



UNIVERSIDADE DA BEIRA INTERIOR
Ciências da Saúde

**Medição Computacional da Escala de Graduação
Efron
O Caso da Hiperémia Conjuntival**

Joana Santos

Dissertação para obtenção do Grau de Mestre em
Optometria em Ciências da Visão
(2º ciclo de estudos)

Orientador: Prof. Doutor António Pinheiro
Co-orientador: Prof. Doutor Francisco Ferreira

Covilhã, Outubro de 2011

Agradecimentos

Ao Prof. Doutor António Pinheiro, meu orientador neste projecto, por todo o conhecimento transmitido, pela sua disponibilidade e ajuda ao longo deste ano de trabalho.

Ao Prof. Doutor Francisco Ferreira, pela preciosa colaboração.

Aos meus pais, pelas pessoas extraordinárias que são e pela ajuda e incentivo constantes, ao longo de todo o meu percurso académico e pessoal.

Resumo

Neste trabalho foi desenvolvido um método que permite a graduação computacional da hiperémia conjuntival na escala de Efron, utilizando técnicas de análise e processamento de imagem.

Após a recolha de um conjunto de imagens representativas da hiperémia conjuntival nos diferentes níveis da escala de Efron, foram constituídos dois conjuntos de imagens, um de treino e outro de teste. Ambos os conjuntos contém imagens dos vários graus constituintes da escala de Efron.

A cada imagem, foi aplicada a transformada de onduleta discreta com dois níveis de decomposição, resultando de cada nível quatro coeficientes. Desta forma, foram constituídos dois descritores, um que resulta do cálculo do desvio padrão normalizado dos referidos coeficientes e outro que é obtido pela normalização da média e desvio padrão (juntos). Assim, o primeiro descritor é formado por oito coeficientes e o segundo por dezasseis.

Para obter a classificação das imagens de teste nos diferentes graus, foram utilizados dois classificadores distintos, o K-NN e o SVM, de forma a perceber qual fornece melhores resultados. Foram igualmente efectuadas comparações entre as diferentes componentes da imagem, verde, vermelho, azul e níveis de cinzentos, analisadas isoladamente. Foram ainda testados vários filtros das onduletas, diferentes distâncias no K-NN e distintas funções “kernel” para o SVM.

Efectuadas as comparações, é possível concluir que, o método que melhor classifica automaticamente as imagens na escala de Efron, no caso particular da hiperémia conjuntival, usa apenas a componente verde das imagens, utiliza o filtro daubechy db1 das onduletas com o descritor do desvio padrão e tem o K-NN, com distância euclidiana, como classificador.

Palavras-chave

Escala de Efron, hiperémia conjuntival, onduletas, descritor, classificação, K-NN, SVM.

Abstract

In this work, a method that computes the Efron grading scale of conjunctival hyperemia, using image analysis and processing techniques, was developed.

Initially a set of representative images of conjunctival hyperemia at different levels of Efron grading scale was collected. Those images were divided into two sets of images, a training group and test group. Both sets contain images from the different degrees of the Efron grading scale.

The discrete wavelet transform with two decomposition levels was computed for each image, resulting four coefficients for each level. Two descriptors were computed. One results from the computation of the normalized standard deviation of these coefficients, resulting in an eight bins descriptor. The second is obtained by grouping the normalized mean and normalized standard deviation, resulting in a sixteen bins descriptor.

For the classification of the test images in the different grading scales, two different classifiers were used, the K-NN and SVM. The descriptors were also computed considering the different color components of the image, red, green and blue, and also the gray levels image, resulting in a separated analysis. Different wavelet filters, different distances measures for the K-NN and distinct kernel functions for the SVM, were also tested.

We conclude that the best results for the Efron grading scale automatic classification of an eye image representative of the conjunctival hyperemia were obtained using: the green color component, the wavelet filter daubechy db1, the normalized standard deviation of the wavelet components as the descriptor and K-NN classification with Euclidean distances.

Keywords

Efron grading scale, conjunctival hyperemia, wavelets, descriptor, classification, K-NN, SVM.

