

Faculdade de Engenharia da Universidade do Porto



FEUP

**Avaliação automática do resultado estético do
tratamento conservador do cancro da mama**

Luís Daniel Torres Rebelo

Dissertação realizada no âmbito do
Mestrado Integrado em Engenharia Electrotécnica e de Computadores
Major Telecomunicações

Orientador: Prof. Dr. Jaime dos Santos Cardoso

Junho de 2008

© Luís Daniel Torres Rebelo, 2008

Resumo

Hoje em dia, a elevada taxa de sobrevivência alcançada com o tratamento conservador do cancro da mama torna-o num procedimento padrão como método terapêutico. Porém, o resultado estético do tratamento é uma questão essencial que preocupa a comunidade médica devido à redução da qualidade de vida das pacientes. A avaliação da aparência do peito é um aspecto importante para o melhoramento dos métodos de tratamento e validação das melhores práticas. Algumas medidas foram definidas com o objectivo de quantificar características como a visibilidade da cicatriz, diferenças de cor e assimetrias do peito. Actualmente, a avaliação resultado estético do tratamento do cancro da mama é efectuada por um grupo de observadores, mas os resultados não são reprodutíveis devido às variações intra e inter-observador. Além disso, é uma tarefa que consome tempo e deve ser feita por especialistas, e daí resulta a necessidade de utilização de sistemas automáticos de avaliação.

O objectivo deste trabalho é investigar e desenvolver algoritmos para extracção automática das posições dos mamilos em imagens frontais das pacientes. As localizações dos mamilos fornecem uma informação importante que é utilizada na estimação das assimetrias mamárias. A abordagem adoptada para a detecção de mamilos foi separada em duas etapas: primeiro realiza-se uma detecção de pele que reduz a área de pesquisa e seguidamente é realizada a detecção mamilo. Para a detecção da pele foram testados três tipos de classificadores: regiões de cor explicitamente definidas, um classificador Gaussiano e uma rede neural usando um algoritmo Perceptrão Multicamada. Para extrair as posições do mamilo, foram implementadas uma rede Perceptrão Multicamada e Máquinas de Vectores de Suporte.

Por fim, este estudo compara os resultados dos classificadores de pele e de mamilos usando uma base de dados com 190 imagens (114 para treino dos classificadores e 76 para teste do sistema). Os classificadores de Perceptrão Multicamada e as Máquinas de Vectores de Suporte tiveram os melhores resultados porque integraram conhecimentos a prior relativo às imagens. Estes resultados poderão ser facilmente adaptados a outras aplicações, como é o caso da cirurgia estética ou utilizados como um filtro para bloqueio de conteúdos pornográficos.

Abstract

In our days, the high survival rate achieved with the Breast Cancer Conservative Treatment (BCCT) makes it a standard procedure as a therapy method. However, the aesthetic outcome of the treatment is a major concern for the medical community because it reduces the patients' quality of life. The evaluation of the breast appearance is an important issue in order to improve the treatment methods and validate the best practices. Some objective measurements have been defined to quantify features like the scar visibility, colour differences and breast asymmetry. Presently, the quality assessment of the outcomes of the breast cancer treatment is performed by a group of observers but the results are poorly reproducible because the intra and inter-observer variability. Besides, this is a time consuming task that must be done by experts, so it is required to use one automatic evaluation system.

The purpose of this work is to investigate and develop algorithms to automatically extract the nipple positions from patients' frontal images. The nipple locations provide important information that is used to estimate breast asymmetries. The approach followed for the nipple detection was divided into two steps: the first one does a skin detection that reduces the search area and then is performed the nipple detection. For the skin detection it was tested three types of classifiers: one explicitly defined color regions, a Gaussian classifier and a neural network using a Multilayer Perceptron algorithm. To extract the nipple positions it was implemented a Multilayer Perceptron network and a Support Vector Machine.

Finally this study compares the results of the skin and nipple classifiers using a database with 190 images (114 for training the classifiers and 76 to test the system). The Multilayer Perceptron and Support Vector Machine classifiers gave the best results because they were capable to integrate background knowledge about the images. These results could be easily adapted to other applications like cosmetic surgery or to be used as a filter for pornographic content blocking.

Agradecimentos

Agradeço a toda equipa do projecto BCCT.core pela forma como me acolheram e apoiaram desde o primeiro dia.

Gostaria de fazer um agradecimento especial ao Dr. Jaime dos Santos Cardoso pela oportunidade que me deu para colaborar no projecto BCCT.core e pela orientação da tese mostrando-se sempre disponível a ajudar.

Por fim, agradeço à minha família e amigos por estarem presentes em todos os momentos e pela força que sempre me transmitiram.

A todos vocês o meu muito obrigado!

Índice

Resumo	iii
Abstract.....	v
Agradecimentos	vii
Índice.....	ix
Lista de figuras	xi
Lista de tabelas	xiii
Abreviaturas e Símbolos	xv
Capítulo 1	1
Introdução.....	1
1.1 Motivação	1
1.2 O projecto BCCT	2
1.3 Objectivos.....	3
1.4 Estrutura do relatório	3
1.5 Contribuições relevantes	4
Capítulo 2	5
Estado da arte	5
2.1 Redes neuronais artificiais (RNA)	5
2.1.1 Perceptrão Multicamada (MLP)	7
2.2 Máquinas de Vectores de Suporte (SVM).....	8
2.3 Segmentação de imagens.....	10
2.3.1 Metodologias genéricas para segmentação de imagens.....	10
2.3.2 Modelos colorimétricos de detecção de pele humana	11
2.3.3 Detecção de mamilos	14
2.3.4 Avaliação do resultado estético do BCCT.....	17
2.4 Ferramentas de apoio à investigação	19
2.4.1 WEKA - <i>Waikato Environment for Knowledge Analysis</i>	19
2.4.2 MATLAB - <i>MATrix LABbtoratory</i>	19
2.4.3 LabVIEW - <i>Laboratory Virtual Instrument Engineering Workbench</i>	19
Capítulo 3	21
Especificações técnicas.....	21

3.1	Requisitos do sistema	21
3.2	Descrição da base de dados.....	22
Capítulo 4	25
Implementação dos algoritmos.....		25
4.1	Arquitectura do sistema	25
4.2	Segmentação de pele	26
4.2.1	Regiões de cor explicitamente definidas.....	27
4.2.2	Modelo aproximado das distribuições das componentes CrCb dos pixels.....	29
4.2.3	Rede Perceptrão Multicamada	31
4.3	Pós-processamento	33
4.4	Detecção de mamilos	34
4.4.1	Segmentação de mamilos	34
Capítulo 5	39
Comparação dos resultados		39
5.1	Segmentação de pele	39
5.1.1	Regiões explicitamente definidas.....	39
5.1.2	Modelo Gaussiano Simples	40
5.1.3	Rede Perceptrão Multicamada	42
5.2	Detecção de mamilos	44
5.2.1	Máquinas de Vectores de Suporte	44
5.2.2	Redes Perceptrão Multicamada	45
Capítulo 6	47
Conclusão		47
6.1	Perspectivas futuras.....	47
Referências	49
Anexos	51

Lista de figuras

Figura 1 - Funcionamento de um neurónio artificial.....	6
Figura 2 - Exemplos de funções de activação usadas em redes neuronais. Função de Siebert à esquerda e uma função sigmóide à direita.	6
Figura 3 - Arquitectura de uma rede neuronal (adaptação de um <i>print screen</i> obtido com a ferramenta WEKA).	7
Figura 4 - Exemplo simples da aplicação do algoritmo SVM na separação de classes. Adaptação da imagem disponível em [10].	9
Figura 5 - Princípio de funcionamento das Máquinas de Vectores de Suporte (SVM) [11].	9
Figura 6 - Representação tridimensional dos modelos RGB (à esquerda) e HSV (à direita).	11
Figura 7 - Processo de correcção de cor com um factor de 0.6 de ponderação da equalização. Figura extraída de [1].	17
Figura 8 - Extracção dos índices de visibilidade da cicatriz.[1].	18
Figura 9 - <i>Print screen</i> da aplicação BCCT.core.	18
Figura 10 - Exemplos de imagens com fundo controlado.	23
Figura 11 - Dois exemplos de imagens sem fundo controlado.	23
Figura 12 - Composição da base de dados.	23
Figura 13 - Imagem manualmente segmentada com extracção da classe “fundo”.	24
Figura 14 - Diagrama de funcionamento do sistema.	25
Figura 15 - Imagem <i>grayscale</i> usando um classificador Gaussiano.	29
Figura 16 - Histograma da imagem <i>grayscale</i> do classificador Gaussiano.	30
Figura 17 - Detecção do limiar de classificação do histograma da imagem de probabilidades.	30
Figura 18 - Diagrama funcional dos módulos implementados para o classificador Gaussiano.	31
Figura 19 - Probabilidade espacial da distribuição dos pixels de pele na imagem.	32

Figura 20 - Exemplo do funcionamento dos filtros de pós-processamento aplicados numa imagem com erros de segmentação. 1. imagem binarizada; 2. imagem após remoção de artefactos; 3. imagem com preenchimento de buracos; 4. extracção do rectângulo envolvente.	34
Figura 21 - Aproximação da distribuição dos mamilos por uma mistura de Gaussianas (direita e esquerda).	36
Figura 22 - Exemplos de <i>templates</i> de pele.	37
Figura 23 - Exemplos de <i>templates</i> de mamilos.	37
Figura 24 - Representação gráfica da distribuição Gaussiana.	41

Lista de tabelas

Tabela 1 - Diferentes metodologias para classificação de pele	12
Tabela 2 - Comparação entre os resultados dos classificadores de regiões RGB e HSV	39
Tabela 3 - Parametrização da distribuição Gaussiana no espaço CrCb.....	40
Tabela 4 - Resultados para o classificador usando uma distribuição Gaussiana	41
Tabela 5 - Resultados para segmentação de pele usando uma rede MLP com diferentes atributos de entrada.....	42
Tabela 6 - Resultados obtidos variando os parâmetros de aprendizagem da rede MLP para classificação de pele	43
Tabela 7 - Resultados SVM kernel polinomial	44
Tabela 8 - Resultados SVM kernel RBF com complexidade=1.0 e gama=0.01	44
Tabela 9 - Resultados para segmentação de pele usando uma rede MLP com diferentes atributos de entrada.....	45

Abreviaturas e Símbolos

Lista de abreviaturas (ordenadas por ordem alfabética)

BCCT	<i>Breast Cancer Conservative Treatment</i>
CSV	<i>Comma-Separated Values</i>
FCT	Fundação para a Ciência e a Tecnologia
FEUP	Faculdade de Engenharia da Universidade do Porto
FMUP	Faculdade de Medicina da Universidade do Porto
HSV	<i>Hue Saturation Value</i>
INESC	Instituto de Engenharia de Sistemas e Computadores
LabVIEW	<i>Laboratory Virtual Instrument Engineering Workbench</i>
LoG	<i>Laplacian of Gaussian</i>
LUT	<i>Look Up Table</i>
MATLAB	<i>Matrix Laboratory</i>
MLP	<i>MultiLayer Perceptron</i>
MSOM	<i>Modified Self-Organizing Map</i>
OCR	<i>Optical Character Recognition</i>
RGB	<i>Red Green Blue</i>
RBF	<i>Radial Basis Function</i>
RNA	Redes Neurais Artificiais
SMO	<i>Sequential Minimal Optimization</i>
SOM	<i>Self-Organizing Map</i>
SVM	<i>Support Vector Machines</i>
WEKA	Waikato Environment for Knowledge Analysis

Capítulo 1

Introdução

1.1 Motivação

Ao longo dos anos, a taxa de sucesso na cura do cancro da mama tem aumentado progressivamente como consequência do melhoramento das técnicas de tratamento e diagnóstico. Um problema comum associado às técnicas vigentes usadas no tratamento da doença é o facto de frequentemente induzirem deformações na aparência do peito das pacientes. Apesar da elevada eficiência do método conservador na cura da doença, a operação de remoção do tumor induz alterações inestéticas com consequências físicas e psicológicas para as pacientes.

Neste contexto, os objectivos do tratamento do cancro da mama não se reduzem à cura da doença havendo um esforço efectivo na minimização dos impactos na qualidade de vida das pacientes a nível do pós-operatório da cirurgia. Com o intuito de estabelecer uma caracterização objectiva dos efeitos inestéticos resultantes do tratamento, foram definidos índices aceites pela generalidade dos clínicos e que traduzem atributos ao nível da visibilidade da cicatriz, assimetrias do peito e diferenças de cor. A extracção dos referidos índices baseia-se na medição de pontos chave no peito da pessoa seguido da aplicação das respectivas fórmulas matemáticas. A quantificação destes elementos é fundamental como ferramenta de suporte ao melhoramento das técnicas existentes podendo, inclusivamente, funcionar como um guia para a selecção dos tratamentos mais adequados a cada caso concreto. Estas medidas de avaliação estética também facilitam a compreensão das implicações de cada um dos parâmetros na qualidade de vida das pacientes.

Actualmente, a avaliação estética dos resultados é realizada manualmente por um painel de observadores especializados. Apesar da definição de parâmetros chave permitir uma

2 Introdução

uniformização dos critérios de avaliação, a necessidade de intervenção humana neste processo apresenta diversos inconvenientes. Em primeiro lugar, a determinação manual dos pontos chave está dependente da pessoa que executa a medição o que suscita variações inter e intra-observador. Além disso, a medição manual é um trabalho moroso e necessita do recurso a pessoal especializado.

Para ultrapassar as limitações referidas, urge a necessidade de automatização de todo o processo de avaliação estética. Existem projectos de investigação presentemente em curso que visam investigar mecanismos automáticos que simulem de modo sistemático a avaliação de imagens de pacientes submetidas ao tratamento conservador do cancro da mama.

O trabalho apresentado nesta dissertação incide na localização automática dos mamilos em imagens frontais fotografadas pelos clínicos após a intervenção cirúrgica sobre a paciente. A localização dos mamilos permite a dedução de importantes propriedades que quantificam o grau de assimetria dos mamilos, nomeadamente o índice de *Breast Retraction Assessment* (BRA), o *Upward Nipple Retraction* (UNR) e o *Breast Compliance Evaluation* (BCE).

