n (x_i - \bar{x})^2} \quad (3.19)$$

Os valores da média e desvio padrão da região periférica interior e exterior foram calculados para os três canais de região, sendo calculados os seguintes rácios:

3.5.1 Rácio de Média e Rácio de Desvio Padrão

São propostos os seguintes rácios para quantificar a irregularidade da fronteira:

Seja E_i e I_i uma imagem em formato RGB que representa a região periférica exterior e interior segundo o canal i , respectivamente, em que $i = 1, \dots, 3$. O rácio de média R_m e de desvio padrão R_d são dados por:

$$R_m = \min\left(\frac{\bar{x}(E_i)}{\bar{x}(I_i)}, \frac{\bar{x}(I_i)}{\bar{x}(E_i)}\right) = \min\left(\frac{\bar{x}(E_1)}{\bar{x}(I_1)}, \frac{\bar{x}(E_2)}{\bar{x}(I_2)}, \frac{\bar{x}(E_3)}{\bar{x}(I_3)}, \frac{\bar{x}(I_1)}{\bar{x}(E_1)}, \frac{\bar{x}(I_2)}{\bar{x}(E_2)}, \frac{\bar{x}(I_3)}{\bar{x}(E_3)}\right) \quad (3.20)$$


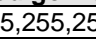

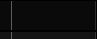
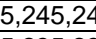
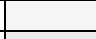
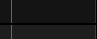
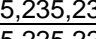

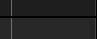
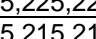
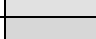
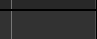
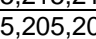

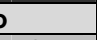




















$$R_d = \min\left(\frac{s(E_i)}{s(I_i)}, \frac{s(I_i)}{s(E_i)}\right) = \min\left(\frac{s(E_1)}{s(I_1)}, \frac{s(E_2)}{s(I_2)}, \frac{s(E_3)}{s(I_3)}, \frac{s(I_1)}{s(E_1)}, \frac{s(I_2)}{s(E_2)}, \frac{s(I_3)}{s(E_3)}\right) \quad (3.21)$$

A análise destes dois rácios permite-nos, em primeiro lugar, determinar através de R_m se existe uma transição demarcada entre as duas regiões periféricas, já que o seu valor traduz a diferença média de intensidades entre elas. Quanto ao rácio R_d , este quantifica a irregularidade da lesão na zona da sua fronteira, dando-nos uma ideia da homogeneidade relativa da lesão nesta região. De notar que a definição destes rácios foi essencialmente empírica, pelo que o seu real significado precisa de ser validado através de mais testes experimentais.

3.6 Cor

Numa imagem em formato RGB, cada pixel pode ser representado através de um vector (R,G,B), em que *R*, *G* e *B* representam a intensidade do pixel no canal vermelho, verde e azul, respectivamente. Sendo o objectivo deste critério a detecção das seis cores propostas pela regra ABCD (preto, branco, azul-cinza, vermelho, castanho-claro e castanho-escuro), um dos métodos mais comuns de detecção de cor com recurso a imagens no sistema RGB é calcular a distância de cada pixel à cor que pretendemos detectar. Para tal é necessário escolher as cores que queremos detectar e quais são os seus códigos RGB, como mostra a tabela 2.

Tabela 2 - Cores que pretendemos detectar, e respectivos códigos RGB.

Preto		Branco		Azul-Cinza	
Código RGB	Cor	Código RGB	Cor	Código RGB	Cor
(0,0,0)		(255,255,255)		(150,125,150)	
(10,10,10)		(245,245,245)		(125,125,150)	
(20,20,20)		(235,235,235)		(100,100,125)	
(30,30,30)		(225,225,225)		(100,125,150)	
(50,40,40)		(215,215,215)		(50,100,150)	
(50,50,50)		(205,205,205)		(0,100,150)	
Vermelho		Castanho Claro		Castanho Escuro	
Código RGB	Cor	Código RGB	Cor	Código RGB	Cor
(255,0,0)		(200,150,100)		(150,100,100)	
(255,50,50)		(200,100,0)		(125,75,75)	
(200,0,0)		(200,100,50)		(100,50,50)	
(200,50,50)		(150,100,50)		(100,50,0)	
(150,0,0)		(150,100,0)		(100,0,0)	
(150,50,50)		(150,50,0)		(50,0,0)	

Note-se que em cada uma das cores que pretendemos detectar são escolhidos 6 códigos RGB, com o objectivo de dar flexibilidade ao algoritmo. Desta forma temos, para cada cor a detectar, um agrupamento de 6 cores que a representa, tendo sido a sua escolha processada da seguinte forma: 1) Escolhe-se como ponto de partida para cada cor um código RGB que a representa e que é utilizado como referência; 2) Seleccionam-se mais cinco cores através de combinações que devolvam cores relacionadas com o código inicial. A escolha destas combinações foi baseada puramente nos resultados experimentais obtidos, já que não houve a possibilidade de recolher dados junto de especialistas que pudesse ajudar o algoritmo a aprender as cores a detectar, nem foi encontrada literatura que documentasse este tipo de informação.

Usa-se como distância entre os valores tabelados e o valor de cada pixel o somatório da diferença em cada canal de cor, ou seja:

Sejam $I(x, y)$ um pixel da imagem I em formato RGB e I' uma cor de referência. A distância entre I e I' é dada por:

$$d(x, y) = \sum_{k=1}^3 |I^k(x, y) - I'^k|, \quad (3.22)$$

Para um pixel da imagem I ser associado a uma determinada cor de referência, é necessário que o valor da distância seja inferior a um limiar predefinido, de forma a permitir pequenas variações. O valor escolhido para o limiar foi de 25, já que é um valor relativamente pequeno tendo em conta que estamos a considerar variações nos 3 canais, fornecendo no entanto uma maior flexibilidade de detecção ao algoritmo. Desta forma o número de pixels activos para cada agrupamento de cores é calculado, sendo a cor considerada presente na lesão caso o número de pixels detectados no agrupamento represente pelo menos 0,1% da área da lesão (figura 16).




Figura 16 – Imagem original (a) e respectivas máscaras, em que o algoritmo detectou as seguintes cores: castanho-escuro (b); castanho-claro (c) e preto (d).

3.7 Estruturas Diferenciais

Nesta característica pretende-se detectar 5 tipos de estruturas diferenciais que usualmente surgem associadas ao desenvolvimento de melanomas. Estas características são as seguintes: rede pigmentada, áreas homogéneas ou sem estruturas, estrias, pontos e glóbulos. A abordagem escolhida para extrair esta característica foi baseada numa metodologia desenvolvida por Betta *et al.* [17] com o objectivo de analisar a rede atípica pigmenta, um dos principais critérios do Método dos 7 Pontos. Foram no entanto feitas várias alterações a esta metodologia, de forma a adaptá-la à característica em estudo, tal como esta é descrita segundo a regra ABCD. O diagrama da figura 17 esquematiza o algoritmo implementado.

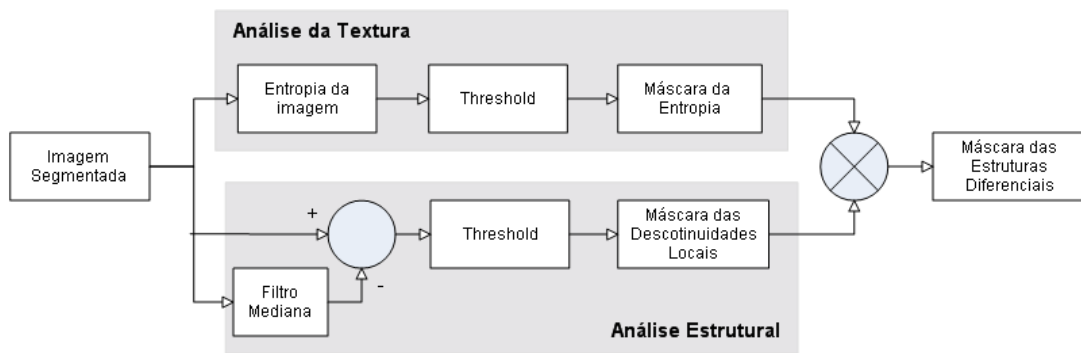


Figura 17– Diagrama de blocos do algoritmo de detecção das estruturas diferenciais.

3.7.1 Análise da Textura

À semelhança do algoritmo descrito em [17], existe uma componente responsável pela análise da textura da imagem, sendo que no algoritmo proposto neste trabalho esta é analisada através da entropia da imagem, em detrimento da sua análise espectral. A entropia é uma medida estatística da aleatoriedade da intensidade dos pixéis numa imagem, para a qual áreas de alta entropia correspondem a zonas da imagem em que a variabilidade de intensidade dos pixéis é bastante elevada. De seguida apresenta-se a definição do conceito de entropia.

Consideremos uma imagem I em escala de cinzentos com N símbolos, em que cada símbolo representa o nível de cinzento na imagem. Sendo a_j um símbolo de I , com $j = 0, \dots, N - 1$, a entropia da imagem é dada por:

$$S = \sum_{j=0}^{N-1} p(a_j) (-\log_2 p(a_j)), \quad (3.23)$$

em que $p(a_j)$ representa a probabilidade de ocorrência do símbolo a_j . Para obter informação sobre a variação de entropia dentro de uma imagem é necessário utilizar o *operador entropia*, o qual consiste em aplicar uma máscara de convolução a uma região da imagem e atribuir ao pixel que se encontra no centro da máscara o valor da entropia da região. Utilizando uma técnica de “sliding window” a duas dimensões, o operador entropia é aplicado em toda a imagem, criando uma nova imagem que possui os valores de entropia de cada região.