Índice

| | |
|--|----|
| Capítulo 1 - Introdução | 1 |
| Capítulo 2 - Escalas | 4 |
| 2.1. Introdução | 4 |
| 2.2. Tipos de escalas | 4 |
| 2.3. As características | 6 |
| 2.4. Escalas fotográficas versus pintadas | 6 |
| 2.5. Escala de Efron | 7 |
| 2.5.1. Precisão | 9 |
| 2.5.2. Factores que influenciam a graduação | 10 |
| Capítulo 3 - Hiperémia conjuntival | 11 |
| 3.1. Introdução | 11 |
| 3.2. Prevalência | 11 |
| 3.3. Sinais e sintomas | 12 |
| 3.4. Patologia | 12 |
| 3.5. Etiologia | 12 |
| 3.5.1. Influências metabólicas e químicas | 12 |
| 3.5.2. Reacções tóxicas | 13 |
| 3.5.3. Reacções alérgicas | 13 |
| 3.5.4. Controlo neuronal | 13 |
| 3.5.5. Inflamação | 13 |
| 3.5.6. Influências mecânicas | 14 |
| 3.6. Diagnóstico diferencial | 14 |
| 3.7. Prevenção e tratamento | 15 |
| 3.7.1. Alterações no tipo de lente | 15 |
| 3.7.2. Alterações do sistema de limpeza | 15 |
| 3.7.3. Melhoramento da higiene ocular | 15 |
| 3.7.4. Aplicação de fármacos | 16 |
| Capítulo 4 - Conceitos de Processamento e Análise de Imagem | 17 |
| 4.1. Introdução | 17 |
| 4.2. Transformada de Fourier | 17 |
| 4.3. Transformada de Onduleta | 19 |
| 4.3.1. Transformada de Onduleta Contínua | 19 |
| 4.3.2. Transformada de onduleta discreta e bancos de filtros | 20 |
| 4.4. Famílias de Onduletas | 21 |
| 4.4.1. “Haar” | 22 |
| 4.4.2. “Daubechies” | 22 |
| 4.4.3. “Coiflets” | 24 |
| 4.5. Classificação estatística | 24 |

| | |
|--|----|
| 4.5.1. “Machine learning” | 24 |
| 4.5.2. Tipos de algoritmos | 25 |
| 4.6. K-NN | 26 |
| 4.6.1. Algoritmo | 26 |
| 4.7. SVM | 27 |
| Capítulo 5 - Metodologia | 29 |
| 5.1. Introdução | 29 |
| 5.2. Método | 29 |
| 5.3. Descritor | 30 |
| 5.4. Classificação | 32 |
| 5.4.1. K-NN | 33 |
| 5.4.2. SVM | 35 |
| 5.5. Tratamento estatístico | 36 |
| 5.6. Resultados | 37 |
| 5.6.1. Comparação de resultados usando diferentes canais da imagem | 37 |
| 5.6.2. Comparação entre os classificadores KNN e SVM | 45 |
| 5.6.3. Comparação de resultados usando os diferentes filtros das ondulas (“haar”, “daubechies2” e “coiflet1”); | 46 |
| 5.6.4. Comparação dos resultados usando diferentes funções “kernel” no SVM (linear, quadrática e polinomial) | 49 |
| 5.6.5. Comparação dos resultados usando diferentes distâncias no K-NN (euclidiana, distância L_1 e correlação) | 50 |
| Capítulo 6 - Conclusões | 52 |
| Bibliografia | 54 |