1.2 O projecto BCCT

Esta dissertação insere-se no projecto de investigação financiado pela FCT denominado "Advanced Objective Method for the Evaluation of the Aesthetical Result of Breast Interventions". O desenvolvimento deste projecto decorre de uma parceria entre o INESC Porto e a FMUP. Como resultado da investigação nasceu a aplicação BCCT.core.

O BCCT.core [1][2] é uma ferramenta vocacionada para realizar uma avaliação objectiva do resultado estético do tratamento conservador do cancro da mama. Neste momento, a aplicação desenvolvida tem um funcionamento semi-automático, isto é, requer uma intervenção inicial do utilizador para a marcação de alguns pontos de referência, nomeadamente a posição dos mamilos, os pontos extremos dos contornos mamários e a sinalização de dois pontos externos (um ao nível do esterno e outro para definição da escala). Com base nestas referências, a aplicação efectua uma detecção automática dos contornos mamários. Em paralelo, é realizada uma correcção de cor sobre a imagem e, por fim, são calculados diversos índices que são disponibilizados ao utilizador. É de salientar que a própria aplicação combina os índices obtidos apresentando uma classificação final da imagem numa escala de excelente a mau com base em padrões predefinidos.

Para atingir os objectivos do projecto, é fulcral garantir a extracção automática dos pontos de referência pois só assim o sistema se tornará completamente autónomo.

1.3 Objectivos

Os objectivos propostos para esta dissertação focaram essencialmente a problemática da automatização da extracção da posição dos mamilos em imagens frontais de pacientes submetidas ao tratamento conservador do cancro da mama. Neste sentido, o trabalho desenvolvido visou o cumprimento dos seguintes objectivos primordiais:

- Estudar diferentes metodologias para segmentação de imagens e extracção de características;
- Desenvolver algoritmos automáticos de segmentação de pele humana e detecção de mamilos;
- Identificar características específicas das imagens processadas que favoreçam os processos de classificação e incorporar esse conhecimento à prior na optimização dos algoritmos;
- Realizar um estudo comparativo entre as diferentes soluções implementadas.

1.4 Estrutura do relatório

Este relatório é composto por seis capítulos. O primeiro capítulo é dedicado ao enquadramento do projecto, contexto global do problema, objectivos a alcançar, fazendo uma pequena descrição das contribuições alcançadas.

No segundo capítulo são descritos algoritmos, projectos e ferramentas existentes que permitem esclarecer as melhores estratégias de abordagem ao problema tendo em conta as virtudes e limitações de cada solução.

Após realizar a avaliação científica e tecnológica do estado da arte, são apresentados os requisitos do sistema e os recursos disponíveis, nomeadamente através de uma descrição da base de dados utilizada.

O capítulo “Implementação dos algoritmos” inicia com a visão global da arquitectura do sistema. Depois, os algoritmos implementados para cada bloco são descritos detalhadamente e por ordem cronológica de funcionamento.

Os resultados obtidos são apresentados no quinto capítulo e são acompanhados por uma análise crítica com comparação de resultados.

4 Introdução

Por fim, o último capítulo faz uma síntese do projecto e resume as principais conclusões obtidas.

1.5 Contribuições relevantes

Os resultados obtidos na elaboração deste trabalho permitiram produzir um conjunto de contribuições aplicáveis a sistemas que envolvem segmentação de pele e mamilos. Como exemplos de aplicações nesta área incluem-se os sistemas de reconhecimento facial e gestual, *tracking* para vídeo-vigilância, filtros para bloqueamento de imagens pornográficas e aplicações médicas como é o caso da cirurgia plástica por razões médicas ou estéticas.

A solução implementada abrangeu mecanismos de introdução de conhecimento *a priori* relativo às imagens processadas, favorecendo desta forma os processos de segmentação e classificação. Neste sentido, foram implementadas uma rede Percepção Multicamada (MLP) e um algoritmo de Máquinas de Vectores de Suporte (SVM).

Todas as imagens armazenadas na base de dados do projecto BCCT.core foram manualmente segmentadas. Este contributo revelou-se um complemento importante ao nível da implementação e teste de algoritmos de segmentação.

O trabalho apresenta um modelo Gaussiano para classificação de pele gerado a partir de imagens guardadas na base de dados.

Por fim, é efectuado um estudo comparativo entre diferentes metodologias para segmentação e detecção de mamilos de imagens frontais de pacientes operadas ao cancro da mama pelo método conservador.

Capítulo 2

Estado da arte

Tendo em conta os objectivos delineados para o trabalho, procedeu-se a uma investigação sobre projectos existentes cujos resultados possam ser aplicados no sistema proposto. A abordagem adoptada para a análise do estado da arte não se cingiu à análise de projectos sob a temática da inspecção e avaliação estética do peito de pacientes submetidas ao tratamento do cancro da mama. Na verdade, o contexto foi alargado a projectos com contributos relevantes nas áreas de segmentação de pele humana e detecção de mamilos.

Começaremos por rever os principais algoritmos de aprendizagem automática (*machine learning*). O esclarecimento inicial dos conceitos básicos subjacentes a estes algoritmos permite compreender a sua aplicação em situações concretas, as quais serão introduzidas posteriormente.

2.1 Redes neuronais artificiais (RNA)

Na génese das redes neuronais artificiais está uma tentativa de reproduzir um modelo simplificado do comportamento do cérebro humano. Este tema tem sido alvo de inúmeros trabalhos científicos fruto fundamentalmente da diversidade de áreas de aplicação das redes neuronais. A título de exemplo pode-se mencionar áreas como a robótica, auxílio ao diagnóstico médico [3], segmentação de imagens [4][5], reconhecimento de padrões (faces [6] [7], gestos, OCR [8], voz, etc.), previsão de acontecimentos [9], etc.

Estabelecendo a analogia com o funcionamento cérebro humano, as redes neuronais recebem estímulos e tomam decisões procurando deduzir correlações entre os padrões de entrada e resultados à saída. A figura 1 exemplifica a estrutura de “neurónio padrão” habitualmente

6 Estado da arte

usada na modelação de redes neuronais artificiais, com a indicação das respectivas fórmulas matemáticas associadas.

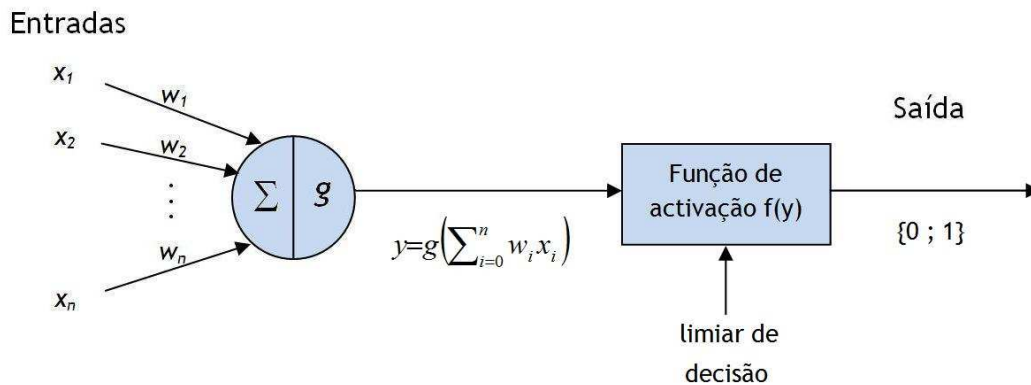


Figura 1 - Funcionamento de um neurónio artificial.

Como se pode observar pela figura anterior, é aplicada uma função de activação depois de se realizar o somatório das entradas multiplicadas pelos respectivos pesos. Existem várias funções que podem ser usadas para activação da saída, tais como: funções lineares, de degrau, rampa, hiperbólicas, de Siebert e sigmóides (ver exemplos na figura 2). Actualmente, as funções sigmóides são as mais utilizadas.




Figura 2 - Exemplos de funções de activação usadas em redes neuronais. Função de Siebert à esquerda e uma função sigmóide à direita.

Tal como se pode observar pela figura 3, o modelo das redes neuronais é constituído por três camadas correspondentes aos nós de entrada, intermédios (escondidos) e de saída. Os nós (neurónios) encontram-se interligados e são atribuídos coeficientes sinápticos às conexões. A determinação dos pesos das ligações é obtida através de um processo iterativo de aprendizagem.

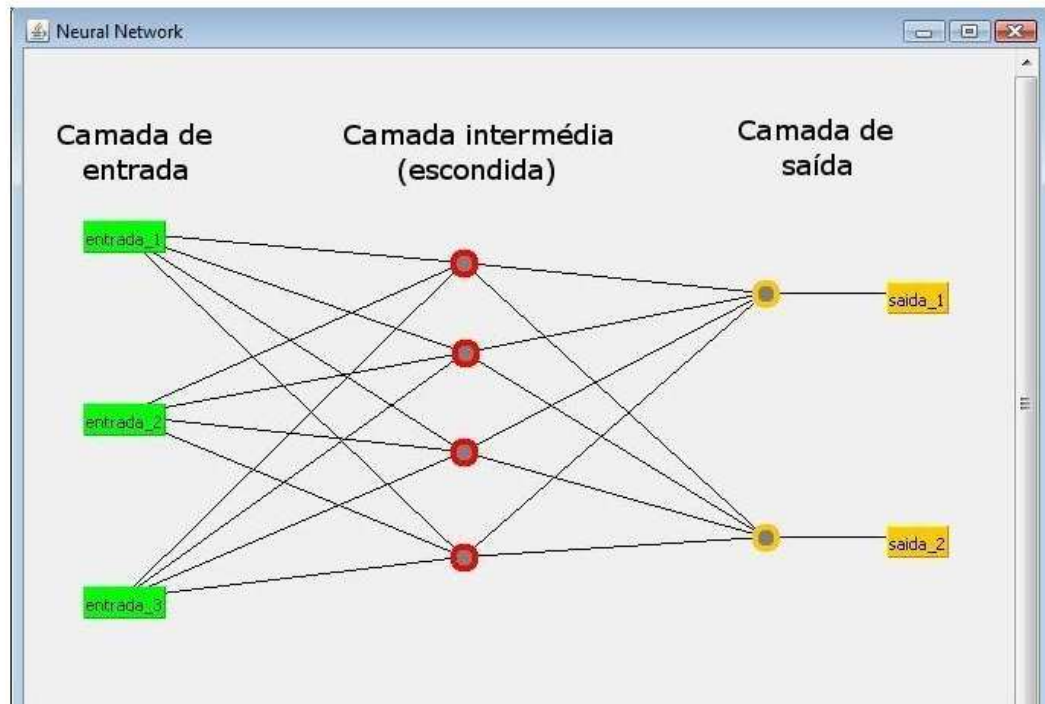


Figura 3 - Arquitectura de uma rede neural (adaptação de um *print screen* obtido com a ferramenta WEKA).

Os métodos de aprendizagem das redes neuronais dividem-se em três tipos básicos: supervisionado, não supervisionado e por reforço.

Nos algoritmos supervisionados, a rede é previamente treinada com um conjunto de dados de entrada e respectivas saídas. Com base nesta informação, a rede ajusta iterativamente os pesos das conexões e os limiares de activação e, desta forma, vai optimizando o processo de classificação.

Por outro lado, nos algoritmos não supervisionados a rede procura organizar os dados em classes cujas instâncias apresentem atributos correlacionados.

Nas redes com aprendizagem por reforço, um agente interage com o “mundo” fazendo observações e aplicando acções. A cada acção está associado uma recompensa ou uma punição e, com base nisto, a rede deve ser capaz de “ir aprendendo”, maximizando a diferença entre as recompensas e os “castigos”.

2.1.1 Perceptrão Multicamada (MLP)

As redes Perceptrão Multicamada (*MultiLayer Perceptron*) são também conhecidas por redes (*feedforward*) porque cada neurónio da rede só pode estar conectado a unidades da camada seguinte. Deste modo, o fluxo do processamento desde a entrada até à saída é unidireccional, o que a diferencia de outras redes com realimentação (redes *feedback*) como é o caso das redes de Hopfield.

Como o próprio nome indica, as redes Percepção Multicamada permitem a definição de múltiplas camadas escondidas o que é bastante útil para resolução de problemas em que a separação entre classes não é linear.

Este modelo exige uma fase de treino supervisionado para que a rede ajuste os coeficientes das conexões e desta forma “aprenda” como deverá ser a relação entre padrões de entrada e saída. No algoritmo de treino, os pesos sinápticos são aleatoriamente inicializados com valores pequenos devido à ausência de conhecimento. Depois são fornecidos à rede exemplos de vectores de entrada e a respectiva saída supervisionada. Com base nesta informação, a rede aplica a entrada recebida e determina a sua estimação para a saída. No passo seguinte, o sinal de saída do exemplo é retropropagado até à entrada e são comparados os erros relativamente à estimação inicial. Então, a rede ajusta iterativamente os coeficientes das conexões de modo a minimizar os erros entre a estimação e os exemplos supervisionados.

Alguns dos métodos de aprendizagem destas redes precisam que a função de activação seja derivável, sendo que a função de activação mais usada é a sigmóide (ver figura 2).

Existem parâmetros de configuração destes algoritmos que influenciam o modo de optimização da aprendizagem, nomeadamente o *learning rate* e o *momentum*. O *learning rate* influencia o ritmo de aprendizagem e quanto maior for o seu valor maior é a variação dos pesos da rede em cada iteração o que permite acelerar o processo de treino, embora isso possa conduzir a rede a uma optimização local do problema. Por outro lado, a solução ideal do problema também pode não ser atingida se as variações forem demasiado lentas. Através do *momentum*, é definido um factor de ponderação da modificação dos pesos tendo em conta o seu valor anterior permitindo atenuar as variações de aprendizagem com ritmos elevados. Desta forma, o resultado do processo de treino depende da combinação entre estes dois parâmetros, sendo necessário procurar o melhor compromisso entre a rapidez de treino e a eficiência atingida o que depende do problema analisado.

2.2 Máquinas de Vectores de Suporte (SVM)

Tal como nas redes Percepção Multicamada, este método insere-se na categoria de algoritmos com aprendizagem supervisionada. As Máquinas de Vectores de Suporte são classificadores lineares que maximizam a distância geométrica entre o subespaço vectorial das classes. Na realidade, os vectores de suporte da rede correspondem aos vectores que definem a largura da margem do hiperplano que maximiza de separação entre as classes (ver figura 4).