O próximo passo é escolher as zonas de maior entropia na imagem, já que estas indicam-nos a existência de descontinuidades na imagem. Como tal, escolheu-se como critério para a criação da máscara de entropia a inclusão de todos os pixéis que apresentem um valor que seja pelo menos $\frac{2}{3}$ do valor máximo de entropia verificado, valor este determinado de forma empírica através da comparação das máscaras de entropia devolvidas e as zonas da lesão onde se localizam as estruturas diferenciais.

3.7.2 Análise Estrutural

O objectivo desta secção do algoritmo passa por detectar as descontinuidades locais presentes na imagem, tais como pontos e linhas. Para tal aplica-se uma metodologia semelhante à descrita em [17], na qual o primeiro passo consiste em aplicar um filtro de mediana considerando uma vizinhança bastante grande, o qual vai conduzir a uma suavização acentuada da imagem, e conseqüentemente levar à eliminação de grande parte das descontinuidades locais presentes na imagem. De seguida faz-se uma diferença entre a imagem original e a imagem filtrada, obtendo-se desta forma uma máscara de diferenças de intensidade, na qual todos os pixéis com intensidade superior a 10 são considerados como pertencentes a uma descontinuidade local. Este valor de limiar foi estimado através da análise experimental do conjunto de imagens utilizado, tendo sido escolhido pela capacidade de preservar as principais descontinuidades enquanto elimina simultaneamente áreas que apresentam variações de intensidade pouco relevantes.

A máscara das estruturas diferenciais é então obtida através da multiplicação matricial elemento a elemento das máscaras obtidas pela análise da textura e estrutural, ou seja as estruturas diferenciais vão ser representadas pelos pixéis detectados como descontinuidades locais que simultaneamente se encontrem em áreas de entropia elevada (figura 18).




Figura 18 – Imagens original (a) e respectiva: máscara de entropia (b); máscara das descontinuidades locais (c) e máscara das suas estruturas diferenciais (d).

3.7.3 Rácio de área e Desvio Padrão das Intensidades

São propostos os seguintes indicadores para quantificar a presença de estruturas diferenciais numa imagem:

Seja I uma imagem em escala de cinzentos. Tomando M_B como a máscara que representa as estruturas diferenciais da imagem I em formato binário, e M_C como o conjunto de pixéis que representam as estruturas diferenciais da imagem I , o rácio de área R_a e o desvio padrão das intensidade R_i são dados por:

$$R_a = \frac{A_B}{A_L} \times 100 \quad (3.24)$$

$$R_i = s(M_C), \quad (3.25)$$

em que A_B representa a área de M_B , A_L a área ocupa pela lesão e $s(M_C)$ o desvio padrão de M_C . O indicador R_a é desta forma responsável por quantificar a percentagem de área ocupada pelas estruturas diferenciais. A definição de outro indicador está associado ao facto de querermos detectar estruturas variadas, e geralmente com aspectos diferentes. Imaginemos que temos uma lesão em que a única estrutural diferencial presente é uma rede pigmentada que se estende por toda a lesão. Segundo proposto pela regra ABCD, a esta lesão apenas seria atribuída 1 ponto em 5 possíveis, sendo que no nosso algoritmo seria atribuído um valor tão alto como o valor atribuído a uma lesão que apresente várias estruturas diferenciais que ocupem a mesma percentagem de área. Como tal o segundo indicador R_i é responsável por medir a variabilidade de intensidade dos pixéis pertencentes a estas estruturas, sendo provável obter um valor de R_i tanto maior quanto maior o número de diferentes estruturas detectadas.

4. Classificação

Este capítulo começa por abordar o problema de classificação de dados. São também analisadas as estruturas dos classificadores utilizados neste trabalho: o classificador de k-vizinhos mais próximos (kNN), e as Máquinas de Vectores de Suporte (SVM).

4.1 Classificação de Dados

O problema pode ser enunciado da seguinte forma: dado um vector de observações $x \in \mathbb{R}^n$ pretende-se atribuir-lhe uma classe c , em que $c \in \{0, \dots, \mathcal{L} - 1\}$ e onde \mathcal{L} representa o numero de classes admissíveis. De uma forma geral, esta classificação pode ser obtida de duas formas: através do classificador óptimo de Bayes quando as estatísticas dos dados são conhecidas ou métodos de aprendizagem utilizando um conjunto de treino. O segundo caso é o mais frequente na prática. Admite-se que são conhecidos exemplos de decisões anteriores realizadas por um especialista e pretende-se treinar o classificador a decidir de forma semelhante (aprendizagem supervisionada).

4.1.1 Classificador de Bayes

Os classificadores de Bayes são classificadores estatísticos que classificam um objecto numa determinada classe baseando-se na probabilidade desse objecto pertencer a essa classe. Ou seja, a observação x será classificada numa classe c para a qual a probabilidade condicional $P(c|x)$ é a mais alta possível. Esta probabilidade é conhecida por probabilidade a posteriori da classe c porque é calculada depois de ser observado o vector x . As probabilidades a posteriori calculam-se usando o teorema de Bayes:

$$P(c|x) = \frac{P(x|c) P(c)}{P(x)} \quad (4.1)$$

Desta forma precisamos de conhecer as estatísticas dos dados e das classes $P(x|c)$ e $P(c)$, de modo a classificar a observação x . Essa informação não está disponível na maioria dos casos.

4.1.2 Aprendizagem utilizando um Conjunto de Treino

Neste tipo de classificação os objectos desconhecidos são classificados tendo em conta um conjunto de objectos que já se encontram previamente classificados, os quais constituem o chamado

conjunto de treino. O processo pelo qual estes são classificados é designado de aprendizagem supervisionada. Desta forma um conjunto de treino é formado por um conjunto de padrões de entrada e respectivas decisões, o qual pode ser definido da seguinte forma:

$$Tr = \{(x^k, c^k)\} \quad (4.2)$$

O conjunto Tr é então utilizado para estimar os parâmetros do classificador, através dos quais é possível classificar novos padrões.

Depois de treinado o classificador é preciso avaliar o seu desempenho, utilizando-se para tal um novo conjunto de dados. Caso o conjunto de dados disponível para treinar e testar um classificador seja demasiado reduzido, pode-se optar pelo método “Leave-one-out” (LOO), o qual consiste em classificar todas as imagens do conjunto de dados considerando como conjunto de treino todas as imagens disponíveis, excepto a imagem que vai ser classificada.

4.2 Classificador K-Vizinhos Mais Próximos

Sucintamente, o classificador kNN compara o vector de entrada x com os vectores x^k do conjunto de treino e determina os k vectores de treino mais próximos. O vector de entrada é então classificado na classe mais votada dos k padrões de treino mais próximos. O método kNN pode então ser descrito da seguinte forma:

Consideremos um conjunto de treino $Tr = \{(x^k, c^k)\}$, em que $x^k \in \mathbb{R}^n$ e $c \in \{0, \dots, \mathcal{L} - 1\}$. Para classificar um novo elemento $x \in \mathbb{R}^n$ calcula-se as distâncias de x a todos os elementos pertencentes ao conjunto de treino, e determina-se os k vectores mais próximos de x . Dentre estes k vectores verifica-se qual a classe que aparece com mais frequência, sendo o elemento x classificado dentro da classe mais frequente.




Figura 19 – Exemplo de classificação segundo o método kNN. O objecto a classificar (círculo verde) será classificado como pertencente à classe dos quadrados azuis caso $K=1$ e classificado como pertencente à classe dos triângulos vermelhos caso $K=3$.

Várias métricas podem ser utilizadas para calcular a distância entre os elementos, sendo a mais comum e aquela que foi escolhida neste trabalho o cálculo da *distância euclidiana*, como descrita anteriormente através da equação (3.17).

4.2.1 Normalização

Tendo em conta que o processo de classificação deste método se baseia no cálculo de distâncias, é necessário garantir que os valores de cada elemento têm um intervalo de variação semelhante ao dos outros. Este processo de normalização é essencial pois podem existir gamas dinâmicas diferentes entre os diferentes atributos, as quais iriam interferir no cálculo da distância.

Seja v um valor do vector de entrada x . O valor normalizado de v , $v' \in [0,1]$, é dado por:

$$v' = \frac{v - \min_x}{\max_x - \min_x}, \quad (4.3)$$

onde \max_x e \min_x representam o valor máximo e mínimo do vector x , respectivamente.

4.2.2 Cálculo de K

O valor de k que apresenta melhores resultados depende do problema. Como tal, o valor de k deve ser determinado experimentalmente. Para tal começa-se por escolher uma gama de valor de k , e para cada um desses valores é estimada a taxa de erro do classificador, sendo escolhido o valor que devolver uma menor taxa de erro. Os valores de k escolhidos foram 1,3 e 5. Nos casos em que a frequência de várias classes é semelhante, escolhe-se a classe que apresente menor distância.

4.3 Máquinas de Vectores de Suporte

As Máquinas de Vectores de Suporte (SVM) representam uma técnica de aprendizagem supervisionada que tem vindo a ser aplicada com sucesso para o treino de classificadores binários. As SVM baseiam-se na teoria de aprendizagem estatística desenvolvida por Vapnik em 1979, e o seu nome tem origem no facto do algoritmo seleccionar um pequeno conjunto de padrões de treino para definir a superfície de decisão entre as classes [21]. Estes padrões são chamados vectores de suporte, sendo a decisão baseada nestes vectores.

Tomando um problema linearmente separável, a SVM estima um hiperplano que separa os dados das duas classes. No entanto não nos interessa que este hiperplano apenas separe os dados, mas que garanta também a maior distância possível aos dados, de forma a não potenciar classificações erradas

devido à sua proximidade em relação a esses dados. A figura 20.a mostra o hiperplano ótimo criado através de um processo de aprendizagem utilizando SVM, com dados linearmente separáveis e pertencentes a duas classes diferentes.