Lista de Figuras

| | |
|--|----|
| Figura 1 - Representação da escala de Koch para a conjuntivite papilar gigante (9) | 5 |
| Figura 2 - Representação da escala Annunziato para a conjuntivite papilar gigante (9) | 5 |
| Figura 3 - Representação da escala de Vistakon para a conjuntivite papilar gigante (9) | 5 |
| Figura 4 - Representação da escala de Efron para a conjuntivite papilar gigante (9) | 5 |
| Figura 5 - Representação da escala de CCLRU para a conjuntivite papilar gigante (9) | 5 |
| Figura 6 - Primeiro painel da escala de Efron, onde estão representadas oito condições mais frequentes. Cada condição é representada nos cinco graus constituintes da escala (10). | 8 |
| Figura 7 - Segundo painel da escala de Efron, onde estão representadas oito condições menos frequentes. Cada condição é representada nos cinco graus constituintes da escala (10). | 9 |
| Figura 8 - As abcissas representam a resolução espacial e as ordenadas a resolução de frequência. a) sem localização da frequência. b) Transformada de Fourier (sem localização temporal). c) Transformada de Fourier com janela (caixas de Heisenberg constantes). d) Transformada de Onduleta (caixas de Heisenberg variáveis) (13). | 18 |
| Figura 9 - Esquematização da transformada de onduleta discreta ortogonal de um sinal f_n (13) | 21 |
| Figura 10 - Representação gráfica da onduleta “Haar” (14) | 22 |
| Figura 11 - Representação gráfica da família de onduletas “Daubechies” (14) | 23 |
| Figura 12 - Representação gráfica da família de onduletas “Coiflets” (14) | 24 |
| Figura 13 - Representação da classificação K-NN. O círculo verde representa o exemplo de teste que se pretende classificar, ou seja vai ser atribuído a uma das duas classes (classe 1 dos quadrados azuis, ou classe 2 dos triângulos vermelhos). Se o K=3 o exemplo será atribuído à classe 2, uma vez que dos três vizinhos mais próximos, dois pertencem à classe 2. Se K=5 existem três quadrados e apenas dois triângulos, logo o exemplo de teste será atribuído à classe 1 (17). | 26 |
| Figura 14 - Margem máxima, definida pela maior separação entre duas classes. Os exemplos que se encontram nas margens são os vectores de suporte (17). | 28 |
| Figura 15 - Representação de vários hiper-planos. O hiper-plano representado pela linha H3 (verde) não separa as duas classes. O hiper-plano representado pela linha H1 (azul) separa com uma margem pequena e o H2 (linha vermelha) separa com uma margem máxima, sendo este o melhor hiper-plano para classificar os dados (17). | 28 |
| Figura 16 - Representação dos vários cortes que foram efectuados ao longo das imagens. Desta forma, foi possível obter várias imagens a partir da mesma, aumentando o número de imagens do grupo de treino. | 30 |
| Figura 17 - Representação da aplicação de dois níveis de decomposição da onduleta. A partir da imagem original são obtidas duas aproximações e de cada uma são apresentados os detalhes horizontais, verticais e diagonais, que formam os coeficientes da imagem. | 30 |
| Figura 18 - Distâncias do conjunto de imagens inicialmente recolhido. O gráfico representa a distância euclidiana dos descritores do desvio padrão entre todas as imagens. Neste exemplo a imagem 31 (de grau 2) apresenta uma distância pequena em relação às restantes do seu grupo (imagens 28 à 40) e uma distância superior em relação às dos outros graus e por isso é uma boa imagem de treino pertencente ao grau 2. | 33 |
| Figura 19 - Esquematização da matriz Grupo, que representa a classe de cada imagem de treino. | 34 |
| Figura 20 - Exemplificação da classificação atribuída a uma imagem de teste | 34 |
| Figura 21 - Esquematização dos vectores Grupo do SVM, que representam a classe de cada imagem de treino. A classificação é binária e foi efectuada testando dois graus de cada vez. | 35 |
| Figura 22 - Esquematização da classificação efectuada com o SVM. Cada imagem é testada para o grau 0, se o resultado for positivo, obtém-se a classe da imagem, se for negativo a operação é repetida para o grau seguinte, até que seja obtido um resultado positivo e consequentemente a classe da imagem de teste. | 36 |
| Figura 23 - Exemplo do primeiro nível de decomposição de uma imagem pertencente ao grupo de treino, após aplicação da transformada de onduleta à componente verde da imagem. | 38 |