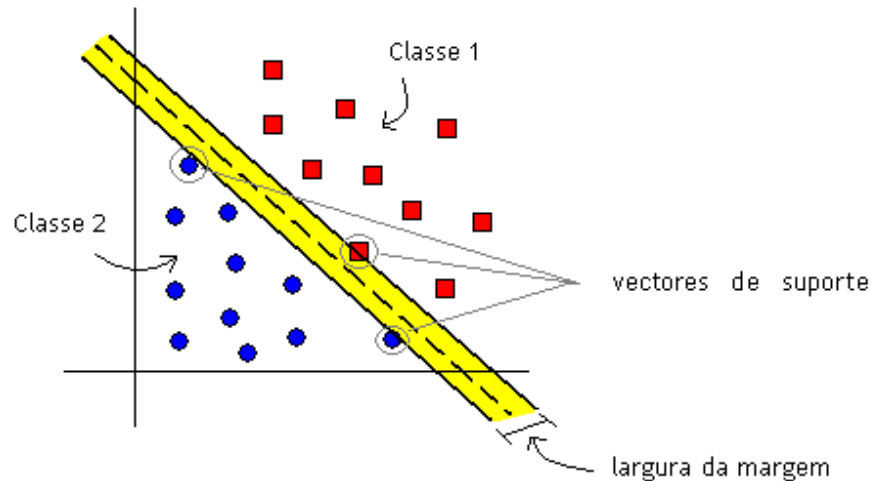


Figura 4 - Exemplo simples da aplicação do algoritmo SVM na separação de classes. Adaptação da imagem disponível em [10].

No entanto, nem sempre é possível estabelecer directamente uma separação linear entre classes. Em geral, os dados à entrada da rede são mapeados por uma função matemática (*kernel*) para um novo domínio de vectores de características (*features*). Esta conversão aumenta as dimensões do espaço o que possibilita a definição de um hiperplano linear que minimiza os erros de classificação. Este processo de transformação vectorial é demonstrado pela figura 5.




Figura 5 - Princípio de funcionamento das Máquinas de Vectores de Suporte (SVM) [11].

Este problema de optimização da separação de classes pode ser resolvido recorrendo a diferentes métodos. Um dos métodos habitualmente implementados para resolução deste problema é o algoritmo *Sequential Minimal Optimization* (SMO).

Relativamente às funções de *kernel*, pode-se optar por um *kernel* polinomial ou uma função de base radial (*Radial Basis Function*). A principal diferença entre eles é que o segundo permite definir fronteiras mais complexas.

2.3 Segmentação de imagens

2.3.1 Metodologias genéricas para segmentação de imagens

A segmentação de uma imagem consiste na decomposição da imagem nos seus elementos constituintes. Um exemplo simples deste processo seria a segmentação de uma imagem panorâmica de uma praia decompondo-a em zonas correspondentes às classes “mar”, “céu” e “areia”.

Tendo em conta que a segmentação automática de imagens é um problema comum em aplicações que envolvem processamento de imagem e/ou vídeo, foram desenvolvidos vários procedimentos que se encontram descritos na literatura da especialidade [12].

Existem diversas estratégias que podem ser seguidas na resolução de problemas de segmentação, sendo que a eficiência de cada algoritmo está intrinsecamente relacionada com as características das imagens processadas. Um método habitualmente utilizado devido à sua simplicidade de implementação é designado por *thresholding*, no qual são estabelecidos valores de limiar para cada uma das classes de pixels. Este limiar é normalmente definido a partir da análise do histograma da imagem. O *thresholding* pode ser modificado para que se adapte a características específicas das imagens como é o caso do *thresholding* variável em que se definem limiares locais para diferentes zonas da imagem.

Em oposição ao método anterior, que classifica pixels com níveis semelhantes de cor (*grayscale* ou por componente de um determinado espaço de representação de cor), a segmentação pode ser realizada através da detecção de orlas correspondentes à transição de classes. Estas descontinuidades podem ser identificadas através da aplicação de transformadas Hough ou simplesmente usando filtros passa-alto do tipo laplaciano; embora estes últimos sejam geralmente precedidos de filtros passa-baixo para suavização da imagem de modo atenuar o ruído.

Outra categoria de métodos para segmentação de imagens são os designados por segmentação sequencial. A grande diferença desta técnica face às demais está no facto de ser um método iterativo de classificação, e por isso, o resultado da segmentação de um determinado pixel depende da classificação dos resultados dos restantes pixels. Pelo facto da classificação dos pixels não ser independente implica que não se pode realizar o processo em paralelo e daí, portanto, a designação de segmentação sequencial. Como exemplo de algoritmos baseados neste paradigma encontra-se o *raster tracking* (seguimento por varrimento) e o *region growing* (crescimento de regiões). Ambos os métodos baseiam-se numa definição de um critério exigente de ruptura (mudança de classes) seguido por um critério brando de agregação de pixels vizinhos.

2.3.2 Modelos colorimétricos de detecção de pele humana

Os modelos colorimétricos para detecção de pele humana são algoritmos de segmentação específicos para a classificação dos elementos “pele” e “não pele” de imagens. Com efeito, estes classificadores procuram integrar conhecimento *a priori* relativo à cor da pele humana evidenciando as suas características unívocas face ao conjunto “não pele”.

Neste domínio encontram-se publicados inúmeros trabalhos científicos. Um dos aspectos mencionados nestes estudos é a importância da selecção do espaço de representação de cor para a classificação de pele humana e demonstra-se que a variação do brilho é superior do que a parte cromática considerando os diferentes tons de pele e raças existentes [13]. Além disso, verifica-se que a componente do brilho apresenta uma maior dependência face às condições de iluminação da cena do que os atributos de cor. Embora o modelo de representação de cor mais comum a nível de computação gráfica seja o RGB¹, este não é prático para segmentação de pele humana pois não estabelece à partida a separação do brilho das componentes de cor do pixel. Para suprir as limitações do sistema RGB, sugere-se a utilização de modelos mais favoráveis ao processo de classificação como é o caso do rgb normalizado, HSV² e YCrCb³.

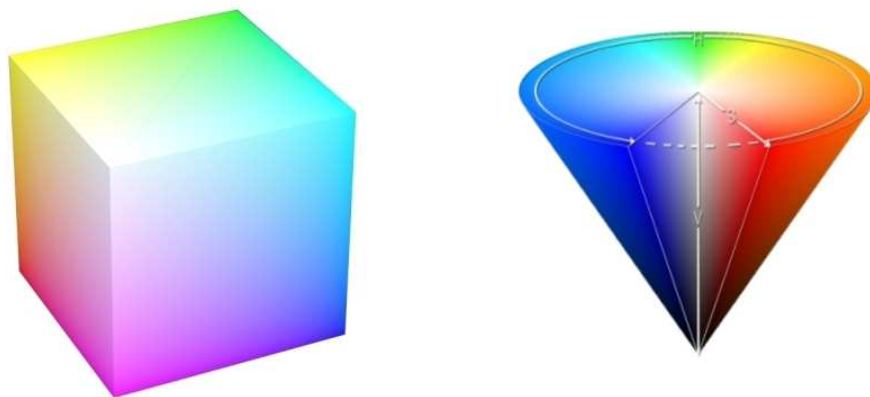


Figura 6 - Representação tridimensional dos modelos RGB (à esquerda) e HSV (à direita).

Fonte: Wikipedia.

Com base neste conhecimento e em experiências empíricas efectuadas, podem-se definir classificadores segundo várias perspectivas. Seguidamente, é apresentado um quadro que resume algumas das técnicas mais populares utilizadas para segmentação de pele [14][15].

¹ Sistema aditivo de representação de cores composto pelas componentes vermelho, verde e azul.

² Sistema de representação de cor constituído pelas componentes tonalidade, saturação e brilho.

³ O elemento Y é a luminosidade enquanto que o Cr e Cr representam a informação de cor.

Tabela 1 - Diferentes metodologias para classificação de pele

MÉTODO	DESCRIÇÃO
Regiões de cor explicitamente definidas	<ul style="list-style-type: none"> - Consiste em fixar um conjunto de regras que as componentes de cor do pixel terão de cumprir para que sejam classificadas como pele. - As condições impostas podem ser especificadas para qualquer espaço de representação de cor, embora essa escolha influencie a sua eficiência. - Tipicamente apresentam uma baixa complexidade computacional.
LUT ⁴ normalizada	<ul style="list-style-type: none"> - Cada componente do espaço de cor é dividida em n partes (por exemplo 64 por dimensão do espaço) e a partir de um conjunto de teste é criado um histograma de distribuição da cor pele. Por fim, o histograma é normalizado e guardado em memória sob a forma de LUT representando a probabilidade de cada combinação do espaço de cor sabendo que o pixel é pele (probabilidade condicional). - Para espaços de cor onde existe uma separação entre a luminosidade e as componentes de cor, é usual eliminar a componente de luminosidade reduzindo o espaço para 2 dimensões.
Classificador Bayesiano	<ul style="list-style-type: none"> - Baseia-se no teorema de Bayes (1), embora se possa usar a fórmula simplificada (2) porque apenas se pretende observar a relação entre $P(x pele)$ e $P(x não-pele)$, sendo que x é cor do pixel. - As probabilidades são obtidas directamente dos histogramas de pele e não-pele das imagens de treino. - É mais imune à ocorrência de erros comparativamente ao do método anterior porque tem em conta a distribuição estatística dos pixels não-pele no espaço de representação de cor.
Classificador Gaussiano	<ul style="list-style-type: none"> - Parametriza o histograma (normalmente 2D sem a componente da luminosidade) por uma distribuição Gaussiana (3) com base no cálculo da média e covariância (4). - Pode utilizar-se a parametrização simples ou de um modo refinado através da combinação de várias distribuições Gaussianas (5). - Para utilização de histogramas com as três componentes de cor, pode-se usar múltiplos <i>clusters</i> Gaussianos.

⁴ Tabela de transformação armazenada em memória no computador o que permite o acesso rápido à informação.

Mapas Auto-Organizados (SOM)	<ul style="list-style-type: none"> - É um dos tipos de redes neuronais não supervisionadas com maior utilização. - No fim da fase de treino é necessário identificar os neurões de saída que activam a classe pele. - A eficiência é pouco dependente do espaço de cor utilizado.
Perceptrão Multicamada	<ul style="list-style-type: none"> - Rede neuronal muito usada na resolução de problemas de classificação e regressão. - Necessita de uma fase de treino com dados supervisionados.

As equações (1.1) a (1.5) referem-se aos conceitos matemáticos mencionados na Tabela 1.

Teorema de Bayes:

$$P(pele | x) = \frac{P(x | pele)P(pele)}{P(x | pele)P(pele) + P(x | não - pele)P(não - pele)} \quad (1)$$

onde x é a cor do pixel.

Simplificação do teorema de Bayes:

$$\frac{P(x | pele)}{P(x | não - pele)} \geq \Phi \quad (2)$$

em que Φ representa o limiar de decisão definido para o classificador.

Função Gaussiana de densidade de probabilidade:

$$p(x | pele) = \frac{(e^{-\frac{1}{2}(x-m_s)^T C_s^{-1}(x-m_s)})}{2\pi |C_s|^{1/2}} \quad (3)$$

x corresponde ao vector de cor, m_s é o vector médio da distribuição e C_s é a matriz de covariância.

Cálculo do vector médio e matriz de covariância da distribuição gaussiana:

$$m_s = \frac{1}{n} \sum_{i=1}^n x_i \quad \text{e} \quad C_s = \frac{1}{n-1} \sum_{i=1}^n (x_i - m_s)(x_i - m_s)^T \quad (4)$$

Fórmula para modelação do histograma usando uma combinação de M distribuições Gaussianas:

$$p(x | pele) = \sum_{i=1}^M \pi_i p_i(x | pele) \quad (5)$$

Cada distribuição Gaussiana $p_i(x|pele)$ tem o seu próprio vector médio m_{Si} e a sua matriz de covariância C_{Si} . O parâmetro π_i é um factor de ponderação devendo-se verificar a condição

$$\sum_{i=1}^M \pi_i = 1.$$

É de notar que alguns dos métodos descritos retornam uma probabilidade de um determinado pixel pertencer à classe pele, sendo por isso necessário complementar o processo com um algoritmo de selecção de limiar de probabilidade para estabelecer a fronteira entre o que é classificado como pele e não-pele.

Alguns dos sistemas actuais usam métodos simples e rápidos, como é o caso das regiões de cor, obtendo uma estimacção inicial de zonas de pele e, a partir desta estimacção inicial, elaboram algoritmos mais sofisticados para aperfeiçoar a segmentação.

Como exemplos de aplicações com segmentação de pele incluem-se os sistemas de *tracking* de pessoas em video-vigilância, reconhecimento facial [6][7] e gestual, filtros automáticos de imagens obscenas[16][17], etc.

2.3.3 Detecção de mamilos

No estudo das soluções já existentes para detecção de mamilos, foram identificados três projectos com contributos relevantes nesta área.

Detecção de mamilos para filtragem de imagens obscenas [18]

Um dos trabalhos, designado por “*Neural Network-Based Nipple Detection for Obscene Pictures*”, foi desenvolvido na *Assumption University* da Tailândia e tem como alvo da sua investigação a criação de mecanismos de protecção de acesso a imagens de carácter obsceno em redes públicas de informação, nomeadamente distribuídos pela *Internet*. Assim sendo, é apresentada uma solução para a implementação de um filtro capaz de fazer um reconhecimento automático de características das imagens que permitam catalogar conteúdo obsceno impedindo visualização não desejada, principalmente por crianças. Na prática, é escolhida como condição para o accionamento do filtro a identificação de mamilos em imagens. Apesar de teoricamente os mamilos poderem localizar-se em qualquer posição na imagem dada a inexistência de conhecimento prévio sobre as mesmas, testes conduzidos pelo

projecto demonstraram que os mamilos normalmente não surgem nas bordas correspondentes a 20% da altura e da largura da imagem sendo, portanto, esta região excluída à partida da área de pesquisa.