No entanto muitos dos problemas não são separáveis linearmente, como mostra a figura 20.b. Nestes casos é então necessário transformar o conjunto de dados iniciais num novo conjunto de dados linearmente separáveis, procedimento que é motivado pelo teorema de Cover [21]: Dado um conjunto de treino que não é linearmente separável, este pode ser transformado com alta probabilidade num conjunto de dados linearmente separável através da sua projecção num espaço de dimensão superior através de uma transformação não-linear.

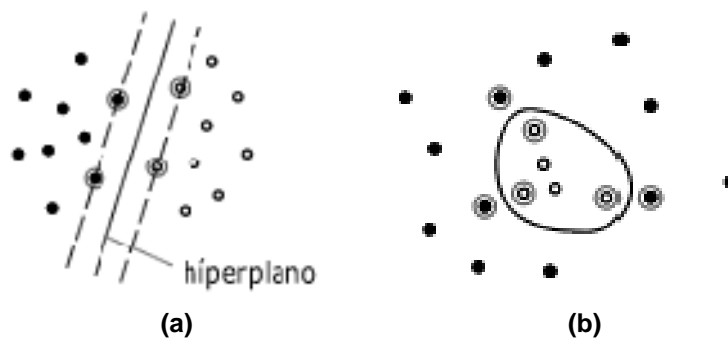


Figura 20– Classificação de duas classes linearmente separáveis (a) e não linearmente separáveis (b) [22].

São desta forma utilizados os *métodos de Kernel* com vista a converter um problema não linear num problema linear. Um Kernel K consiste numa função que recebe dois pontos x_i e x_j do espaço de entradas e calcula o seu produto escalar nesse espaço, transformando-os em pontos de outro espaço. As funções de Kernel mais utilizadas estão descritas na tabela 3, bem como os parâmetros que devem ser determinados pelo utilizador.

Tabela 3– Funções de Kernel mais comuns [21].

Tipo de Kernel	Função $K(x_i, x_j)$	Parâmetros a determinar
Polinomial	$(\partial(x_i \cdot x_j) + \kappa)^d$	∂, κ e d
Gaussiano	$\exp(-\sigma \ x_i - x_j\ ^2)$	σ
Sigmoidal	$\tanh(\partial(x_i \cdot x_j) + \kappa)$	∂ e κ

4.4 O Modelo de Classificação Proposto

Nesta secção apresenta-se a estrutura completa do modelo proposto para o diagnóstico de lesões cutâneas baseado em imagens dermoscópicas, a qual pode ser visível no seguinte diagrama de blocos:

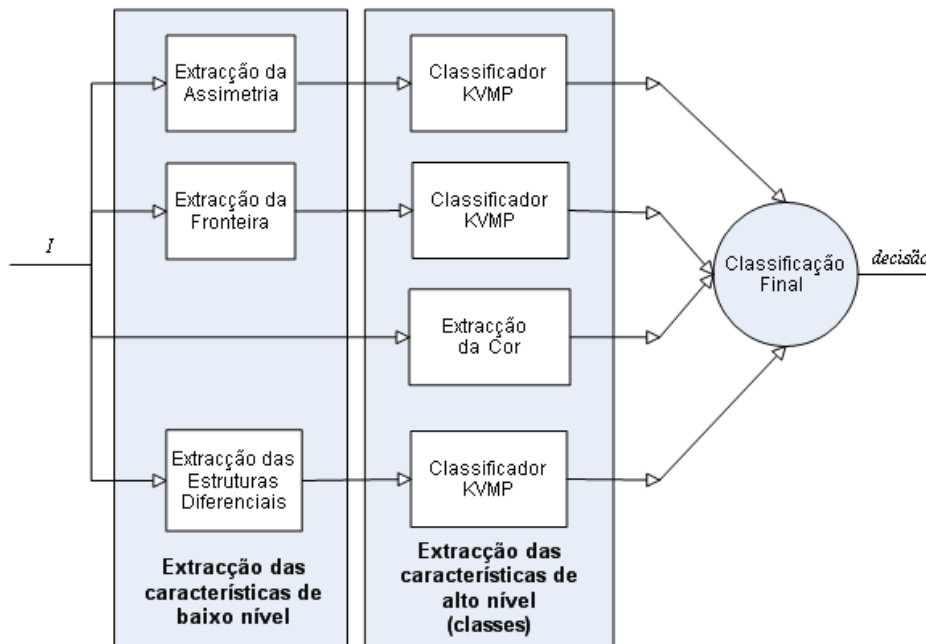


Figura 21 – Diagrama de blocos do modelo de classificação de lesões cutâneas proposto neste trabalho.

Como podemos verificar, o sistema pode ser dividido em três blocos principais:

- **Características de baixo nível:** O sistema começa por receber uma imagem dermoscópica I , a qual se pretende classificar como suspeita ou não suspeita de ser melanoma. Começa-se então por extrair parâmetros que quantificam as características que a regra ABCD propõe como relevantes para a detecção de melanoma. De notar que à excepção da característica Cor, todos os outros algoritmos responsáveis pela extracção de cada característica não classificam as lesões de maneira semelhante à regra ABCD, ou seja a gama de valores utilizada para quantificar estas características não são semelhantes, pelo que os seus *outputs* são designados de *características de baixo nível*.

- **Características de alto nível (classes):** O objectivo desta fase é obter uma pontuação para cada característica semelhante à proposta na regra ABCD. Para as três características que ainda não estão neste formato (todas excepto a Cor), temos como ponto de partida os parâmetros extraídos na etapa anterior para cada imagem, bem como a classificação de cada característica segundo a regra ABCD por parte de um especialista. Desta forma os vectores de observação são classificados segundo o

método kNN, sendo obtida para cada característica uma pontuação que se encontra dentro da gama de valores descritos para cada classe da regra ABCD (*características de alto nível*).

- **Classificação Final:** Nesta etapa é obtida uma decisão final do modelo quanto à malignidade da lesão. Para a sua classificação final consideraram-se três classificadores: o classificador kNN, que recebe como entrada as pontuações dos parâmetros ABCD obtidas na fase anterior; o classificador SVM, que utiliza uma entrada semelhante à do classificador anterior; e um método de limiarização, que recebe como entrada uma combinação linear dos parâmetros ABCD designada de PDT (ver equação 2.1). Independentemente do classificador utilizado, a decisão final terá um formato binário, identificando positiva ou negativamente a lesão como suspeita de ser um melanoma.

Nesta classificação final recorreu-se a outra classificação por parte de um especialista, o qual classificou cada imagem do conjunto em estudo como suspeita ou não suspeita de ser melanoma.

5. Resultados e Discussão

Neste capítulo são apresentados e discutidos todos os resultados relativos à implementação do sistema automático de detecção de lesões cutâneas descrito nos capítulos anteriores. Partindo do conjunto inicial de 68 imagens, apenas 44 serão utilizadas para obtenção de resultados, já que 21 imagens satisfizeram pelos menos um dos critérios de omissão descritos na secção 1.3, e 5 imagens foram suprimidas após a análise dos resultados da segmentação. As imagens suprimidas após segmentação contam no entanto para a análise dos resultados do algoritmo de segmentação utilizado, sendo retiradas nas fases seguintes do modelo apenas com a finalidade de não tornar dependente de segmentações incorrectas os resultados dos algoritmos de extracção de características.

Apresentam-se de seguida os resultados e respectivas análises para o processo de segmentação, extracção de cada uma das características e classificação das lesões, sendo simultaneamente introduzidas as métricas utilizadas para avaliar os resultados obtidos.

5.1 Segmentação

As imagens segmentadas foram descritas anteriormente no capítulo 3.3, figura 12. Estas imagens foram então comparadas com a segmentação manual realizada por um especialista para esse mesmo conjunto. A quantificação da discrepância entre a segmentação automática e manual foi feita usando a *métrica de Hammoude* [12].

Dadas duas imagens binárias X e Y , em que X e Y designam os conjuntos de pixéis activos, a *métrica de Hammoude* é dada por:

$$d_H = \frac{\#(X \cup Y) - \#(X \cap Y)}{\#(X \cup Y)} \quad (5.1)$$

A métrica de Hammoude apresenta valores entre 0 e 1, sendo que 0 corresponde a uma correspondência perfeita das imagens segmentadas (são iguais) e 1 quando não há intersecção entre as imagens (são completamente dissimilares).

Para caracterizar os valores obtidos através da métrica de Hammoude no conjunto de imagens de teste, recorreu-se ao cálculo da média e variância (tabela 4).

Tabela 4- Média e Variância obtidos para a métrica de Hammoude.

	Segmentação Automática	
Segmentação Manual	Média (\bar{x})	0.19
	Variância (s^2)	0.024

5.1.1 Discussão dos Resultados obtidos para a Segmentação

A segmentação por limiarização é um processo que se tornou vastamente utilizado devido à sua fácil implementação e rapidez de processamento. Apesar de devolver resultados bastante satisfatórios, é necessário ter em conta alguns casos pontuais em que a metodologia falha. Um deles é a influência da iluminação, já que uma iluminação desigual da imagem irá conduzir à distorção do seu histograma. Os critérios de escolha dos máximos e mínimos locais representativos das zonas de interesse mostraram-se eficazes a contornar esta contrariedade, como pode ser visto na figura 22.a, onde apesar das más condições de iluminação se obteve um baixo índice de Hammoude ($d_H= 0.13$).

No entanto o modelo de segmentação implementado apresenta algumas limitações. A mais significativa prende-se com a falha na detecção de lesões com pouco contraste. A segmentação foi realizada tendo em conta apenas o canal azul, o qual fornece de uma forma geral uma boa discriminação das lesões. No entanto existem lesões com pouco contraste neste canal, pelo que a informação presente nos restantes canais desempenhará certamente um papel fundamental na sua correcta segmentação. A este problema estão associados os casos em que o algoritmo detecta uma lesão em várias regiões separadas, muitas vezes devido à falta de contraste entre estas. Apesar das operações morfológicas aplicadas para unir regiões próximas, por vezes estas regiões encontram-se demasiado afastadas para serem unidas. Como o algoritmo está projectado para considerar apenas como lesão a maior área detectada, as restantes regiões são rejeitadas, como mostra a figura 22.c. Uma possível solução para este problema passará pela consideração de múltiplas regiões detectadas, tendo em conta critérios como a semelhança de intensidades entre os seus pixéis ou a distância entre estas regiões.

A análise da eficácia do algoritmo de segmentação proposto pode então ser realizada através dos valores obtidos pela métrica de Hammoude. Os resultados obtidos mostram-se bastante satisfatórios, já que a sua média se encontra relativamente próxima do valor ideal ($d_H=0$), sendo pequena a variância dos dados.

Estes resultados podem ser comparados com resultados de trabalhos anteriores [12], o qual foi um trabalho que utilizou uma base de dados de tamanho semelhante e que comparou vários métodos de segmentação. Há que ter no entanto em conta que o estudo [12] não omitiu nenhuma imagem do conjunto de teste, mesmo que estas apresentassem artefactos que comprometessem a segmentação.

Tabela 5 - Comparação dos resultados obtidos com outros métodos [12] segundo a métrica de Hammoude.

	Segmentação Proposta	Limiarização Adaptativa	“Level Set”	“Robust Snakes”
Média (\bar{x})	0.19	0.21	0.21	0.16
Variância (s^2)	0.024	0.037	0.023	0.007

Considerando o cálculo da métrica de Hammoude para cada um dos métodos referidos em [12], os índices de Hammoude obtidos neste trabalho apresentam melhores resultados quando comparados com um algoritmo de limiarização adaptativa e um algoritmo que utiliza o método de “Level Set”, apresentando no entanto valores superiores quando comparado com um algoritmo baseado no modelo “Robust Snakes” (ver tabela 5).




Figura 22 – Exemplos de resultados de segmentação: com sucesso (a, b); e sem sucesso (c, d).

Distâncias de Hammoude: $d_H^{(a)} = 0.13$; $d_H^{(b)} = 0.10$; $d_H^{(c)} = 0.58$ e $d_H^{(d)} = 0.87$.

5.2 Extracção de Características

Após obtidos os parâmetros de baixo nível (ver capítulo 3) que medem as características ABCD, cada uma foi analisada individualmente de forma a testar a eficácia dos algoritmos implementados. Para tal utilizou-se na classificação de cada característica um classificador kNN, o qual recebe como *input*: os parâmetros da característica em estudo para todas as imagens de treino; o número de vizinhos mais próximos a considerar; e a classificação dessa característica segundo a regra ABCD feita por um especialista para todas as imagens de treino. Desta forma todas as imagens são avaliadas utilizando um critério de LOO, sendo cada uma classificada com a pontuação dada pelo especialista para a classe que foi mais votada segundo o método kNN.

Antes de serem apresentados os resultados obtidos para cada uma das características extraídas, serão introduzidas de seguida os critérios utilizados para avaliar a classificação de cada característica.

Matriz de Confusão

A matriz de confusão permite avaliar o desempenho de um classificador. A matriz de confusão para k classes é uma matriz quadrada cujos elementos são dados por:

$$M_{ij} = P(\hat{c} = j \mid c = i), \quad (5.2)$$

com $i, j = 1, \dots, k$ e em que c e \hat{c} são classificações correctas e obtidas pelo classificador para um padrão de entrada genérico x , respectivamente. Estas probabilidades são aproximadas pelas frequências relativas destes acontecimentos no conjunto de teste.

Note-se que a matriz de confusão é uma matriz estocástica pois a soma dos elementos de cada linha é igual a 1:

$$\sum_{j=1}^k M_{ij} = 1 \quad (5.3)$$

Probabilidade de Erro

Seja P_i a probabilidade de ocorrência da classe i num conjunto de dados classificado em k classes. A probabilidade de erro P_{erro} do classificador é dada por:

$$P_{erro} = \sum_i P_i \cdot P(\text{erro} | c = i) = \sum_i P_i \cdot \left[\sum_{j \neq i} M_{ij} \right],$$

com $i, j = 1, \dots, k$ e onde M_{ij} representa a matriz de confusão do classificador.

5.2.1 Assimetria

A classificação desta característica foi realizada através de um classificador kNN, o qual classificada as lesões em três classes diferentes, como sugerido pela regra ABCD. A pontuação varia entre 0, 1 e 2, consoante a lesão se apresente completamente simétrica, assimétrica em relação a um eixo principal ou assimétrica em relação a ambos os eixos principais, respectivamente. O processo de classificação leva em consideração a pontuação fornecida por um especialista de forma a treinar o classificador, tendo sido obtida a seguinte dispersão de dados:

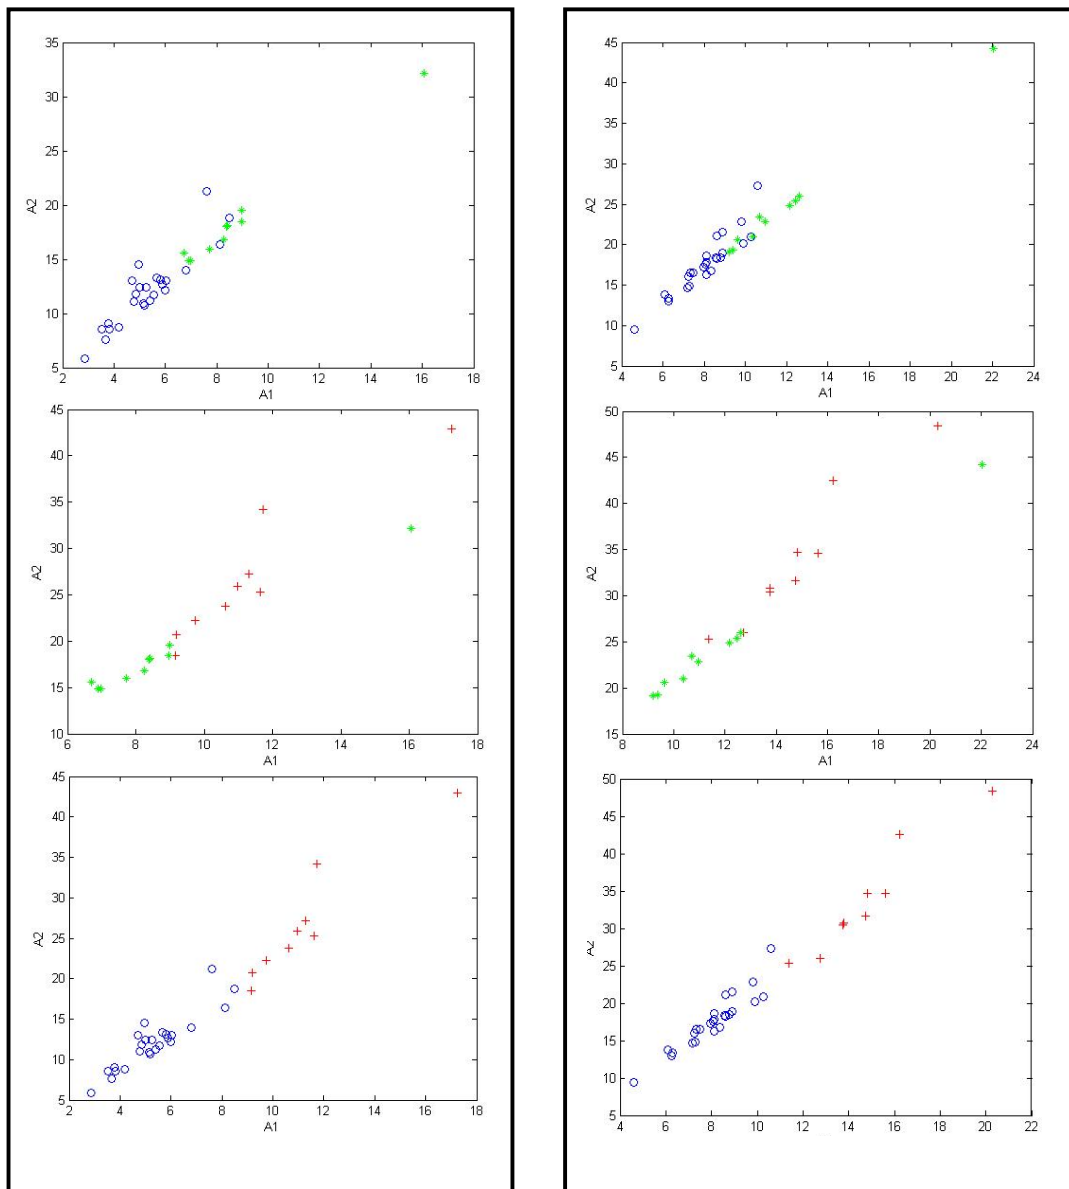


Figura 23 – Classificação da assimetria: Dispersão dos parâmetros A_1 e A_2 para o caso binário (a) e para a imagem em escala de cinzentos (b), com $k=3$ (“O” - classe 0; “*” - classe 1; e “+” classe 2).