A primeira fase do procedimento descrito no referido artigo consiste numa detecção de pele baseado no valor das componentes HSV de cada pixel da imagem. Foram realizadas experiências que conduziram à definição de um classificador com regiões explícitas no espaço HSV. Desta forma, é realizada uma filtragem preliminar do fundo sendo identificado os pixels de pele que serão candidatos à classificação de mamilos.

Após terminada a fase de localização de pele na imagem, a detecção dos mamilos é realizada através de uma rede do tipo SOM. Tal como foi mencionado anteriormente, os SOMs, na literatura portuguesa traduzido para Mapas Auto-Organizados ou simplesmente Mapas de Kohonen, pertencem à categoria de redes neuronais com aprendizado não supervisionado, isto é, o treino da rede é autónomo e tende a agrupar em classes as instâncias com base na semelhança dos seus atributos (vectores de entrada). Na entrada da rede são introduzidos *templates* 15x15 (resolução considerada comum para mamilos das imagens testadas) e a camada de saída dispõe de uma matriz de 20x20 nós. Foi introduzida uma modificação que limita a área de cobertura da activação dos nós da classe mamilos sendo por isso o algoritmo designado por *Modified Self-Organizing Map* (MSOM). Com esta alteração da rede foi possível reduzir a taxa de falsos positivos.

Em suma, este método utiliza uma solução simples e genérica para classificação de pele baseada no conhecimento empírico sobre as componentes de cor de pele humana. Devido à escassez de informação *a priori* relativa às imagens processadas, o reconhecimento dos mamilos é realizado recorrendo exclusivamente à informação de cor (componentes HSV no processamento para detecção de pele e *templates grayscale* para detecção dos mamilos).

Detecção de mamilos para quantificação do resultado estético do tratamento do cancro da mama

A detecção automática de mamilos no âmbito da avaliação estética do peito de mulheres submetidas a intervenção cirúrgica tem sido um problema comum aos projectos dedicados a esta temática. Efectivamente, existe um núcleo de investigação da Universidade de Texas [19] cujos objectivos são similares aos do projecto BCCT. A investigação levada a cabo por este projecto tem dado especial importância ao processo de detecção automática de mamilos por duas ordens de razões. Em primeiro lugar, a localização dos mamilos é uma característica que permite determinar vários índices de simetria. Em segundo lugar, os estudos efectuados demonstram que o processo de marcação destes pontos se revela consistente quando

realizado por observadores humanos, o que sugere que os mamilos serão pontos de referência em que é expectável a obtenção de bons resultados de automatização.

A abordagem seguida pelo grupo de investigação divide o processo de detecção de mamilos em três etapas fundamentais.

Na primeira fase, é realizado um pré-processamento das imagens em que é recortado o rectângulo envolvente do torso da pessoa na imagem. Este processo torna-se bastante simples devido ao facto de as fotografias terem sido obtidas sempre com um fundo azul facilmente separável do tronco das pacientes.

Depois de terminada a fase de pré-processamento, é aplicado um algoritmo para determinação das regiões potencialmente candidatas a serem consideradas mamilos. O algoritmo adoptado baseia-se num esquema de *template matching*⁵ de duas formas identificadas como representativas da morfologia dos mamilos. Uma primeira morfologia refere-se a mamilos cujo centro é o ponto mais escuro com um decaimento exponencial de intensidade para os contornos. Esta forma é representada por uma superfície Gaussiana invertida. A segunda situação comum reporta-se aos mamilos em que o factor preponderante não é o centro do mamilo mas sim os contornos que fazem a separação entre a aréola e a pele envolvente. Este formato é representado no modelo por uma distribuição Laplaciana de Gaussiana (LoG).

No entanto, os mamilos apresentam diferentes áreas consoante a paciente, sendo portanto necessário fazer um escalonamento para que as distribuições se adaptem ao formato concreto do mamilo. Foi estabelecida uma gama de pixels representativa do tamanho típico dos mamilos (entre 10 a 45 pixels). Por fim, a imagem é dividida em duas partes, esquerda e direita, e para cada uma delas é efectuada a correlação cruzada dos dois modelos. Para cada sub-imagem são assinalados os pontos com valores superiores de correlação.

Na última fase do processo de detecção de mamilos são eliminadas falsas detecções (falsos positivos). O princípio de funcionamento baseia-se numa estratégia Bayesiana na qual os valores de correlação anteriormente calculados são multiplicados por uma mapa de probabilidade associado à posição de cada potencial mamilo detectado. A estimação da posição dos mamilos corresponde ao valor máximo obtido para cada uma das sub-imagens esquerda e direita.

⁵ Técnica usada em processamento digital de imagem para reconhecimento de formas e padrões presentes nas imagens.

2.3.4 Avaliação do resultado estético do BCCT

Tal como referido na introdução, o *software* BCCT.core [1][2] apresenta-se como um importante apoio ao processo de avaliação do resultado estético do tratamento conservador do cancro da mama. Para isso, são combinados índices que representam características de assimetria, diferenças de cor e visibilidade da cicatriz.

Na caracterização das assimetrias são calculados índices absolutos e índices relativos. O principal inconveniente associado aos índices absolutos é o facto de necessitarem de uma marca adicional para calibrar a escala das medidas na imagem; enquanto que no caso das medidas relativas o seu valor é adimensional. Os índices calculados pela aplicação referem-se às assimetrias dos contornos mamários e da posição dos mamilos na imagem. A extracção dos contornos mamários é efectuada através de um algoritmo de contornos activos baseados em *splines* com 11 pontos de controlo. O utilizador marca inicialmente a posição dos mamilos e dos pontos extremos dos contornos mamários e depois, com base nestas referências, a aplicação extrai automaticamente os contornos oferecendo a possibilidade de o utilizador efectuar as correcções desejadas.

Para avaliar as diferenças de cor é aplicada uma correcção de cor prévia à extracção dos índices respectivos. A correcção de cor aplicada baseia-se numa equalização do histograma da imagem. No entanto, para evitar a distorção de cor na equalização introduz-se um factor de ponderação da equalização. Além disso, os pixels de fundo são excluídos do histograma através de uma segmentação prévia da imagem, o que permite aplicar a correcção de cor exclusivamente aos pixels correspondentes ao corpo da paciente. Este processo encontra-se evidenciado na figura 7. No último passo desta fase, o espaço de representação de cor é convertido do modelo RGB para CIE L*a*b* por ser um modelo perceptualmente mais uniforme e depois são obtidos os índices de assimetria de cor.




Figura 7 - Processo de correcção de cor com um factor de 0.6 de ponderação da equalização. Figura extraída de [1].

Por fim, a extracção dos índices de visibilidade da cicatriz é realizada a partir de uma análise local da imagem em torno de cada seio. Deste modo, o algoritmo divide cada seio em 12 sectores de 30° em torno do seio e com vértice no mamilo. São então determinados os histogramas de cor para cada sector e de seguida são obtidos os índices de semelhança de cor para os pares de sectores contíguos. A figura 8 ilustra este algoritmo.



Figura 8 - Extracção dos índices de visibilidade da cicatriz.[1]

Para além de apresentar os índices acima descritos, a aplicação possui uma funcionalidade que automaticamente classifica o resultado estético numa escala de Harris (excelente, bom, razoável e mau). A figura 9 apresenta um *print screen* da aplicação BCCT.core.




Figura 9 - *Print screen* da aplicação BCCT.core.

O sistema foi testado em 120 imagens de pacientes provenientes de três instituições portuguesas e que aceitaram participar no projecto. As imagens foram validadas por um painel de 24 peritos de 13 países diferentes. Os resultados apresentam uma taxa de acerto de 70%, uma precisão comparável ao resultado do melhor avaliador do painel de observadores.

2.4 Ferramentas de apoio à investigação

Para realizar a implementação dos algoritmos e teste do sistema, houve a necessidade de recorrer a plataformas de suporte à investigação. Neste sentido, é apresentada uma introdução sumária às ferramentas utilizadas.

2.4.1 WEKA - *Waikato Environment for Knowledge Analysis*

Esta plataforma reúne um conjunto de algoritmos de *Machine Learning*. Existem outras opções de software nesta área como é o caso do See5, WizWhy e do AutoClass. Porém, a preferência pela utilização do WEKA teve em conta a diversidade de algoritmos implementados, os quais se encontram convenientemente documentados. Uma outra importante vantagem é o facto de ser uma ferramenta *Open Source* licenciada ao abrigo da *General Public Licence* permitindo o acesso e edição do código fonte.

2.4.2 MATLAB - *MATrix LABborary*

O MATLAB é um *software* desenvolvido pela “The MathWorks” sendo bastante utilizado em instituições de ensino e centros de investigação. Esta plataforma permite combinar funcionalidades ao nível do cálculo numérico e, simultaneamente, disponibiliza uma linguagem de programação. Além disso, existem *toolboxes* com funcionalidades para áreas específicas como por exemplo para processamento de imagem, modelação de sistemas, *Machine Learning*, etc.

Existem diversos tutoriais e manuais de apoio que facilitam a sua aprendizagem.

2.4.3 LabVIEW - *Laboratory Virtual Instrument Engineering Workbench*

O LabVIEW é uma ferramenta da “National Instruments” que disponibiliza um ambiente gráfico para o desenvolvimento de aplicações. Pelo facto de ser uma linguagem de programação gráfica facilita a abstracção do código de baixo nível e permite visualização do fluxo dos dados o que se revela bastante útil principalmente para tarefas de *debugging*.

Tal como as aplicações acima apresentadas, encontram-se disponíveis livros, tutoriais e fóruns de apoio para esclarecimento de dúvidas.

Outro factor que influenciou a opção por esta plataforma de desenvolvimento deveu-se à familiaridade adquirida após a sua utilização em projectos anteriores.

Capítulo 3

Especificações técnicas

3.1 Requisitos do sistema

Na fase de concepção da arquitectura da aplicação, foram definidos um conjunto de pressupostos relativos às características das imagens submetidas ao *software* para os quais os algoritmos implementados deverão funcionar correctamente. Existem diversos factores como por exemplo as condições de iluminação na fase de aquisição das imagens, o *background*⁶ da imagem, etc., que podem condicionar o desempenho do sistema. Neste sentido, procurou-se minimizar as restrições técnicas reduzindo o seu impacto através de algoritmos robustos, garantindo desta forma uma ampla e fácil utilização da aplicação para um leque extenso de imagens.

Considerando os aspectos supracitados, pode-se fazer então uma clara distinção entre parâmetros considerados controlados e não controlados. Enquanto que os primeiros se apresentam como requisitos obrigatórios, por outro lado, os efeitos dos parâmetros não controlados deverão ser atenuados pela aplicação, embora obviamente possam afectar a precisão dos resultados. Seguidamente é apresentada uma listagem de condições que resume os parâmetros identificados como controlados e não controlados.

Parâmetros controlados:

- O JPEG é o formato de codificação das imagens suportado pelo sistema.
- As imagens devem focar a zona do tronco, desde o pescoço até à cinta da paciente.

⁶ Região exterior ao objecto de interesse na imagem, neste caso o fundo posterior ao corpo da paciente.

Parâmetros não controlados:

- A cor e textura do fundo presente nas imagens são um factor não controlado. O fundo poderá variar desde uma tela com uma tonalidade de cor distinta da pele humana até uma parede de um consultório médico o que será o caso mais prático do ponto de vista do utilizador.
- Dado o facto de as imagens submetidas à aplicação serem fotografadas pelo clínico, não foram definidos mecanismos de controlo prévio sobre as condições de iluminação de forma a facilitar a utilização do software. Contudo, uma imagem obtida com uma iluminação de cena deficiente induz uma distribuição não uniforme da luminosidade na imagem submetida à aplicação.
- Não existem restrições relativas à raça da pessoa, podendo ser tão dispares como pacientes de origem africana, asiática, europeia, sul-americana, etc.
- A resolução das imagens não é um parâmetro fixo embora seja recomendado um valor mínimo de 1.3 megapixels. O *aspect ratio*⁷ das imagens deverá aproximar-se preferencialmente do formato 4:3.
- A posição do tronco na imagem pode não ser central, podendo existir um desvio relativamente ao eixo horizontal.

3.2 Descrição da base de dados

Para efeitos de desenvolvimento e teste dos algoritmos implementados, recorreu-se a uma base de dados com imagens de pacientes operadas ao cancro da mama através do tratamento conservador.

Na base de dados foram identificadas duas categorias de imagem: com fundo controlado e sem fundo controlado, com 120 imagens pertencentes à primeira categoria e 70 relativas à segunda. A principal diferença entre estes dois tipos de imagens relaciona-se com a composição do fundo que, no caso das imagens sem fundo controlado, apresenta uma maior densidade de contexto o que dificulta significativamente o processo de segmentação. Além disso, enquanto que nas imagens com fundo controlado a tonalidade do fundo é normalmente em tons escuros ou azuis, nas imagens sem fundo controlado este contém frequentemente paredes em tons bege que facilmente se confundem com tonalidades de pele controlado (ver exemplos da figura 10 e 11).

⁷ Relação entre a resolução horizontal e vertical da imagem.



Figura 10 - Exemplos de imagens com fundo controlado.



Figura 11 - Dois exemplos de imagens sem fundo controlado.

Para treino dos algoritmos desenvolvidos para segmentação de pele e mamilos, utilizou-se 60% das imagens com fundo controlado e 60% das imagens com fundo não controlado, ou seja, 72 e 42 imagens respectivamente (ver figura 12).

Estas imagens foram seleccionadas aleatoriamente sendo que as restantes foram usadas para teste do sistema.

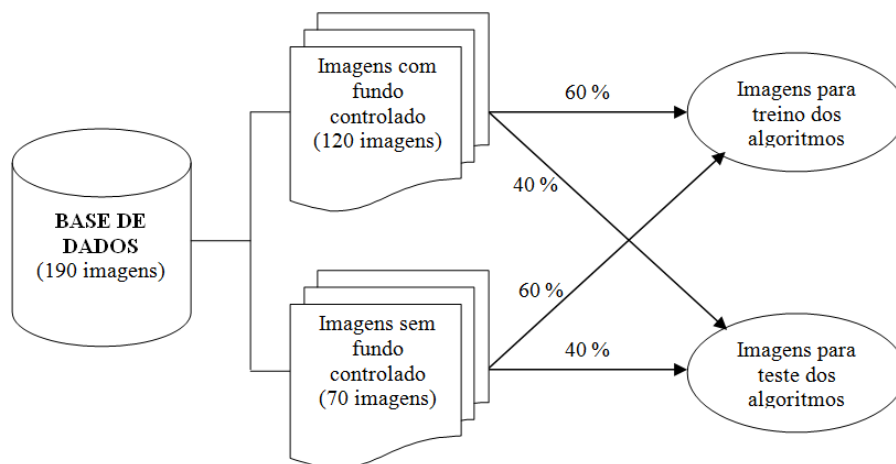


Figura 12 - Composição da base de dados.