Analisando a dispersão de dados da figura 23, verificamos que as lesões classificadas como pertencentes à classe 2 formam o grupo de dados que melhor se distingue das restantes classes, o que prova a eficácia do algoritmo em distinguir correctamente lesões que apresentam assimetria acentuada. A grande limitação do algoritmo parece estar em discriminar as classes 0 e 1. Podemos ver que existe uma clara sobreposição na dispersão dos dados para estas duas classes, o que evidencia a sua dificuldade em separar as lesões completamente simétricas daquelas que são simétricas apenas em relação a um eixo.

Podemos também afirmar que a separação entre as classes é mais nítida para o caso em que se recorre à imagem em escala de cinzentos, provando-se assim a importância da análise das estruturas dentro da lesão na quantificação da assimetria.

De seguida mostram-se alguns exemplos de classificações com e sem sucesso: a figura 24.a foi classificada como pertencente à classe 0 pelo especialista e pelo classificador kNN; a figura 24.b foi classificada como pertencente à classe 2 pelo especialista e pelo classificador; a lesão da figura 24.c foi considerada como pertencente à classe 0 pelo especialista e à classe 2 pelo classificador; e a lesão da figura 24.d foi classificada como pertencente à classe 2 pelo especialista e à classe 1 pelo classificador.




Figura 24– Exemplos de resultados da classificação da assimetria: com sucesso (a, b); e sem sucesso (c, d).

Tabela 6 – Classificação da assimetria: Matrizes de confusão e respectivas probabilidades de erro para os diferentes valores de k utilizados.

		Classificação kNN									P_i
		$k=1$			$k=3$			$k=5$			
		0	1	2	0	1	2	0	1	2	
Classificação Especialista	0	71%	21%	8%	75%	21%	4%	71%	25%	4%	55%
	1	33%	47%	20%	40%	33%	27%	53%	27%	20%	34%
	2	40%	20%	40%	0%	20%	80%	0%	20%	80%	11%
P_{erro}		41%			39%			43%			

Fazendo a análise estatística dos resultados através da tabela 6, podemos considerar que a classificação devolvida para a classe 0 é satisfatória, já que independentemente do k escolhido, a larga maioria das imagens consideradas completamente simétricas pelo especialista são correctamente classificadas. De notar no entanto que a frequência desta classe é bastante elevada, pelo que o classificador terá mais tendência a classificar as lesões nesta categoria à medida que o número de vizinhos mais próximos considerados aumenta. Este acontecimento é particularmente visível na alta percentagem de casos considerados pertencentes à classe 1 pelo especialista, mas que foram classificados na classe 0 pelo classificador. Na origem desta alta percentagem, que chega a ser superior ao número de casos bem classificados para valores de k superiores a 1, poderá estar a dificuldade do algoritmo implementado em quantificar de forma claramente distinguível as lesões simétricas das assimétricas em apenas um dos eixos, tal como foi sugerido na análise de dispersão dos dados. Há que ter em conta que o tamanho reduzido do conjunto de treino utilizado poderá também influenciar este comportamento, já que a variabilidade nas lesões cutâneas é enorme, e como tal duas lesões podem ser classificadas na mesma classe pelo especialista tendo no entanto formas e estruturas completamente diferentes, as quais quando quantificadas pelo algoritmo irão devolver valores consideravelmente afastados.

No que toca à classe 2, verifica-se que o número de casos considerados completamente assimétricos pelo especialista é bastante reduzido em relação ao tamanho do conjunto de imagens utilizado, no entanto a classificação destas lesões é correctamente realizada em 80% dos casos para k superior a 1. Podemos assim afirmar que o algoritmo é eficaz na detecção de imagens assimétricas segundo os dois eixos principais.

Analisando finalmente qual o valor de k que melhor se adapta à classificação desta característica, a melhor classificação para as classes 0 e 2 obtém-se com $k=3$, enquanto a classe 1 só é classificada correctamente na maioria dos casos para $k=1$. Olhando para o método de pontuação da regra ABCD, verificamos que a assimetria é a característica mais influente no cálculo do PDT (eq. 2.1), já que a larga maioria dos melanomas são completamente assimétricos. Como tal a principal prioridade passa por discernir correctamente a maioria dos casos que apresentam assimetria em ambos os eixos principais dos restantes casos, sendo desta forma considerada que a melhor classificação para esta característica é devolvida para $k=3$.

5.2.2 Fronteira

Segundo a regra ABCD, esta característica é pontuada numa gama de 0 a 8, o que corresponde a um problema com 9 classes. Devido possivelmente à vasta gama de valores que esta característica pode assumir, unido ao facto do número de imagens para treinar o classificador ser relativamente reduzido, 6 destas 9 classes não têm qualquer representante no conjunto de dados. Isso coloca uma dificuldade, já que não temos dados para treinar o classificador a reconhecer as 9 classes. Além disso não possuímos informação sobre quais dos 8 sectores circulares apresentam transição abrupta de textura, pelo que o procedimento adoptado apresenta muitas limitações.

Desta forma considerou-se haver transição abrupta em todos os sectores circulares nas lesões em que o especialista atribuiu uma pontuação igual ou superior a 1, obtendo-se assim duas classes. Após dividida a imagem em 8 segmentos iguais, cada segmento foi classificado segundo o método kNN, sendo atribuído 1 ponto ao segmento caso seja classificado como pertencente à classe onde existe um corte abrupto, e 0 pontos caso contrário. Posteriormente é somada a pontuação de todos os segmentos, sendo desta forma atribuída uma pontuação para a fronteira que pode variar entre 0 e 8, tal como descrito na regra ABCD.

De seguida mostram-se alguns dos resultados obtidos. Como exemplos de classificações em que houve correspondência temos as lesões das figuras 25.a e 25.b, às quais foram atribuídas em ambas as classificações 0 e 2 pelo especialista e pelo algoritmo automático. Por outro lado na figura 25.c temos uma lesão que foi classificada com 8 pontos pelo especialista, à qual o classificador atribuiu 0 pontos; e ainda a lesão da figura 25.d que foi classificada com 0 pontos pelo especialista, enquanto segundo o classificador lhe atribuídos 3 pontos.




Figura 25 – Exemplos de resultados da classificação da fronteira: com sucesso (a, b); e sem sucesso (c, d).

Tabela 7 – Classificação da fronteira: Matrizes de confusão e respectivas probabilidades de erro para os diferentes valores k utilizados.

		Classificação kNN										P_i
		k=1										
		0	1	2	3	4	5	6	7	8		
Classificação Especialista	0	9%	35%	38%	12%	6%	0%	0%	0%	0%	0%	77%
	1	-	-	-	-	-	-	-	-	-	-	0%
	2	0%	50%	25%	13%	0%	13%	0%	0%	0%	0%	18%
	3	-	-	-	-	-	-	-	-	-	-	0%
	4	-	-	-	-	-	-	-	-	-	-	0%
	5	-	-	-	-	-	-	-	-	-	-	0%
	6	-	-	-	-	-	-	-	-	-	-	0%
	7	-	-	-	-	-	-	-	-	-	-	0%
	8	0%	50%	0%	50%	0%	0%	0%	0%	0%	0%	5%
P_e		89%										
		k=3										P_i
		0	1	2	3	4	5	6	7	8		
		0	1	2	3	4	5	6	7	8		
Classificação Especialista	0	26%	47%	15%	12%	0%	0%	0%	0%	0%	0%	77%
	1	-	-	-	-	-	-	-	-	-	-	0%
	2	38%	50%	13%	0%	0%	0%	0%	0%	0%	0%	18%
	3	-	-	-	-	-	-	-	-	-	-	0%
	4	-	-	-	-	-	-	-	-	-	-	0%
	5	-	-	-	-	-	-	-	-	-	-	0%
	6	-	-	-	-	-	-	-	-	-	-	0%
	7	-	-	-	-	-	-	-	-	-	-	0%
	8	0%	50%	50%	0%	0%	0%	0%	0%	0%	0%	5%
P_e		77%										

Analisando as estatísticas da tabela 7, em primeiro lugar há que ter em conta que a frequência da classe 0 é bastante superior às restantes classes, sendo que apenas em 23% dos casos foi considerado pelo especialista a presença desta característica em pelo menos um segmento de cada imagem. Como tal realizou-se uma classificação automática segundo o método kNN apenas para $k=1$ e $k=3$, já que a escolha de um número de vizinhos superior não faria sentido tendo em conta a baixa frequência de uma das classes aliado ao reduzido número de imagens pertencentes ao conjunto de treino.

Em relação aos resultados obtidos, podemos constatar que a classificação obtida não se mostra adequada à detecção desta característica, facto que é comprovado através das enormes percentagens de erro. Este era à partida um resultado que já seria esperado devido às limitações referidas anteriormente. Tendo em conta que o algoritmo divide a imagem em oito partes iguais e quantifica esta característica segmento a segmento, o ideal seria ter como conjunto de treino a classificação de cada um dos segmentos da imagem por parte de um especialista, não sendo assim necessário durante a fase de treino generalizar a presença desta característica para todos os segmentos da imagem caso exista pelo menos um segmento classificado positivamente pelo especialista.

Apesar dos resultados pouco satisfatórios, foi considerada a pontuação obtida para $k=3$ na classificação final da lesão.

5.2.3 Cor

A pontuação desta característica é baseada na detecção de 6 cores diferentes, sendo atribuído um ponto pela presença de cada uma delas. Tendo em conta a classificação obtida pelo especialista e a pontuação devolvida pelo algoritmo, apresentam-se de seguida alguns dos resultados obtidos: na lesão da figura 26.a foi detectada apenas uma cor tanto pelo especialista como pelo algoritmo, tendo este último detectado castanho-escuro; na lesão da figura 26.b foram detectadas duas cores tanto pelo especialista como pelo algoritmo, tendo este último detectado castanho-escuro e castanho-claro; na lesão da figura 26.c foram identificadas 3 cores pelo especialista, enquanto o algoritmo só detectou uma (castanho-escuro); e finalmente na figura 26.d foi considerada a presença de apenas uma cor pelo especialista, enquanto o algoritmo detectou duas cores (castanho-claro e castanho-escuro).




Figura 26 – Exemplos de resultados da análise de cor: com sucesso (**a, b**); e sem sucesso (**c, d**).

Tabela 8 – Classificação da cor: Matrizes de confusão e respectivas probabilidades de erro para os diferentes valores k utilizados.

		Classificação Algoritmo						P_i
		1	2	3	4	5	6	
Classificação Especialista	1	63%	32%	5%	0%	0%	0%	45%
	2	15%	65%	20%	0%	0%	0%	48%
	3	67%	33%	0%	0%	0%	0%	7%
	4	-	-	-	-	-	-	0%
	5	-	-	-	-	-	-	0%
	6	-	-	-	-	-	-	0%
P_e		40%						

Observando as estatísticas da tabela 8, note-se que a eficácia do algoritmo não pode ser analisada para todas as classes possíveis, dado que na base de dados só há lesões com um máximo de 3 cores para ambos os tipos de classificação. Para a classe 1 e 2, as quais representam um total de 93% do conjunto de casos analisados, verifica-se que o algoritmo detecta na maioria dos casos o mesmo número de cores que o especialista considerou, o que no entanto não nos garante que são detectadas pelo algoritmo as mesmas cores identificadas pelo especialista.

Durante a fase de experimentação do algoritmo verificou-se que, apesar da grande variabilidade ao nível de cores das imagens dermoscópicas, muitas delas apresentam cores bastante semelhantes e consequentemente com vectores RGB bastante próximos. Sendo assim, uma forma de refinar este algoritmo passaria por determinar as gamas do espaço RGB que melhor identificam cada uma das seis cores da regra ABCD, ao invés de detectar zonas isoladas no espaço RGB que correspondam a uma determinada cor. Na determinação destas gamas a colaboração com especialistas seria certamente uma mais-valia, já que a sua experiência seria crucial no reconhecimento das variações de cores mais recorrentes em lesões cutâneas.

5.2.4 Estruturas Diferenciais

Na classificação desta característica são consideradas 5 classes, ou seja a pontuação é atribuída numa gama de valores de 1 a 5, sendo atribuído 1 valor na presença de cada uma das seguintes estruturas: rede pigmentada, áreas homogéneas ou sem estruturas, estrias, pontos e glóbulos.




Figura 27- Classificação de estruturas diferenciais: Dispersão dos parâmetros R_a e R_i para $k=5$.
("O" - classe 1; "*" - classe 2; e "+" - classe 3).

Analisando a dispersão de dados da figura 27, podemos verificar que as imagens pertencentes à classe 3 apesar de serem poucas formam o grupo de dados que melhor se distingue das restantes classes. Por outro lado é visível que o algoritmo tem alguma dificuldade em discriminar as lesões que apresentam pontuação entre 1 e 2. Este acontecimento está certamente associado à própria estrutura do algoritmo implementado, já que não é feita uma detecção independente de cada uma das estruturas referidas pela regra ABCD, mas sim quantificada a presença e variabilidade do conjunto dessas estruturas. Mesmo na detecção destas estruturas o algoritmo apresenta algumas limitações, já que as zonas homogéneas ou sem estruturas não são detectadas (figura 28.b). No entanto o algoritmo mostra-se eficaz principalmente na detecção da rede pigmentada, como é visível na figura 28.d, também detectando regularmente a presença de estrias, glóbulos e pontos (figura 28.f). Desta forma, trabalhos futuros deverão centrar-se na detecção separada de cada uma destas estruturas, garantindo desta forma uma quantificação mais correcta desta característica.




Figura 28– Exemplos de detecção de estruturas diferenciais pelo algoritmo implementado.

De seguida apresentam-se alguns dos resultados obtidos: Como exemplos de lesões onde houve correspondência na classificação temos as figuras 29.a e 29.b, as quais foram classificadas como pertencentes respectivamente à classe 3 e 0 tanto pelo especialista como pelo algoritmo; No que toca a classificações incorrectas temos a figura 29.c que foi classificada como pertencente à classe 1 pelo especialista e à classe 2 pelo algoritmo; e finalmente a figura 29.d, classificada como pertencente à classe 3 pelo especialista e à classe 2 pelo algoritmo.




Figura 29 – Exemplos de resultados de estruturas diferenciais: com sucesso (a, b); e sem sucesso (c, d).

Tabela 9 – Classificação das estruturas diferenciais: Matrizes de confusão e respectivas probabilidades de erro para os diferentes valores k utilizados.

		Classificação kNN															P_i
		k=1					k=3					k=5					
		1	2	3	4	5	1	2	3	4	5	1	2	3	4	5	
Classificação Especialista	1	54%	38%	8%	0%	0%	38%	62%	0%	0%	0%	46%	54%	0%	0%	0%	30%
	2	15%	58%	27%	0%	0%	8%	77%	15%	0%	0%	12%	85%	4%	0%	0%	59%
	3	0%	60%	40%	0%	0%	20%	40%	40%	0%	0%	0%	60%	40%	0%	0%	11%
	4	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	0%
	5	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	0%
P_e		45%					39%					32%					

A análise estatística dos resultados (tabela 9) vem provar algumas das conclusões retiradas na análise da dispersão dos dados. Em particular, a dificuldade do algoritmo em classificar correctamente as lesões que pertencem à classe 1, onde a percentagem máxima de classificações correctas foi obtida para $k=1$ com uns escassos 54%. No que toca à classificação das restantes classes, verifica-se que a classe 2 é classificada correctamente na maioria dos casos para qualquer valor de k , atingindo uma percentagem de 85% de classificados correctas para $k=5$. É para este valor de k que se verifica a melhor classificação, apesar de não serem classificados correctamente a maioria dos casos na classe 1 e 3, na primeira devido aos problemas já mencionados e na segunda devido provavelmente à baixa frequência da classe 3. Apesar de só serem classificados correctamente 40% dos casos para a classe 3, 60% são classificados como pertencentes à classe 2, possivelmente devido ao número elevado de vizinhos mais próximos considerados.

5.3 Classificação Final das Lesões

Esta é a etapa final do processo de classificação das imagens dermoscópicas, na qual cada lesão irá ser classificada como suspeita ou não suspeita de ser um melanoma. Consideraram-se então as melhores classificações obtidas na etapa anterior para cada característica como as pontuações ABCD a utilizar na classificação final. A figura 30 mostra o PDT de cada imagem calculado a partir das pontuações dadas por um especialista segundo a regra ABCD. De notar que neste gráfico está também presente a classificação realizada por outro especialista, que classificou as imagens em 3 classes: lesão altamente suspeita de ser melanoma (classe rotulada de melanoma); lesão suspeita de ser melanoma; e lesão benigna. Esta classificação foi feita sem a aplicação da regra ABCD. As rectas de valor 4,8 e 5,5 identificadas no gráfico representam o limiar segundo a regra ABCD a partir do qual uma lesão é considerada suspeita de ser melanoma ou altamente suspeita de ser melanoma, respectivamente.




Figura 30 – Valores PDT calculados a partir das pontuações dadas por um especialista segundo a regra ABCD.

Comparando o resultado das duas classificações realizadas pelos especialistas, vemos que existe uma relação entre ambas as classificações. À excepção de algumas imagens, na maioria dos casos as imagens com PDT elevados estão maioritariamente associadas a lesões consideradas suspeitas pela avaliação em 3 classes, sendo visivelmente distinguível o PDT médio obtido em cada uma das classes. No entanto as imagens classificadas pela regra ABCD não apresentam na maioria dos casos um PDT suficientemente elevado para ultrapassarem os limiares a partir do qual são classificadas como suspeitas ou altamente suspeitas, não havendo na maioria destes casos uma correspondência quanto à classe a que são atribuídas nas duas classificações.




Figura 31 – Valores PDT calculados a partir das pontuações obtidas pelo sistema automático proposto.

A figura 31 mostra o PDT de cada imagem calculado a partir das pontuações obtidas pelo sistema automático. Comparando os valores de PDT com a classificação do especialista, podemos verificar que a maioria das lesões suspeitas e altamente suspeitas continuam a estar associadas a valores de PDT elevados, no entanto o número de casos benignos com PDT elevado é bastante superior quando comparado com a classificação do especialista através da regra ABCD. Este acontecimento está obviamente associado aos problemas de classificação na extração de cada uma das características, os quais já foram descritos nas secções anteriores. Tal como no gráfico anterior verifica-se novamente que os valores de PDT obtidos estão bastante abaixo dos limiares propostos pela regra ABCD, facto que era expectável já que os dados dessa classificação foram utilizados para treinar o classificador. Desta forma conclui-se que não é possível classificar correctamente este conjunto de imagens através do simples cálculo do PDT e aplicação do critério de classificação da regra ABCD, motivo pelo qual se optou por utilizar uma nova etapa de classificação para classificar as imagens.

Para a classificação final das imagens utilizaram-se três classificadores diferentes: um classificador kNN; um classificador SVM; e um método de Limiarização que compara o PDT com o limiar. O valor do limiar é escolhido de forma a minimizar o erro de classificação do conjunto de treino.