24 Especificações técnicas

Para além do processo de geração aleatória de imagens para treino e teste do sistema, houve a necessidade de realizar uma segmentação manual da pele e registo das coordenadas da posições dos mamilos direito e esquerdo de cada uma das imagens na base de dados. Na segmentação manual foi utilizado um programa editor de imagem, ficando o fundo segmentado a branco (R=G=B=255 no formato RGB 24bits) e mantendo-se as cores da zona da pele. A imagem de exemplo apresentada na figura 13 refere-se à supervisão manual da imagem do lado esquerdo da figura 11.




Figura 13 - Imagem manualmente segmentada com extracção da classe “fundo”.

Por outro lado, a posição dos mamilos ficou registada num ficheiro no formato CSV⁸, novamente como resultado de uma inspecção manual das imagens.

A informação armazenada é essencial tanto para o treino de algoritmos de redes neuronais supervisionadas, como também para a obtenção das percentagens de acerto de cada algoritmo implementado.

⁸ Formato de arquivo de informação com os campos separados por virgulas e os registos separados por linhas.

Capítulo 4

Implementação dos algoritmos

4.1 Arquitectura do sistema

De seguida é apresentada uma breve descrição dos blocos que compõe a arquitectura do sistema, como representado na figura 14. A pormenorização de cada um dos algoritmos é realizada nas restantes secções deste capítulo.

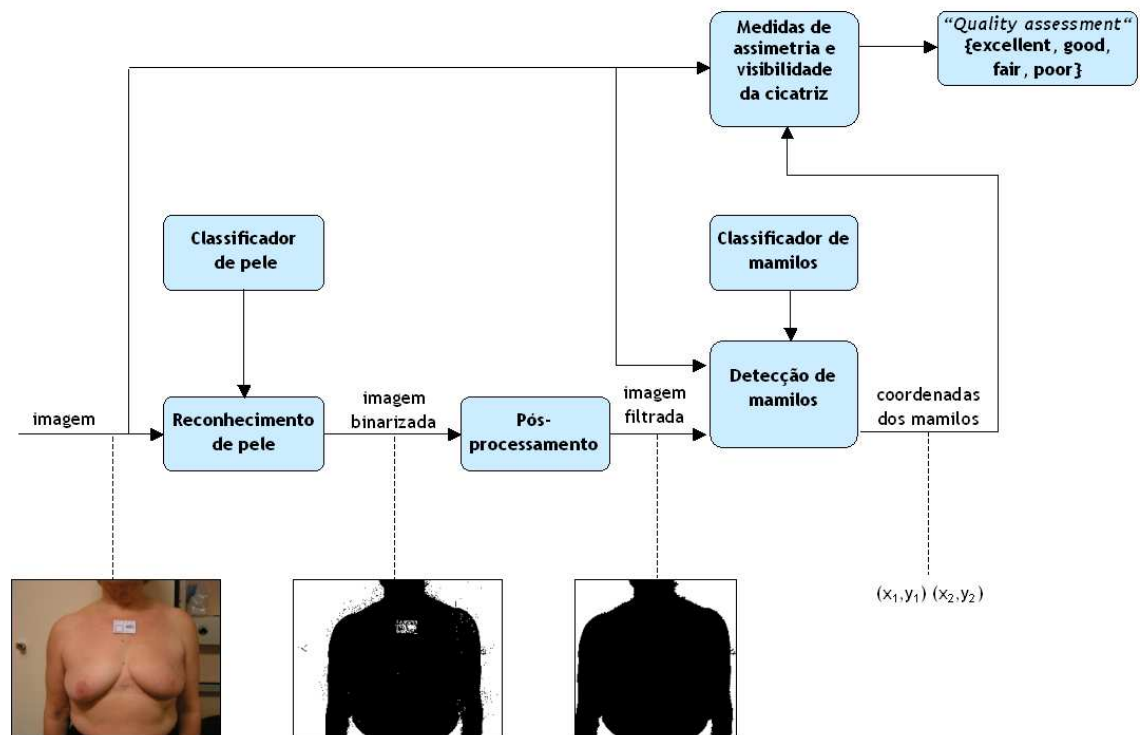


Figura 14 - Diagrama de funcionamento do sistema.

- **Reconhecimento de pele**

Este processo recebe uma imagem e aplica um algoritmo classificador obtendo-se como resultado uma imagem binarizada com os pixels de pele assinalados a preto e os restantes marcados com cor branca.

- **Classificador de pele**

Este bloco representa o algoritmo para classificação de pele. Foram implementados três tipos de classificadores e analisados os respectivos resultados.

- **Pós-processamento**

O pós-processamento do sistema procura corrigir eventuais erros da detecção de pele e extrai a região de interesse para a pesquisa de mamilos.

- **Detecção de mamilos**

Nesta fase é efectuada a localização das coordenadas dos mamilos na imagem original. Para auxílio do processo, o algoritmo recebe uma imagem proveniente do pós-processamento com indicação da região de interesse.

- **Medidas de assimetria e visibilidade da cicatriz**

Este processo já está implementado na aplicação BCCT.core e calcula índices para avaliação estética da imagem. Actualmente, a posição dos mamilos é indicada manualmente pelo utilizador. Futuramente o algoritmo será adaptado para receber automaticamente a posição dos mamilos.

- **Quality assessment**

Por fim, os índices de assimetria e visibilidade da cicatriz são computados sendo atribuído à imagem um valor na escala de excelente a mau. Esta funcionalidade já se encontra implementada no software BCCT.core.

4.2 Segmentação de pele

Na segmentação de pele é aplicado um determinado classificador sobre a imagem de entrada, obtendo-se como resultado uma imagem binarizada pelas classes “pele” e “não pele”.

No âmbito deste projecto foram testados três tipos de classificadores: um baseado em regiões do espaço de cor (RGB e HSV), outro segundo uma aproximação do espaço de cores CrCb por uma distribuição Gaussiana e, por fim, um classificador utilizando uma rede Percepção Multicamada customizada para as características das imagens submetidas ao

sistema. Esta abordagem permitiu a comparação do grau de eficiência destas soluções para a detecção de pele nas imagens testadas.

À entrada dos classificadores implementados efectua-se um redimensionamento de todas as imagens para uma resolução de 256x192. Este passo garante que todas as imagens testadas contribuem com a mesma quantidade de amostras (número de pixels) para a análise estatística dos resultados e, simultaneamente, permite acelerar o processamento das imagens. É de notar que a distorção introduzida pelo redimensionamento é desprezável tendo em conta que o *aspect ratio* de todas as imagens se aproximava do formato 4:3. Além disso, o redimensionamento não foi realizado pelo método *nearest-neighbor*, mas sim através do método bilinear o qual determina uma média de vizinhança o que permitiu minimizar os efeitos do *downsampling* nos resultados.

Em seguida, encontra-se uma descrição de cada uma das implementações.

4.2.1 Regiões de cor explicitamente definidas

Tal como foi referido no capítulo “Estado da arte”, este método de classificação define limites para as componentes de cor com base no conhecimento empírico das classes. O processamento da imagem é ponto-a-ponto podendo-se efectuar um varrimento vertical ou horizontal da imagem. Foram implementados duas versões deste classificador: uma usando o espaço de cor RGB e outra referente ao modelo HSV.

Modelo RGB

Os limites especificados para este classificador estão definidos no trabalho “*Human Skin Colour Clustering for Face Detection*” [20].

Assim, para um dado pixel ser considerado “pele” terá que obedecer integralmente às seguintes condições:

- $R > 95$;
- $G > 40$;
- $B > 20$;
- $\text{Máximo}(R,G,B) - \text{mínimo}(R,G,B) > 15$;
- $R - G > 15$;
- $R > B$.

O *script classificador_regioes_rgb* em anexo recebe de entrada o caminho para a pasta com as imagens para o classificador segmentar e a pasta com as imagens segmentadas que são utilizadas para que o código registe o número de acertos e falhas do classificador.

Modelo HSV

A implementação deste modelo baseou-se no processo de descrito no artigo “*Neural Network-Based Nipple Detection for Obscene Pictures*” [18].

A conversão entre o modelo de representação de cor RGB e HSV efectua-se aplicando as seguintes fórmulas:

$$V = \max$$

$$S = \begin{cases} \frac{\max - \min}{\max} & , \text{ se } \max \neq 0 \\ 0 & , \text{ se } \max = 0 \end{cases}$$

$$H = \begin{cases} 0 & , \text{ se } S = 0 \\ 60 \left(\frac{G - B}{\max - \min} \right) & , \text{ se } R = \max \\ 60 \left(2 + \frac{B - R}{\max - \min} \right) & , \text{ se } G = \max \\ 60 \left(4 + \frac{R - G}{\max - \min} \right) & , \text{ se } B = \max \end{cases}$$

A variável *max* mencionada nas fórmulas de conversão refere-se ao máximo valor das componentes RGB. Para realizar esta conversão é necessário que as componentes R, G e B estejam normalizadas para valores entre 0 e 1. Desta forma, como resultado desta conversão obtém-se um valor de brilho (V) e saturação (S) entre 0 e 1. Por sua vez, o valor de tonalidade (H) corresponde a um ângulo medido em graus e que deve ser convertido para uma escala entre 0 e 360.

Terminado o processo de conversão acima anunciado, a classificação dos pixels é realizada através das seguintes critérios:

- $H \in [0;36] \cup [306;360]$;
- $S \in [0,1;1]$;
- $V \in [0,1;1]$;

Se o pixel analisado verificar as condições especificadas, nesse caso fica automaticamente classificado como pertencente à classe “pele”; caso contrário, é rotulado como sendo “fundo”. No anexo B encontra-se disponível o *script* com a implementação deste algoritmo para Matlab.

4.2.2 Modelo aproximado das distribuições das componentes CrCb dos pixels

Para implementar este modelo foi necessário usar parte da base de dados para geração da distribuição Gaussiana e as restantes imagens serviram para teste do modelo obtido. O processo de selecção de imagens para treino e teste encontra-se detalhado na secção “Descrição da base de dados”.

O teste do modelo consiste num processamento local (pixel-a-pixel) dos pixels das imagens de teste. A distribuição Gaussiana é aplicada directamente sobre as componentes Cr e Cb extraídas dos pixels e como resultado obtém-se uma probabilidade de o pixel ser da classe “pele”. A conversão do espaço RGB para YCrCb é efectuada aplicando as seguintes fórmulas:

$$Y = 0.257R + 0.587G + 0.114B + 16$$

$$Cr = 0.439R - 0.368G - 0.071B + 128$$

$$Cb = -0.148R - 0.291G + 0.439B + 128$$

Na prática procedeu-se a uma normalização das probabilidades para o intervalo de 0 a 255. Como se pode confirmar pela figura 15, esta normalização permite a visualização das probabilidades numa imagem no formato *grayscale*⁹ na qual quanto mais escuro for o valor do pixel menor é a sua probabilidade de ser pele.



Figura 15 - Imagem *grayscale* usando um classificador Gaussiano.

O limiar de decisão para classificação foi definido segundo o algoritmo utilizado no trabalho “*Face Detection*” de Henry Chang e Ulises Robles [21].

No histograma da imagem *grayscale* obtida, é expectável que se obtenha um máximo local associado à pele (níveis elevados na escala de cinzentos) e outro para o fundo (pixels de baixa intensidade na escala de cinzentos). Para otimizar a eficiência na selecção do

⁹ Imagem em tons de cinzento com os pixels a variar entre 0 (preto) e 255 (branco) para uma profundidade de cor de 8bits.

30 Implementação dos algoritmos

threshold, o valor considerado ideal para limiar de decisão deve encontrar-se num vale da zona intermédia do histograma que corresponde à transição de classes. A imagem 16 pode observar-se um histograma de exemplo no qual se encontra assinalado os pontos mais relevantes para a selecção do limiar.




Figura 16 - Histograma da imagem *grayscale* do classificador Gaussiano.

O processo inicia-se verificando o somatório do histograma no intervalo entre aproximadamente 5% e 15% na escala de cinzentos. O processo repete-se depois para o intervalo entre 15% e 25%, e assim sucessivamente até se atingir 65% do histograma. Por fim, o limiar de decisão é atribuído ao ponto médio do intervalo que apresentou um menor somatório do histograma. A figura 17 exemplifica os passos deste processo.




Figura 17 - Detecção do limiar de classificação do histograma da imagem de probabilidades.

Em anexo encontra-se disponível um *script* o correspondente ao processo de geração da distribuição Gaussiana, outro referente ao teste do classificador e um terceiro código para análise dos resultados. Na figura 18 pode observar-se o diagrama funcional dos módulos implementados.

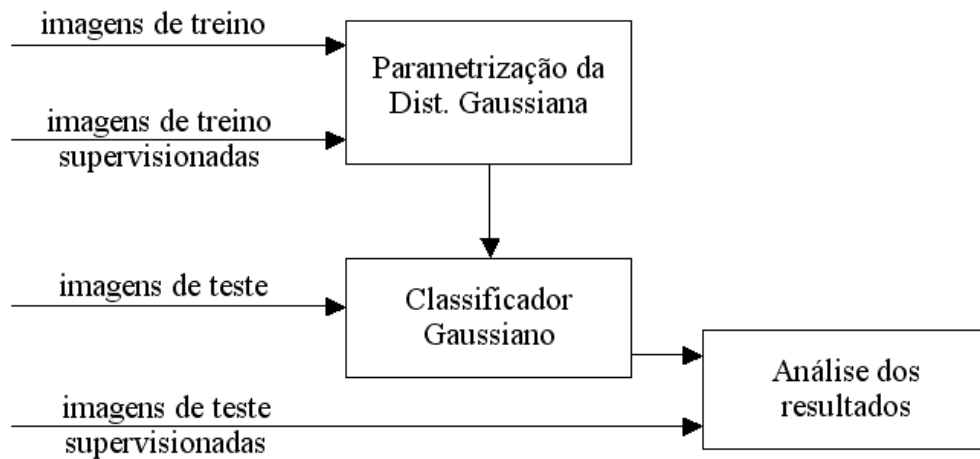


Figura 18 - Diagrama funcional dos módulos implementados para o classificador Gaussiano.

4.2.3 Rede Perceptrão Multicamada

Uma das limitações dos classificadores anteriores é o facto de não combinarem os atributos de cor do pixel com outras informações conhecidas à priori e que favorecem a eficácia da classificação. Para fazer essa integração de conhecimento, implementou-se uma rede Perceptrão Multicamada. A opção por este tipo de rede neuronal teve em conta a possibilidade de inclusão de treino supervisionado e porque é uma solução adequada para resolução de problemas de classificação.

Procedeu-se então à selecção dos atributos que permitem extrair informação relevante para auxilio na classificação dos pixels.

1. Distribuição espacial dos pixels de “pele”

Da análise dos requisitos obrigatórios das imagens processadas verifica-se a obrigatoriedade da imagem contemplar a zona do tronco da paciente, aproximadamente entre o pescoço e a linha da cintura. Apesar dos desvios horizontais relativamente ao centro da imagem serem considerados como aceitáveis, deduz-se que estatisticamente o centro da imagem terá uma probabilidade elevada de conter pixels de “pele”, enquanto que nos cantos superior direito e esquerdo da imagem essa probabilidade é muito reduzida. Esta intuição foi comprovada a

partir da geração de um mapa de probabilidades da distribuição dos pixels pele na imagem como se pode confirmar pela figura 19.




Figura 19 - Probabilidade espacial da distribuição dos pixels de pele na imagem.

Este mapa foi gerado a partir das imagens de treino supervisionadas após serem redimensionadas para uma resolução de 256x192. Procedeu-se à normalização das probabilidades para uma gama entre 0 e 255 de modo a facilitar a sua visualização no formato *grayscale*.

Algumas imagens processadas tinham cartões de referência ao nível do umbigo e na zona entre o peito e o pescoço da paciente. Este facto originou uma diminuição local da probabilidade de pele nestas zonas do mapa como é visível na figura 19. Por vezes as imagens continham a parte superior da saia da paciente o que justifica a diminuição de probabilidade na zona inferior da imagem.

2. Informação colorimétrica

A informação de cor da imagem é obviamente um factor importante para classificação de pele numa imagem. Examinando o mapa de probabilidades podemos afirmar que se pretendermos obter uma estimativa da cor do fundo, as melhores zonas para extrair essa informação serão os cantos superior direito e esquerdo da imagem. Aplicando o mesmo raciocínio para prever o tipo de tonalidade de pele da pessoa, os pixels que nos poderão fornecer essa informação com o menor risco possível serão os pixels da região central da imagem.

Assumindo os pressupostos expostos para a estimação da tonalidade da cor do fundo e da pele da pessoa, podemos prever uma correlação forte entre a cor do pixel e a cor do fundo se o

pixel pertencer ao fundo e um raciocínio análogo caso o pixel seja pele. Desta forma, contrariamente aos classificadores anteriores que cuja classificação depende exclusivamente do valor das componentes de cor do pixel processado, é introduzida na rede uma informação relativa à previsão da cor das classes “fundo” e “pele”.

A determinação da estimação da cor de fundo é efectuada calculando a média das componentes de cor de toda a imagem, pesadas pela probabilidade de o pixel pertencer ao

$$\text{fundo: } \frac{\sum_{row} \sum_{col} prob_{fundo}(row, col) \times Cor(row, col)}{\sum_{row} \sum_{col} prob_{fundo}(row, col)} .$$

A previsão da tonalidade da pele é calculada de forma semelhante:

$$\frac{\sum_{row} \sum_{col} prob_{pele}(row, col) \times Cor(row, col)}{\sum_{row} \sum_{col} prob_{pele}(row, col)} .$$

A selecção do espaço de representação de cor teve em conta o conhecimento adquirido no estado da arte e por isso deu-se preferência aos modelos em que há uma separação da luminosidade das componentes de cor. Neste sentido, foram testados os modelos HSV e YCrCb o que permitiu a comparação dos resultados de cada um deles.

4.3 Pós-processamento

O principal objectivo desta fase é realizar a extracção da máscara da pessoa filtrando o ruído presente na imagem binarizada.

Neste sentido, o algoritmo desenvolvido começa por identificar o objecto com maior área na imagem binarizada. Cada objecto da imagem é definido por um conjunto de pixels pretos conexos, sendo que cada pixel preto corresponde a um pixel classificado pelo processo anterior como pertencente à classe “pele”. Admitindo que o objecto que apresenta maior área corresponde ao tronco da pessoa, a filtragem aplicada permite remover ruído da imagem.

De seguida, os buracos presentes no objecto são preenchidos obtendo-se então a máscara da pessoa. A correcta extracção da máscara é um ponto crítico do funcionamento do sistema pois serão esses os pixels que serão analisados na fase de segmentação de mamilos.

Por fim, é extraído um rectângulo envolvente do objecto. Esta região de interesse é importante pois permite que a classificação dos mamilos seja independente do facto de

eventualmente existirem desvios do posicionamento do tronco relativamente ao centro da imagem.

Tal como se pode verificar no exemplo da figura 20, a implementação deste algoritmo de pós-processamento permite corrigir erros de segmentação da pele melhorando assim o desempenho na detecção da posição dos mamilos.




Figura 20 - Exemplo do funcionamento dos filtros de pós-processamento aplicados numa imagem com erros de segmentação. 1. imagem binarizada; 2. imagem após remoção de artefactos; 3. imagem com preenchimento de buracos; 4. extracção do rectângulo envolvente.

4.4 Detecção de mamilos

4.4.1 Segmentação de mamilos

Para o processo de segmentação de mamilos, foi utilizada uma abordagem análoga à usada na segmentação de pele com classificador Perceptrão Multicamada. Neste caso, foram testados dois métodos de classificação: um usando uma rede Perceptrão Multicamada (MLP) e o segundo com um algoritmo as máquinas de vector de suporte (SVM). Desta forma, foi necessário voltar a fazer uma identificação dos atributos para entrada dos classificadores.

1. Template grayscale

Através da extração de um *template grayscale* pretende-se que o classificador “aprenda” a associar as formas dos mamilos com a sua classificação. Para a definição do tamanho da janela é importante ter em consideração os determinados factores. Assim sendo, janelas muito pequenas não permitem que o classificador extraia informação suficiente do *template* simplesmente porque não se consegue que o *template* contenha integralmente os mamilos. Por outro lado, a utilização de *templates* demasiado grandes também tende a aumentar o nível de ruído associado às zonas exteriores ao mamilo. Além disso, é preciso passar o valor *grayscale* de todos os pixels para o classificador o que aumenta as dimensões do problema e, portanto, o treino fica mais lento.

Tendo em conta que as imagens se encontram redimensionadas para 256x192, foi escolhida uma resolução de 20x20 pixels por *template*. Este valor foi definido empiricamente porque permitia extrair mamilos completos da maioria das imagens com um mínimo de ruído exterior possível.

2. Distribuição espacial dos “mamilos”

De um modo semelhante ao conhecimento relativo à distribuição da classe “pele” na imagem, sabe-se que existem zonas da imagem em que a probabilidade de ocorrência de mamilos é superior. Esta informação pode ser novamente compilada sob a forma de um mapa de probabilidades. O facto de não haver garantias que a pessoa se encontra centrada na imagem implica a introdução de erros na geração do mapa. Para tornar o sistema robusto a estes desposicionamentos, optou-se por uma referenciação dos mamilos relativamente ao rectângulo envolvente do corpo da pessoa evitando assim referenciar as posições relativamente à imagem completa.

Procedeu-se ao cálculo da média da largura e altura das imagens de treino após a extração da região de interesse. Verificou-se que a largura média foi de 224 pixels e 192 pixels de altura, ou seja, em média há uma remoção de $256-224=32$ colunas de pixels que contêm exclusivamente fundo. Definiu-se então que o mapa de probabilidades de localização dos mamilos teria uma resolução igual à média obtida, ou seja 224x192. Como nem todos os rectângulos envolventes apresentavam essa resolução, calculou-se a escala de redimensionamento necessária para converter para a resolução do mapa de probabilidades e aplicou-se esse factor de escala aos valores supervisionados da posição dos mamilos. Um problema associado a este mapa é que dispendo apenas de 60% das imagens da base de dados

para treino, isso corresponde a 228 pontos de mamilos para geração do mapa o que é manifestamente pouco. Para ultrapassar esta limitação aplicou-se uma mistura Gaussiana em que uma distribuição Gaussiana foi calculada para a semi-metade esquerda do mapa (mamilos do lado esquerdo) e a outra distribuição ficou relativa aos mamilos do lado direito. Como resultado final deste processo de geração do mapa de probabilidades da localização dos mamilos das imagens de treino, obteve-se a imagem da figura 21.



Figura 21 - Aproximação da distribuição dos mamilos por uma mistura de Gaussianas (direita e esquerda).

3. Informação de cor

Quando analisamos uma imagem do peito de uma pessoa, sabemos intuitivamente que tipicamente a tonalidade de pele da aréola mamária é diferente da tonalidade de pele da pessoa. Assumindo que o reconhecimento de pele produz resultados fiáveis, podemos fazer uma estimativa da pele da pessoa baseado na média dos pixels identificados como pele. Este método procura refinar a estimativa inicial calculada com base no mapa de probabilidade da distribuição dos pixels de pele na imagem. Embora os pixels dos mamilos também sejam contabilizados na determinação da média de cor de pele, devido à sua baixa percentagem espera-se que o seu efeito se dilua nos resultados.

O objectivo da inserção deste atributo, visa a comparação directa com a média das componentes de cor de cada *template*.

Extracção dos atributos identificados

Para cada pixel candidato à classificação de “mamilo” é extraído a sua vizinhança num *template* 20x20 centrado nesse ponto. Depois, é calculada a média de cada uma das componentes de cor desse *template* e em seguida é convertido para tons de cinzento (*grayscale*). A última operação consiste na obtenção da média da cor da pele que é feita recorrendo à imagem com a detecção de pele filtrada (pós-processamento) em conjunto com

a imagem original. Para cada ponto da imagem filtrada classificado como pele, são extraídas as componentes de cor e no fim são determinadas as médias respectivas. Obviamente este processo só precisa de ser executado uma vez por imagem.

Todo o treino foi realizado apenas com as imagens de definidas para esse efeito. Foi definido um desvio máximo admissível de 6 pixels aplicado às localizações supervisionadas dos mamilos. Essa região foi definida empiricamente de modo a garantir que na maioria das imagens os *templates* efectivamente incluíssem todo o mamilo e permitiu aumentar a quantidade de *templates* disponíveis para treino. No entanto, após esta região onde se pode fazer a extracção automática de *templates* de mamilos para treino, encontra-se uma fase de transição na imagem. Devido à diversidade de formas e tamanhos dos mamilos, torna-se impossível classificar automaticamente esses *templates* porque numas imagens podem ainda incluir todo o mamilo, noutras apenas parte dele e podem ainda simplesmente ser totalmente de pele. Para ultrapassar esta restrição, definiu-se uma segunda região localizada entre os 6 pixels de distância anteriormente definida e os 30 pixels. A partir deste limite os *templates* foram automaticamente treinados para serem classificados como pele, ou seja, não-mamilo.

Para reduzir a redundância dos *templates* extraídos, procedeu-se a um varrimento de 2 em 2 pixels na horizontal e na vertical o que permitiu acelerar o processo de treino.

Por fim, para reduzir a desproporcionalidade entre a quantidade de amostras de *templates* de pele relativamente aos de mamilos (que logicamente era muito inferior), definiu-se que só seria extraído um *template* de pele em cada trinta possíveis. Como resultado deste processo obteve-se cerca de 4000 *templates* de mamilos e 13000 para pele distribuídos entre aproximadamente 10200 *templates* para treino e 6800 para teste.

Na figura 22 podem ser observados alguns *templates* extraídos de pele, enquanto que na figura 23 são apresentados exemplos de *templates* de mamilos.




Figura 22 - Exemplos de *templates* de pele.




Figura 23 - Exemplos de *templates* de mamilos.

Capítulo 5

Comparação dos resultados

5.1 Segmentação de pele

5.1.1 Regiões explicitamente definidas

Os classificadores testados pelo método de regiões explicitamente definidas, não necessitaram de um conjunto de treino porque os limites resultaram de investigações de projectos externos e como tal os classificadores foram testados em todas as imagens da base de dados.

De seguida pode observar-se os resultados obtidos para estes classificadores:

Tabela 2 - Comparação entre os resultados dos classificadores de regiões RGB e HSV

Imagens de teste	Falsos Positivos (%)		Falsos Negativos (%)		Acerto (%)	
	RGB	HSV	RGB	HSV	RGB	HSV
Com fundo controlado	0,01	0,13	36,49	27,68	63,50	72,19
Sem fundo controlado	12,12	13,64	13,05	2,20	74,83	84,15
Todas	4,47	5,11	27,85	18,29	67,68	76,60

As taxas de falsos positivos e falsos negativos apresentados na tabela 2 representam as probabilidades de erro ao classificar fundo como pele e classificar pele como fundo respectivamente. Por sua vez, a probabilidade de acerto corresponde à probabilidade de classificar correctamente pixels de pele e fundo.

É importante lembrar que, tal como foi explicado na secção “Descrição da base de dados”, a quantidade de imagens com fundo controlado é superior ao número de imagens sem fundo controlado e, por isso mesmo, os resultados usando todas as imagens não correspondem à média dos resultados parcelares com e sem fundo controlado.

Os resultados obtidos revelam que os classificadores testados pelo método de regiões explicitamente definidas tiveram taxas reduzidas de falsos positivos e taxas elevadas de falsos negativos. Comparando as duas implementações verifica-se que globalmente os resultados favorecem o modelo HSV face ao RGB com taxas de acerto de 76,60% e 67,68% respectivamente.

Outro facto que se pode observar pela tabela 2 é que ambos classificadores apresentam uma taxa elevada de falsos negativos nas imagens com fundo controlado, o que leva a supor que a cor de pele das pacientes dessas imagens desvia-se do padrão de pele considerado preponderante pelos modelos RGB e HSV utilizados.