Para analisar e comparar dos resultados obtidos recorreu-se às matrizes de confusão de cada uma das classificações, através das quais se determinou a probabilidade de erro (P_{erro}), a sensibilidade (SE) e a especificidade (SI) da classificação. Os conceitos de SE e SI são seguidamente explicados.

Sensibilidade e Especificidade

Após a classificação das imagens como suspeitas ou não suspeitas de melanoma, podemos obter quatro situações diferentes ao compararmos os resultados obtidos com a classificação levada a cabo pelo especialista: O resultado foi positivo e a lesão é suspeita de ser melanoma (verdadeiro positivo - **VP**) ou não é suspeita de ser melanoma (falso positivo - **FP**); por outro lado, quando o resultado for negativo, e a lesão não é suspeita de ser melanoma (verdadeiro negativo - **VN**) ou foi classificada como suspeita de ser melanoma (falso negativo - **FN**).

Desta forma é possível calcular a sensibilidade e a especificidade, duas medidas responsáveis por quantificar a precisão do modelo de classificação utilizado. A sensibilidade mede a capacidade do modelo em identificar correctamente a doença entre os casos que de facto a possuem, ou seja:

$$SE = \frac{VP}{VP + FN} = M_{11}$$

A especificidade mede a capacidade do modelo em excluir correctamente os casos que não possuem a doença, ou seja, é a fracção dos casos que obtiveram resposta negativa no modelo entre aqueles que não possuem a doença:

$$SP = \frac{VN}{VN + FP} = M_{00}$$

Note-se que estes valores são dados directamente pela matriz de confusão, correspondendo a sensibilidade ao elemento M_{11} e a especificidade ao elemento M_{00} .

Antes de serem apresentadas as matrizes de confusão obtidas para cada um dos classificadores, há que referir que os dados pertencentes ao conjunto de treino classificados como suspeitos foram triplicados antes do processo de classificação. Isto porque o número de casos suspeitos era bastante inferior aos restantes casos no conjunto de imagens utilizadas, sendo que uma frequência semelhante em ambas as classes nos permitiria obter uma ideia mais clara sobre a eficácia do modelo proposto.

Tabela 10 – Matrizes e confusão e respectivas probabilidades de erro para cada um dos classificadores utilizados na classificação final.

		Classificação Final					
		kNN		SVM		Limiarização	
		Não suspeita	Suspeita	Não suspeita	Suspeita	Não suspeita	Suspeita
Classificação Especialista	Não suspeita	61%	39%	61%	39%	70%	30%
	Suspeita	18%	82%	64%	36%	27%	73%
<i>P_{erro}</i>		34%		45%		30%	

De referir que os *inputs* para os vários classificadores utilizados não foram sempre os mesmos, tendo sido utilizada a pontuação das classes ABCD obtida na etapa anterior para classificar a imagem segundo os métodos kNN e SVM, e a PDT para realizar a classificação através de um método de Limiarização. A tabela 11 resume os resultados obtidos.

Tabela 11 – Resumo dos resultados obtidos na classificação final.

Input	Classificador	<i>P_{erro}</i>	<i>SE</i>	<i>SP</i>
Pontuação das classes ABCD	kNN	34%	82%	61%
Pontuação das classes ABCD	SVM	45%	36%	61%
PDT ¹	Limiarização	30%	73%	70%

5.3.1 Discussão dos Resultados obtidos na Classificação Final

Começamos por analisar as percentagens de erro obtidas. De uma forma geral podemos afirmar que estamos perante uma probabilidade de erro elevada, independentemente do classificador escolhido. Estes valores estão naturalmente relacionados com todas as condicionantes associadas à extracção e classificação de cada uma das características, as quais foram referidas nas secções anteriores. A propagação destes erros, associados a um conjunto de dados reduzido para treinar os classificadores, acaba por justificar esta percentagem significativa de casos mal classificados.

No entanto verifica-se que existem métodos de classificação que se enquadram melhor na classificação final das imagens. Em particular, a classificação segundo um método de limiarização é aquela que apresenta menor probabilidade de erro, tendo simultaneamente valores de *SE* e *SP* relativamente elevados. Este método ao utilizar como input o PDT calculado a partir da pontuação das

¹ Pontuação calculada a partir da pontuação das classes ABCD obtida na etapa anterior.

classes ABCD obtida na etapa anterior, é influenciado pelo peso que cada classe representa na pontuação final da imagem, como sugerido pela regra ABCD.

Os outros dois métodos de classificação baseiam-se exclusivamente na pontuação das classes ABCD obtida. Consideremos a classificação segundo o método kNN para $k=3$, já que foi para este valor que se obtiveram melhores resultados. Verificamos que a probabilidade de erro segundo este método é relativamente superior à classificação por limiarização, apresentando um valor de SE superior e de SP inferior. Isto indica-nos que existe um maior número de lesões suspeitas detectadas, no entanto o número de lesões benignas que são classificadas como suspeitas também aumenta. À medida que o valor de k é aumentado verifica-se que a SE continua ligeiramente a melhorar, no entanto a SP desce drasticamente, obtendo-se consequentemente uma probabilidade de erro superior. Este trade-off está certamente relacionado com a triplicação dos dados relativos aos casos suspeitos, os quais vão desta forma ter uma maior influencia na escolha da classe mais comum entre os vizinhos mais próximos considerados.

Em relação à classificação através de SVM, podemos concluir que este foi o classificador que apresentou piores resultados. A probabilidade de erro elevadíssima, bem como a baixa SE provam o insucesso da aplicação deste método. Tendo em conta que o processo de aprendizagem deste classificador passar por identificar um determinado número de padrões e classificar um novo padrão segundo os padrões de treino existentes, caso os dados de treino sejam reduzidos o classificador vai ter bastante dificuldade em classificar novos dados. E tudo indica que é esse o motivo da obtenção de resultados piores com este classificador, já que o reduzido conjunto de treino não nos permite generalizar, ou seja classificar correctamente um padrão novo que não foi usado para treinar o classificador.

6. Conclusões e Trabalhos Futuros

Neste trabalho foi desenvolvido um sistema automático para diagnóstico de lesões cutâneas baseado na regra ABCD, através do qual a melhor classificação foi obtida para o método de limiarização, com $SE=73\%$, $SP=70\%$ e $P_{erro}=30\%$.

O modelo implementado começa por realizar a segmentação das imagens, processo que obteve resultados satisfatórios tendo em conta a sua análise através da métrica de Hammoude ($\bar{x} = 0.19$ e $s^2 = 0.024$). No entanto há que ter em conta que várias imagens do conjunto inicial foram omitidas caso tenham verificado pelo menos um dos seguintes critérios: a lesão não está inteiramente contida no espaço da imagem; a presença de demasiado pêlo; contraste insuficiente entre a lesão e a pele circundante. Desta forma torna-se essencial o desenvolvimento de rotinas dentro do processo de segmentação que contornem estas contrariedades e permitam a segmentação de um conjunto de imagens sem ser necessária uma etapa de selecção.

Outro factor a ter em consideração é a base de dados utilizada neste trabalho. Partindo de um conjunto de 68 imagens, após a etapa de selecção sobram 44 imagens, através do qual o classificador foi treinado e avaliado. Desta forma a dimensão do conjunto de imagens apresenta uma dimensão bastante inferior à desejada para um processo de classificação de dados com estas características. Em particular, dentre as 44 imagens apenas 4 foram classificadas como melanoma e 7 como lesões suspeitas por um especialista, o que certamente limita o processo de classificação do modelo implementado. Como tal torna-se essencial a utilização de uma base de dados de dimensões superiores e devidamente classificada na utilização desta ferramenta em trabalhos futuros.

Foram escolhidas 4 características de alto nível baseadas na regra ABCD para classificar a imagem. Para o algoritmo responsável pela extracção da assimetria obteve-se uma probabilidade de erro de 39%, no entanto verificou-se que o algoritmo classifica correctamente 75% e 80% das imagens completamente simétricas e assimétricas em ambos os eixos principais, respectivamente, sendo a sua maior dificuldade a classificação correcta das lesões que apresentam assimetria em apenas um dos eixos principais. Desta forma a melhoria deste algoritmo passa por torná-lo mais sensível na detecção das lesões assimétricas em apenas um dos eixos principais.

Os resultados obtidos para a extracção da fronteira mostram-se totalmente desequilibrados, tendo sido atingido uma probabilidade de erro de 77%. Este valor é certamente devido ao facto desta característica ser avaliada em 9 classes diferentes, o que aliado à reduzida dimensão da base de dados influenciou os resultados obtidos. Como tal mostra-se essencial que este algoritmo seja novamente avaliado através de uma base de dados adequada, de forma aferir sobre o seu verdadeiro potencial na detecção da característica em causa.

Relativamente ao algoritmo proposto para a extracção da cor, verificou-se também uma elevada probabilidade de erro ($P_{erro} = 40\%$), no entanto em duas das 3 classes presentes no conjunto de dados foram detectadas correctamente a maioria dos casos, com 63% e 65%. De notar que a larga

maioria dos resultados mal classificados apenas difere da classificação do especialista pela detecção de mais ou menos uma cor, não sendo desta forma obtidos valores completamente desenquadrados. Uma forma de melhorar este algoritmo passaria por determinar as gamas do espaço RGB que melhor identificam cada uma das seis cores da regra ABCD, ao invés de detectar zonas isoladas no espaço RGB que correspondam a uma determinada cor. Na determinação destas gamas a colaboração com especialistas seria certamente uma mais-valia, já que a sua experiência seria crucial no reconhecimento das variações de cores mais recorrentes em lesões cutâneas.