5.1.2 Modelo Gaussiano Simples

Na tabela 3 encontram-se discriminados os parâmetros obtidos para a distribuição Gaussiana após a conclusão da fase de treino do classificador.

Tabela 3 - Parametrização da distribuição Gaussiana no espaço CrCb

PARÂMETRO	VALOR
Cr médio	141,1302
Cb médio	118,9998
Matriz de covariância	$\begin{bmatrix} 104,4434 & -93,3397 \\ -93,3397 & 100,5720 \end{bmatrix}$

A representação gráfica desta distribuição pode ser visualizada na figura 24.




Figura 24 - Representação gráfica da distribuição Gaussiana

Os resultados obtidos utilizando este classificador estão disponíveis na tabela 4.

Tabela 4 - Resultados para o classificador usando uma distribuição Gaussiana

Imagens de teste	Falsos Positivos (%)	Falsos Negativos (%)	Acerto (%)
Com fundo controlado	5,98	47,13	46,89
Sem fundo controlado	0,60	69,67	29,73
Todas	4,00	55,43	40,57

Analisando os resultados obtidos para este método, verifica-se que foram bastante insatisfatórios para o tipo de imagens processadas pela aplicação. Nas imagens com fundo controlado, verificou-se um fraco desempenho do classificador sempre que o fundo era escuro pois, nesses casos, o valor de C_r e C_b tende a ser 128 o que é um valor próximo do ponto médio obtido para a distribuição Gaussiana.

Por outro lado, o fraco desempenho nas imagens sem fundo controlado deve-se ao facto de que nessas imagens a cor do fundo assemelha-se aos tons de pele. Como consequência, o algoritmo de *threshold* adaptativo não consegue encontrar o limiar de separação na classificação de pele e fundo resultando numa elevada taxa de falsos negativos.

5.1.3 Rede Perceptrão Multicamada

Foram efectuados diversos testes para determinação da combinação de atributos que proporciona melhor desempenho para as imagens testadas. Na tabela 5 apresenta os resultados obtidos usando como parâmetros para fase de treino os valores configurados por defeito no WEKA: *Learning Rate* = 0,3 e *Momentum* = 0,2.

Tabela 5 - Resultados para segmentação de pele usando uma rede MLP com diferentes atributos de entrada

ATRIBUTOS															RESULTADOS (%)						
Prob. espacial	Pixel						Fundo						Centro						Com fundo controlado	Sem fundo controlado	Todas
	H	S	V	Y	Cr	Cb	H	S	V	Y	Cr	Cb	H	S	V	Y	Cr	Cb			
	x	x	x																94,042	74,232	86,744
				x	x	x													93,349	82,951	89,518
X	x	x	x																95,167	89,221	92,977
X				x	x	x													96,836	90,559	94,523
X	x	x	x				x	x	x										98,138	93,163	96,305
X				x	x	x				x	x	x							98,290	92,136	96,023
X	x	x	x										x	x	x				97,630	92,872	95,877
X				x	x	x										x	x	x	97,861	93,511	96,258
X	x	x	x				x	x	x				x	x	x				98,111	94,910	96,932
X				x	x	x				x	x	x				x	x	x	98,227	93,991	96,666
X	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	98,001	94,850	96,840

A partir dos resultados obtidos, pode-se comprovar um acréscimo significativo no desempenho do classificador após a introdução do atributo probabilidade espacial. Efectivamente, esta informação permitiu que o classificador usando os valores HSV do pixel passa-se de 86,744% de eficiência para 92,977%; enquanto que no caso do classificador com os valores YCrCb aumentou de 89,518% para 94,523%.

Outro aspecto que se pode inferir dos resultados é que existe um melhoramento efectivo do desempenho quando é fornecida à rede informação sobre o valor médio HSV e YCrCb dos pixels dos cantos superior direito e esquerdo (normalmente correspondente à informação de cor do fundo). O mesmo efeito se verifica ao adicionar informação relativa ao centro da imagem pois deste modo a rede recebe estatisticamente uma amostra da cor de pele da pessoa presente na imagem o que permite melhorar os resultados da detecção de pele.

Com os dados obtidos, verifica-se que a inclusão da informação *a priori* possibilita um desempenho superior a 96% na detecção de pele usando diferentes combinações de atributos,

obtendo-se um valor máximo de 96,932% (assinalado a verde na tabela 5). A solução de utilizar uma rede Perceptrão Multicamada revelou-se substancialmente melhor do que os outros métodos testados.

Tendo em conta que os valores anteriores foram obtidos com base na configuração de *Learning Rate* e *Momentum* definidas por defeito pelo WEKA, procedeu-se à variação destes parâmetros para o conjunto de atributos com melhores resultados. É de notar que este procedimento não garante a obtenção de uma rede Perceptrão Multicamada “óptima” para detecção de “pele” nas imagens testadas, apenas permite descobrir um máximo local. O processo de selecção da configuração da rede com melhor desempenho global necessitaria de uma variação dos parâmetros *Learning Rate* e *Momentum* para todas as combinações possíveis de atributos, o que seria manifestamente impraticável no contexto desta dissertação.

Os resultados obtidos variando os parâmetros de *Learning Rate* e *Momentum*, podem ser observados na tabela 6.

Tabela 6 - Resultados obtidos variando os parâmetros de aprendizagem da rede MLP para classificação de pele

MOMENTUM	LEARNING RATE				
	0,1	0,3	0,5	0,7	0,9
0,1	97,135	96,520	97,089	95,550	96,854
0,3	97,070	96,875	96,945	97,145	96,659
0,5	97,272	96,943	96,957	97,070	97,056
0,7	97,068	96,983	96,791	96,330	96,822
0,9	96,598	97,034	97,004	96,950	96,362

Dos resultados obtidos pode confirmar-se que as variações do desempenho da rede tiveram pouco impacto nos resultados. Esta situação revela a dificuldade em melhorar a classificação quando a eficiência da rede atinge os 97%. Na verdade, estes melhoramentos residuais reflectem uma optimização particular do classificador para as imagens de teste disponibilizadas.

5.2 Detecção de mamilos

5.2.1 Máquinas de Vectores de Suporte

Na tabela 7 e 8 encontram-se os resultados obtidos para a detecção de mamilos usando Máquinas de Vectores de Suporte (SVM) com *kernel* polinomial e funções de base radial (RBF).

Tabela 7 - Resultados SVM kernel polinomial

ATRIBUTOS												RESULTADOS (%)				
Template grayscale	Prob. espacial	Template						Pele						Com fundo controlado	Sem fundo controlado	Todas
		H	S	V	Y	Cr	Cb	H	S	V	Y	Cr	Cb			
x														89,569	89,524	89,553
x	x													95,994	94,127	95,308
x	x	x	x	x				x	x	x				96,155	94,048	95,381
x	x				x	x	x				x	x	X	96,155	94,048	95,745
x	x	x	x	x	x	x	x	x	x	x	x	x	X	96,385	94,365	95,643

Tabela 8 - Resultados SVM kernel RBF com complexidade=1.0 e gama=0.01

ATRIBUTOS												RESULTADOS (%)				
Template grayscale	Prob. espacial	Template						Pele						Com fundo controlado	Sem fundo controlado	Todas
		H	S	V	Y	Cr	Cb	H	S	V	Y	Cr	Cb			
X														89,616	90,397	89,902
X	x													94,474	95,000	94,667
X	x	x	x	x				x	x	x				94,520	94,683	94,580
X	x				x	x	x				x	x	X	94,796	94,762	94,784
X	x	x	x	x	x	x	x	x	x	x	x	x	X	94,727	94,802	94,755

Tal como se pode confirmar pelas tabelas, verificou-se uma significativa melhoria nos resultados após a inclusão do atributo “Prob. espacial” obtido directamente do mapa de probabilidades da distribuição de mamilos aproximado por uma mistura Gaussiana. Relativamente à adição de informação à priori da cor do *template* e da estimação da pele, a melhoria dos resultados foi pouco significativa. Existem alguns factores que podem ter condicionado este resultado. Em primeiro lugar, os *templates* dos mamilos normalmente abrangiam um pouco de área de pele próxima dos limites da aréola o que afecta as média das componentes de cor do *template*. Além disso, os eventuais erros de segmentação de pele

influenciam o cálculo a média das componentes de cor “pele” (pixels não-mamilos). Por fim, nem sempre a distinção de entre a tonalidade de cor da pele e do mamilo era perceptível havendo por isso casos em que a cor era muito semelhante.

Comparando os resultados entre as tabelas, os resultados obtidos mostram que o *kernel* polinomial teve uma eficácia ligeiramente superior. No entanto, é de notar que na verdade o *kernel* RBF tem a possibilidade de configuração dos parâmetros de complexidade e de gama. A variação destes parâmetros permite que o classificador se adapte melhor aos dados melhorando desta forma os resultados.

Em ambos os casos, a combinação dos atributos que apresentou melhores resultados foi: *template grayscale* (20x20), probabilidade espacial, média das componentes HSV do *template* e da pele.

5.2.2 Redes Perceptrão Multicamada

Os resultados obtidos usando uma Rede Perceptrão Multicamada podem ser observados na tabela 9.

Tabela 9 - Resultados para segmentação de pele usando uma rede MLP com diferentes atributos de entrada

ATRIBUTOS										RESULTADOS (%)								
Template grayscale	Prob. espacial	Template						Pele						Com fundo controlado	Sem fundo controlado	Todas		
		H	S	V	Y	Cr	Cb	H	S	V	Y	Cr	Cb					
X																93,161	89,564	91,840
X	X															96,638	94,524	95,862
X	X	x	x	x				x	x	x						96,546	94,603	95,833
X	X				x	x	x					x	x	x		96,823	94,286	95,891
X	X	x	x	x	x	x	x	x	x	x	x	x	x	x		96,339	94,683	95,731

Os resultados da tabela 7 revelam que são ligeiramente melhores para o classificador Perceptrão Multicamada do que os obtidos com Máquinas de Vetores de Suporte. Em contrapartida, é preciso realçar que o tempo necessário ao treino da rede Perceptrão Multicamada é muito superior comparativamente aos algoritmos de Máquinas de Vetores de Suporte. Neste sentido, podemos concluir que as Máquinas de Vetores de Suporte convergem muito mais rapidamente para uma solução com uma perda ligeira de *performance*.

Capítulo 6

Conclusão

Comparando os resultados obtidos na detecção de pele, verifica-se que o classificador de Perceptrão Multicamada permitiu obter os melhores resultados. Um problema comum ao classificador Gaussiano e de regiões de cor explicitamente definidas deriva do facto de apenas terem em consideração os pixels de pele, independentemente das condições do fundo. Tendo em conta que o fundo das imagens sem fundo controlado se apresentava sistematicamente em tonalidades de cor de pele, isso teve um impacto negativo significativo nos resultados obtidos para estes classificadores. Além disso, verificou-se a dificuldade em definir regiões de cor devido à necessidade de se estabelecer um equilíbrio entre a quantidade de falsos positivos e falsos negativos. Regiões de cor demasiado restritivas fazem crescer exponencialmente os falsos negativos, mas se forem demasiado amplas reflecte-se nos falsos positivos, especialmente para imagens com fundo não controlado.

As implementações anteriores permitiram estabelecer um patamar comum de comparação e, simultaneamente, ficou evidenciado nos resultados as diferenças de eficácia na segmentação entre imagens com e sem fundo controlado.

A grande vantagem de se utilizar algoritmos de aprendizagem automática tanto na detecção de pele como na detecção de mamilos está relacionada com a possibilidade de integração de conhecimento *a priori*. Em ambos os casos os resultados revelaram taxas elevadas de acerto na ordem dos 95%.

6.1 Perspectivas futuras

A nível de perspectivas e trabalho futuro refira-se a importância de se aumentar a base de dados por forma a contemplar o máximo de diversidade de tons de pele e mamilos em diferentes condições de iluminação e *background* passíveis de serem submetidas à aplicação.

48 Conclusão

Uma possibilidade que se perspectiva interessante será a integração dos algoritmos dos detecção de contornos mamários na classificação de mamilos. Os contornos permitem reduzir a região de pesquisa exclusivamente em torno da mama sendo portanto espectável verificar as melhorias introduzidas no processo de classificação.

Actualmente o algoritmo implementado de treino tem um comportamento estático, ou seja, existe uma fase exclusivamente de treino para calibração dos classificadores. O próximo passo será convergir este modelo para um processo dinámico que, após terminar o treino supervisionado, faça uma refinação do modelo de classificação com base em algoritmos de treino não supervisionado para as novas imagens submetidas.

Por fim, é de salientar que o trabalho desenvolvido pode ser expandido para a outras aplicações, nomeadamente para avaliação do resultado de cirurgia estética ou previsão do resultado estético a nível de tratamento oncológico ou cirurgia estética.

Referências

- [1] J. S. Cardoso e M. J. Cardoso, “Towards an Intelligent Medical System for the Aesthetic Evaluation of Breast Cancer Conservative Treatment”, *Artificial Intelligence in Medicine*, Volume 40, páginas: 115-126, 2007
- [2] M. J. Cardoso, J. Cardoso, N. Amaral et al, “Turning Subjective Into Objective: The BCCT.core Software for Evaluation for Cosmetic Results in Breast Cancer Conservative Treatment”, *Artificial Intelligence in Medicine*, Volume 40, páginas: 115-126, 2007
- [3] P. Andreeva, M. Dimitrova, e P. Radeva, “Data Mining Learning Models and Algorithms for Medical Applications”, 18 Conference Systems for Automation of Engineering and Research (SEAR 2004), Varna, BG.
- [4] C. C. Reyes-Aldasoro, “Image Segmentation with Kohonen Neural Network”, Instituto Tecnológico Autónomo de México, 2001.
- [5] P. B. Ribeiro, “Classificação por Análise de Contornos de Nódulos Mamários Utilizando Redes Neurais Artificiais”, Escola de Engenharia de São Carlos, Universidade de São Paulo, 2006.
- [6] A. R. Bianchini, “Arquitetura de Redes Neurais para o Reconhecimento Facial Baseado no Neocognitron”, Escola de Engenharia de São Carlos, Universidade de São Paulo, Julho de 2001.
- [7] L. O. Marin e J. M. Barreto, “Reconhecimento de Faces”, Universidade Federal de Santa Catarina, Laboratório de Conexão e Ciências Cognitivas, Dezembro de 2003.
- [8] S. Draghici, “A Neural Network Based Artificial Vision System for Licence Plate Recognition”, Dept. of Computer Science, Wayne State University.
- [9] L. H. B. Cunico, “Técnicas em Data Mining Aplicadas na Predição de Satisfação de Funcionários de uma Rede de Lojas do Comércio Varejista”, Universidade Federal do Paraná, Setembro de 2005.
- [10] Support Vector Machines. Disponível em <http://cnx.org/content/m13131/latest/>. Acesso em 10/05/2008.
- [11] Support Vector Machines. Disponível em <http://www.imtech.res.in/raghava/rbpred/svm.jpg>. Acesso em 10/05/2008.
- [12] R. F. Gonzalez, R. E. Woods, “Digital Image Processing”, Addison-Wesley Publishing Company, 1993.
- [13] B. D. Zarit, B. J. Super e F.K.H. Quek, “Comparison of Five Color Models in Skin Pixel Classification”, *Proceedings of the International Workshop on Recognition, Analysis, and Tracking of Faces and Gestures in Real-Time Systems*, 1999.

- [14]I. M. Beszède, “Color Classification Methods for Skin Detection”, IEEE Workshop Vrsov, páginas: 13-16, 2005.
- [15]V. Vezhnevets, V. Sazonov e A. Andreeva, “Pixel-Based Skin Color Detetion Techniques”, Machine Graphics & Vision International Journal, Volume 14, páginas: 61-70, 2005.
- [16]A. Abadpour e S. Kasaei, “Pixel-Based Skin Detection for Pornography Filtering”, Iranian Journal of Electrical & Electronic Engineering, 2005.
- [17]H. Zheng, M. Daoudi e B. Jedynek, “Blocking Adult Images Based on Statistical Skin Detection”, Computer Vision Center, Universitat Autònoma de Barcelona, 2004.
- [18]P. Fuangkhone, “Neural Network-Based Nipple Detection for Obscene Pictures”, Department of Business Information Systems, Assumption University, 2005.
- [19]N. Udpa, M. P. Sampat, M. S. Kim, G. P. Reece e M. K. Markey, “Objective Assessment of the Aesthetic Outcomes of Breast Cancer Treatment: Toward Automatic Localization of Fiducial Points on Digital Photographs”, Computers in Biology and Medicine, Volume 37, páginas: 49-59, 2007.
- [20]J. Kovac, P. Peer e F. Solina, “Human Skin Colour Clustering for Face Detection”, EUROCON 2003, Volume 2, páginas: 144-148, 2003.
- [21]H. Chang, U. Robles, « Face Detection », 2005. Disponível em <http://www-cs-students.stanford.edu/~robles/ee368/main.html>. Acesso em 26/03/2008.
- [22]I. H. Witten e E. Frank, “Data Mining - Practical Machine Learning Tools and Java Implementations”, Morgan Kaufmann Publishers, 2000

Anexos

ANEXO A - *classificador_regioes_rgb.m*

```

% Implementação do classificador de pele com base em regiões RGB explicitamente definidas
% Exemplo de utilização:
% [certos_pele, certos_fundo, errados_pele_marcada_de_fundo,
   errados_fundo_marcado_de_pele]=classificador_regioes_rgb('C:\Imagens','C:\Imagens\supervisiona
   das\');

function [certos_pele, certos_fundo, errados_pele_marcada_de_fundo,
         errados_fundo_marcado_de_pele] =
         classificador_regioes_rgb(caminho_imagens,caminho_imagens_supervisionadas)

imagens = dir(caminho_imagens);
certos_pele = 0; certos_fundo = 0;
errados_pele_marcada_de_fundo = 0;
errados_fundo_marcado_de_pele = 0;

for contador=3:size(imagens)*[1;0]
    if (findstr(imagens(contador).name, '.jpg'))>0
        caminho_img = [caminho_imagens, imagens(contador).name];
        caminho_img_supervisionada = [caminho_imagens_supervisionadas, imagens(contador).name];
        img = imresize(imread(caminho_img),[192 256],'bilinear');
        altura = size(img)*[1;0;0];
        largura = size(img)*[0;1;0];
        img_supervisionada = rgb2gray(imresize(imread(caminho_img_supervisionada),[altura
        largura],'bilinear'));
        img_segmentada = zeros(altura,largura);

        for i=1:largura
            for j=1:altura
                red = img(j,i,1);
                green = img(j,i,2);
                blue = img(j,i,3);

                if (red>95 & green>40 & blue>20 & (double(max(img(j,i,:)))-
                double(min(img(j,i,:))))>15 & abs(double(red)-double(green))>15 & red>green & red>blue)
                    img_segmentada(j,i)=0;
                    if (img_supervisionada(j,i)==255)
                        errados_fundo_marcado_de_pele =
errados_fundo_marcado_de_pele + 1;
                    else
                        certos_pele = certos_pele + 1;
                    end
                else
                    img_segmentada(j,i)=255;
                    if (img_supervisionada(j,i)==255)
                        certos_fundo = certos_fundo + 1;
                    else
                        errados_pele_marcada_de_fundo =
errados_pele_marcada_de_fundo + 1;
                    end
                end
            end
        end
        imwrite(img_segmentada,imagens(contador).name);
    end

    clc
    fprintf('Processando... %f %%\n',100*contador/(size(imagens)*[1;0]));
end

fprintf('Número de pixels de pele classificados como pele: %d\n',certos_pele);
fprintf('Número de pixels de pele classificados como fundo: %d\n',errados_pele_marcada_de_fundo);
fprintf('Número de pixels de fundo classificados como pele: %d\n',errados_fundo_marcado_de_pele);
fprintf('Número de pixels de fundo classificados como fundo: %d\n',certos_fundo);

```

ANEXO B - *classificador_regioes_hsv.m*

```

% Implementação do classificador de pele com base em regiões HSV explicitamente definidas
% Exemplo de utilização:
% [certos_pele, certos_fundo, errados_pele_marcada_de_fundo,
  errados_fundo_marcado_de_pele]=classificador_regioes_hsv('C:\Imagens\', 'C:\Imagens\supervisiona
  das\');

function [certos_pele, certos_fundo, errados_pele_marcada_de_fundo,
  errados_fundo_marcado_de_pele] =
  classificador_regioes_hsv(caminho_imagens,caminho_imagens_supervisionadas)

imagens = dir(caminho_imagens);
certos_pele = 0; certos_fundo = 0;
errados_pele_marcada_de_fundo = 0;
errados_fundo_marcado_de_pele = 0;

for contador=3:size(imagens)*[1;0]
  if (findstr(imagens(contador).name, '.jpg'))>0
    caminho_img = [caminho_imagens, imagens(contador).name];
    caminho_img_supervisionada = [caminho_imagens_supervisionadas, imagens(contador).name];

    img = imresize(imread(caminho_img),[192 256], 'bilinear');
    img_hsv = rgb2hsv(img);
    altura = size(img)*[1;0;0];
    largura = size(img)*[0;1;0];
    img_supervisionada = rgb2gray(imresize(imread(caminho_img_supervisionada),[altura
    largura], 'bilinear'));
    img_segmentada = zeros(altura, largura);

    for i=1:largura
      for j=1:altura
        h = img_hsv(j,i,1)*360;
        s = img_hsv(j,i,2);
        v = img_hsv(j,i,3);
        if (((h>=0 & h<=36) | (h>=306 & h<=360)) & (s>=0.1 & s<=1) & (v>=0.1 & v<=1))
          img_segmentada(j,i)=0;
          if (img_supervisionada(j,i)==255)
            errados_fundo_marcado_de_pele =
errados_fundo_marcado_de_pele + 1;
          else
            certos_pele = certos_pele + 1;
          end
        else
          img_segmentada(j,i)=255;
          if (img_supervisionada(j,i)==255)
            certos_fundo = certos_fundo + 1;
          else
            errados_pele_marcada_de_fundo =
errados_pele_marcada_de_fundo + 1;
          end
        end
      end
    end
    imwrite(img_segmentada, imagens(contador).name);
  end

 clc
  fprintf('Processando... %f %%\n', 100*contador/(size(imagens)*[1;0]));
end
fprintf('Número de pixels de pele classificados como pele: %d\n', certos_pele);
fprintf('Número de pixels de pele classificados como fundo: %d\n', errados_pele_marcada_de_fundo);
fprintf('Número de pixels de fundo classificados como pele: %d\n', errados_fundo_marcado_de_pele);
fprintf('Número de pixels de fundo classificados como fundo: %d\n', certos_fundo);

```

ANEXO C - *gera_modelo_gaussiano_simples.m*

```

% Aproxima o histograma de distribuição de cor CrCb por uma distribuição Gaussiana
% A distribuição Gaussiana fica guardada sob a forma de imagem com o nome 'modelo_gaussiano.bmp'
% Exemplo de utilização:
% gera_modelo_gaussiano_simples('C:\imagens_train.txt','C:\Imagens\supervised\');

function gera_modelo_gaussiano_simples(imagens_treino,caminho_imagens_supervisionadas)

largura = 256;
altura = 192;
dist_cr = [];
dist_cb = [];
dist = zeros(256,256);

nomes_imagens = textread(imagens_treino,'%s');
nr_de_imagens = size(nomes_imagens)*[1;0];

for contador=1:nr_de_imagens
    img_supervisionada =
    imresize(imread([caminho_imagens_supervisionadas,char(nomes_imagens(contador))]),[altura
    largura],'bilinear');
    for j=1:altura
        for i=1:largura
            if (img_supervisionada(j,i)~=255)
                red = double(img_supervisionada(j,i,1));
                green = double(img_supervisionada(j,i,2));
                blue = double(img_supervisionada(j,i,3));

                cr = round(0.439*red - 0.368*green - 0.071*blue) + 128;
                cb = round(-0.148*red - 0.291*green + 0.439*blue) + 128;

                dist(cb,cr) = dist(cb,cr) + 1;
            end
        end
    end
    clc
    fprintf('Processando... %f %%\n',100*contador/nr_de_imagens);
end

disp ('Construindo o Modelo Gaussiano Simples...');
for i=1:256
    for j=1:256
        if dist(j,i)>0
            dist_cb = [dist_cb j*ones(1,dist(j,i))];
            dist_cr = [dist_cr i*ones(1,dist(j,i))];
        end
    end
end

cr_medio = mean(dist_cr);
cb_medio = mean(dist_cb);
crcb_cov = cov(dist_cb,dist_cr);
for x = 1:256
    for y = 1:256
        aux = [(y-cb_medio) ; (x-cr_medio)];
        modelo_gaussiano(y,x) = exp(-0.5* aux*inv(crcb_cov)* aux);
    end
end

imwrite(modelo_gaussiano,'modelo_gaussiano.bmp')
disp ('Modelo Gaussiano Simples concluído.');
```

cr_medio
cb_medio
crcb_cov

ANEXO D - *classificador_gaussiano.m*

```

% Implementação do classificador de pele com base numa distribuição Gaussiana do histograma de CrCb
% Exemplo de utilização:
% classificador_gaussiano('C:\imagens_test.txt','C:\Imagens\','C:\modelo_gaussiano.bmp');

function classificador_gaussiano(imagens_teste,caminho_imagens,caminho_modelo_gaussiano)

largura = 256;
altura = 192;

nomes_imagens = textread(imagens_teste,'%s');
nr_de_imagens = size(nomes_imagens)*[1;0];

img_dist_gaussiana = imread(caminho_modelo_gaussiano);
for contador=1:nr_de_imagens
    img = imresize(imread([caminho_imagens,char(nomes_imagens(contador))]),[altura
    largura],'bilinear');
    for j=1:altura
        for i=1:largura

                red = double(img(j,i,1));
                green = double(img(j,i,2));
                blue = double(img(j,i,3));

                cr = round(0.439*red - 0.368*green - 0.071*blue) + 128;
                cb = round(-0.148*red - 0.291*green + 0.439*blue) + 128;

                img_segmentada(j,i) = img_dist_gaussiana(cr,cb);
        end
    end

    hist = imhist(img_segmentada);
    cum_hist = cumsum(hist);
    min = cum_hist(round(0.65*256))-cum_hist(round(0.55*256));
    threshold = 0.6;
    for a=0.55:-0.1:0.15
        if (cum_hist(round(a*256))-cum_hist(round((a-0.1)*256)))<min
            min = cum_hist(round(a*256))-cum_hist(round((a-0.1)*256));
            threshold = a-0.05;
        end
    end

    imwrite(im2bw(img_segmentada,threshold),char(nomes_imagens(contador)));
    clc
    fprintf('Progress (%%): %f',100*contador/nr_de_imagens);
end

```

ANEXO E - *resultados_classificador.m*

```

% Analiza os resultados do classificador
% Exemplo de utilização:
% resultados_classificador('C:\Imagens\','C:\Imagens\supervisionadas\');

function resultados_classificador(caminho_imagens,caminho_imagens_supervisionadas)

largura = 256;
altura = 192;

imagens = dir(caminho_imagens);
nr_de_imagens = size(imagens)*[1;0];

certos_pele = 0;
certos_fundo = 0;
errados_pele_marcada_de_fundo = 0;
errados_fundo_marcado_de_pele = 0;

for contador = 3:nr_de_imagens
    img = imread([caminho_imagens, imagens(contador).name]);
    img_supervised = imresize(imread([caminho_imagens_supervisionadas
    imagens(contador).name]),[altura largura]);

    for j=1:altura
        for i=1:largura
            if (img_supervised(j,i)==255)
                if (img(j,i)<128)
                    certos_fundo = certos_fundo+1;
                else
                    errados_fundo_marcado_de_pele =
errados_fundo_marcado_de_pele+1;
                end
            else
                if (img(j,i)>128)
                    certos_pele_f = certos_pele_f+1;
                else
                    errados_pele_marcada_de_fundo =
errados_pele_marcada_de_fundo+1;
                end
            end
        end
    end

    fprintf('Processando... %f %%\n',100*contador/nr_de_imagens);
end

certos_pele
certos_fundo
errados_pele_marcada_de_fundo
errados_fundo_marcado_de_pele

```