A extracção da característica relacionada com as estruturas diferenciais obteve uma probabilidade de erro de 32%, o qual pode estar associado ao facto de não ser feita uma detecção independente de cada uma das cinco estruturas referidas para esta característica segundo a regra ABCD, mas sim quantificada a presença e variabilidade do conjunto dessas estruturas. Desta forma em trabalhos futuros com este algoritmo deve-se tentar detectar separadamente a presença de cada uma destas estruturas, garantindo desta forma uma maior aproximação aos factores de classificação utilizados na regra ABCD.

Concluindo, fica provado que é necessário melhorar vários aspectos deste modelo, tanto ao nível da segmentação como da extracção de características, de forma a torná-lo uma ferramenta eficaz no diagnóstico de lesões cutâneas através de imagens dermoscópicas.

Referências


1. Liga Portuguesa contra o Cancro. [Online] <http://www.ligacontracancro.pt/>.
2. *Parameterization of Dermoscopic Findings for the Internet-based Melanoma Screening System*. **H. Iyatomi, H. Oka, M. E. Celebi, M. Tanaka, and K. Ogawa**. Proc. IEEE Symposium on Computational Intelligence in Image, 2007, pp. 189-193.
3. *Early diagnosis of malignant melanoma by surface microscopy*. **H.P.Soyer, J.Smolle, H.Kerl and H. Stettne**. Lancet, 1987, Vol. 2.
4. *Current and emerging technologies in melanoma diagnosis: the state of the art*. **E. Psaty, A. Halpern**. Clin Dermatol., 2009, Vol. 27, pp. 35-45.
5. *Diagnostic accuracy of dermoscopy*. **H Kittler, H Pehamberger, K Wolff, and M Binder**. The Lancet Oncology, 2002, Vol. 3.
6. *In vivo epiluminescence microscopy of pigmented skin lesions*. **Pehamberger H, Steiner A, Wolff K**. J Am Acad Dermatol., 1987, Vol. 17, pp. 571-583.
7. *ABCD rule of dermatoscopy: a new practical method for early recognition of malignant melanoma*. **Stolz W, Riemann A, Cognetta AB**. Eur J Dermatol, 1994, Vol. 4. pp. 521-527.
8. Dermoscopy.org. [Online] <http://www.dermoscopy.org/>.
9. *Epiluminescence microscopy: criteria of cutaneous melanoma progression*. **G. Argenziano, G. Fabbrocini, P. Carli et al**. J Am Acad Dermatol, 1997, Vol. 37, pp. 68-74.
10. *A possible new tool for clinical diagnosis of melanoma: The computer*. **N. Cascinelli, M. Ferrario, T. Tonelli, E. Leo**. J Am Acad Dermatol, 1987, Vol. 16, pp. 361-367.
11. *Computer image analysis in the diagnosis of melanoma*. **A. Green, N. Martin, J. Pfitzner, M. O'Rourke, and N. Knight**. J. Amer. Acad. Dermatol, 1994, Vol. 31, pp. 958-964.
12. *Comparison of segmentation methods for automatic diagnosis of dermoscopy images*. **T. Mendonca, A. Marcal, A. Vieira A, J. Nascimento, M. Silveira, J. Marques, J. Rozeira**. Proceedings of the 29th IEEE EMBS Annual International Conference, 2007, Vol. 1, pp. 6572-6575.
13. *Automated melanoma recognition*. **H. Ganster, A. Pinz, et al**. IEEE transaction on Medical Imaging, 2001, Vol. 20, pp. 233-239.
14. *Automated diagnosis of pigmented skin lesions*. **P. Rubegni, G. Cevenini, M. Burrioni, R. Perotti, G. Dell'Eva, P. Sbrano, et al**. International Journal of Cancer, 2002, Vol. 101, pp. 576-580.
15. *Digital image analysis for diagnosis of cutaneous melanoma. Development of a highly effective computer algorithm based on analysis of 837 melanocytic lesions*. **A. Blum, H. Luedtke, U. Ellwanger, R. Schwabe, G. Rassner, C. Garbe**. British Journal of Dermatology, 2004, Vol. 151, pp. 1029-1238.
16. *A methodological approach to the classification of dermoscopy images*. **M.E. Celebi, H.A. Kingravi and B. Uddin**. Computerized Medical Imaging and Graphics, 2007, Vol. 31, pp. 362-373.


17. *Dermoscopic image-analysis system: estimation of atypical pigment network and atypical vascular pattern.* **G. Betta, G. Di Leo, G. Fabbrocini, A. Paolillo, P. Sommella.** IEEE International Workshop on Medical Measurement and Applications, 2006, pp.63-67.
18. *Automatic Detection of Blue-White Veil and Related Structures in Dermoscopy Images.* **M. E. Celebi, H. Iyatomi, W. V. Stoecker, R. H. Moss, H. S. Rabinovitz, G. Argenziano, and H. P. Soyer.** Computerized Medical, 2008, Vol. 32. pp. 670-677.
19. *An Improved Internet-Based Melanoma Screening System with Dermatologist-like Tumor Area Extraction Algorithm.* **H. Iyatomi, H. Oka, M. E. Celebi, M. Hashimoto, M. Hagiwara, M. Tanaka, and K. Ogawa.** Computerized Medical Imaging and Graphics, 2008, Vol. 32, pp. 566-579.
20. *Digital image processing: an algorithmic introduction using Java.* **Burger, Wilhelm.** Springer, 2008.
21. *Uma Introdução às Support Vector Machines.* **Lorena A, Carvalho A.** RITA, 2007, Vol. 14.
22. *Máquinas de Vetores de Suporte aplicadas à classificação de defeitos em couro bovino.* **R. Rodrigues.** 2006.
23. *Extraction of specific parameters for skin tumour classification.* **M. Messadi, A. Bessaid, and A. Taleb-Ahmed.** Journal of Medical Engineering & Technology, 2009, Vol. 33, pp. 288-295.
24. *Digital Image Processing using Matlab.* **R. C. Gonzalez, R. E. Woods, S. L. Eddins.** Prentice Hall, 2004.
25. Wikipédia, a enciclopédia livre. [Online] <http://pt.wikipedia.org>.

Apêndices

I - Base de dados de imagens dermoscópicas


I.A – Imagens utilizadas no modelo proposto






Nota: Imagens com limites a vermelho foram excluídas após o processo de segmentação.


I.B – Imagens excluídas




II – Segmentação obtida por especialista (Dr. José Rozeira)

II.A – Segmentação para as imagens do apêndice I.A





II.B – Segmentação para as imagens do apêndice I.B



III – Pontuação ABCD e Classificação obtidas por especialistas (Dra. Joana Antunes e Prof. Paulo Filipe)

III.A – Classificação por especialistas das imagens do apêndice I.A

Número da Imagem	Pontuação ABCD (Dra. Joana Antunes)				Classificação (Prof. Paulo Filipe)
	Assimetria	Fronteira	Cor	Estruturas Diferenciais	Classificação ²
1	1	2	2	3	2
2	2	2	3	3	2
3	2	8	2	2	0
4	0	0	2	2	0
5	0	0	2	1	0
6	0	8	2	1	0
7	0	2	3	1	0
8	0	0	2	2	0
9	0	0	2	1	0
10	0	2	1	2	0
11	0	0	1	2	0
12	0	0	3	2	0
13	0	0	2	2	0
14	0	0	1	2	0
15	1	0	1	1	1
16	0	0	1	2	0
17	1	2	2	2	1
18	1	0	2	1	0
19	0	0	2	2	0
20	2	0	2	3	2
21	0	2	2	2	0
22	1	0	1	2	0
23	0	0	1	1	0
24	1	0	2	2	1
25	0	0	1	2	0
26	0	2	1	2	0
27	1	0	1	2	1
28	0	0	2	1	0
29	0	0	1	1	0
30	1	0	2	2	1
31	0	0	1	2	0
32	0	0	2	2	0
33	1	0	1	2	1
34	1	0	2	3	1
35	0	0	1	1	0
36	0	0	2	2	0
37	1	0	2	2	0
38	2	2	2	3	2
39	2	2	1	1	0
40	1	0	1	1	0
41	1	0	1	1	0
42	0	0	1	2	0
43	0	0	1	2	0
44	0	0	1	2	0

² Método de classificação: **2** – Lesão altamente suspeita de ser melanoma; **1** – Lesão suspeita de ser melanoma; **0** – Lesão benigna.

III.B – Pontuação ABCD obtida pelo sistema automático para as imagens do apêndice I.A

Número da Imagem	Pontuação ABCD (Sistema Automático)			
	Assimetria	Fronteira	Cor	Estruturas Diferenciais
1	2	2	1	3
2	2	0	2	2
3	2	1	3	2
4	1	2	2	3
5	0	0	1	1
6	0	2	2	1
7	0	1	1	1
8	0	0	1	2
9	0	0	2	1
10	0	1	1	2
11	0	1	1	2
12	0	1	1	2
13	0	1	3	2
14	0	2	2	2
15	1	1	2	2
16	0	1	2	1
17	1	1	2	2
18	0	1	2	1
19	2	0	2	1
20	1	2	3	2
21	0	0	2	2
22	0	0	3	2
23	0	1	1	2
24	0	0	2	2
25	0	0	1	1
26	0	3	2	2
27	2	1	2	2
28	1	1	2	2
29	0	3	1	2
30	0	0	2	2
31	1	2	1	2
32	1	1	2	2
33	1	1	1	2
34	1	1	2	3
35	0	3	2	2
36	0	1	2	2
37	0	1	2	2
38	2	1	3	2
39	2	0	2	2
40	0	3	1	2
41	2	1	1	1
42	0	2	1	2
43	1	0	1	2
44	2	1	1	2