- Figura 24 - Exemplo do segundo nível de decomposição de uma imagem pertencente ao grupo de treino, após aplicação da transformada de onduleta à componente verde da imagem. 39
- Figura 25 - Exemplo do primeiro nível de decomposição de uma imagem pertencente ao grupo de treino, após aplicação da transformada de onduleta à componente azul da imagem. 39
- Figura 26 - Exemplo do segundo nível de decomposição de uma imagem pertencente ao grupo de treino, após aplicação da transformada de onduleta à componente azul da imagem. 40
- Figura 27 - Exemplo do primeiro nível de decomposição de uma imagem pertencente ao grupo de treino, após aplicação da transformada de onduleta à componente vermelha da imagem. 40
- Figura 28 - Exemplo do segundo nível de decomposição de uma imagem pertencente ao grupo de treino, após aplicação da transformada de onduleta à componente vermelha da imagem. 41
- Figura 29 - Exemplo do primeiro nível de decomposição de uma imagem pertencente ao grupo de treino, após aplicação da transformada de onduleta aos níveis de cinzentos da imagem. 41
- Figura 30 - Exemplo do segundo nível de decomposição de uma imagem pertencente ao grupo de treino, após aplicação da transformada de onduleta aos níveis de cinzentos da imagem. 42
- Figura 31 - Gráfico precisão/ sensibilidade para os cinco graus da escala de Efron e para ambos os descritores, desvio padrão e média com o desvio juntos, tendo sido seleccionada a componente verde das imagens. Foi usado o classificador K-NN com a distância euclidiana e o filtro da onduleta é o db1. 43
- Figura 32 - Gráfico precisão/ sensibilidade para os cinco graus da escala de Efron e para ambos os descritores, desvio padrão e média com o desvio juntos, tendo sido seleccionada a componente azul das imagens. Foi usado o classificador K-NN com a distância euclidiana e o filtro da onduleta é o db1. 43
- Figura 33 - Gráfico precisão/ sensibilidade para os cinco graus da escala de Efron e para ambos os descritores, desvio padrão e média com o desvio juntos, tendo sido seleccionada a componente vermelha das imagens. Foi usado o classificador K-NN com a distância euclidiana e o filtro da onduleta é o db1. 44
- Figura 34 - Gráfico precisão/ sensibilidade para os cinco graus da escala de Efron e para ambos os descritores, desvio padrão e média com o desvio juntos, tendo sido as imagens convertidas para cinzentos. Foi usado o classificador K-NN com a distância euclidiana e o filtro da onduleta é o db1. 44
- Figura 35 - Gráfico precisão/ sensibilidade para os cinco graus da escala de Efron. São comparados os dois classificadores KNN com SVM, utilizando o descritor com o desvio padrão. Foi seleccionada a componente verde das imagens, usada a “kernel function” linear no SVM e a distância euclidiana no K-NN. O filtro da onduleta usado foi o db1. 45
- Figura 36 - Gráfico precisão/ sensibilidade para os cinco graus da escala de Efron. São comparados os dois classificadores KNN com SVM, utilizando o descritor com a média e o desvio padrão juntos. Foi seleccionada a componente verde das imagens, usada a “kernel function” linear no SVM e a distância euclidiana no KNN. O filtro da onduleta usado foi o db1. 46
- Figura 37 - Exemplo do primeiro nível de decomposição de uma imagem pertencente ao grupo de treino, após aplicação da transformada de onduleta com filtro db1. 47
- Figura 38 - Exemplo do primeiro nível de decomposição de uma imagem pertencente ao grupo de treino, após aplicação da transformada de onduleta com filtro db2. 47
- Figura 39 - Exemplo do primeiro nível de decomposição de uma imagem pertencente ao grupo de treino, após aplicação da transformada de onduleta com filtro coif1. 48
- Figura 40 - Gráfico precisão/ sensibilidade para os cinco graus da escala de Efron. São comparados três filtros da onduleta, db1, db2 e coif1 para o descritor do desvio padrão. O classificador utilizado é o K-NN com a distância euclidiana e foi seleccionada a componente verde das imagens. 48
- Figura 41 - Gráfico precisão/ sensibilidade para os cinco graus da escala de Efron, onde são comparadas três “kernel function” do classificador SVM, linear, quadrática e polinomial, utilizando o descritor com o desvio. Foi seleccionada a componente verde das imagens e o filtro da onduleta usado foi o db1. 49
- Figura 42 - Gráfico precisão/ sensibilidade para os cinco graus da escala de Efron, onde são comparadas três “kernel function” do classificador SVM, linear, quadrática e polinomial,

utilizando o descritor com a média e o desvio juntos. Foi seleccionada a componente verde das imagens e o filtro da onduleta usado foi o db1. 50

Figura 43 - Gráfico precisão/ sensibilidade para os cinco graus da escala de Efron, onde são comparadas três distâncias do classificador KNN, euclidiana, cityblock e correlação, utilizando o descritor com o desvio. Foi seleccionada a componente verde das imagens e o filtro da onduleta usado foi o db1. 51

Figura 44 - Gráfico precisão/ sensibilidade para os cinco graus da escala de Efron, onde são comparadas três distâncias do classificador KNN, euclidiana, cityblock e correlação, utilizando o descritor com a média e o desvio juntos. Foi seleccionada a componente verde das imagens e o filtro da onduleta usado foi o db1. 51

Lista de Acrónimos

| | |
|-------|---------------------------------------|
| CCLRU | Cornea and Contact Lens Research Unit |
| PHEMA | Poly Hydroxy Ethyl MethAcrylate |
| CLARE | Contact Lens Acute Red Eye |
| WFT | Windowed Fourier Transform |
| K-NN | K-Nearest Neighbour |
| SVM | Support Vector Machine |
| S | Sensibilidade |
| VP | Verdadeiros Positivos |
| FN | Falsos Negativos |
| P | Precisão |
| FP | Falsos Positivos |
| DP | Desvio Padrão |
| MD | Média Desvio |

Capítulo 1 - Introdução

A hiperémia conjuntival está relacionada com diversas condições que afectam a conjuntiva. Este facto realça não só a importância da utilização de escalas de graduação, mas também a necessidade dessa graduação ser o mais exacta e objectiva possível. Apesar dos diversos formatos de escalas actualmente existentes, a subjectividade associada a cada observador está sempre presente.

O estudo de Fieguth e Simpson (1) demonstra que existe uma variabilidade enorme na graduação efectuada pelos clínicos. Esta graduação é muitas vezes inconsistente, mesmo na presença de esquemas de graduação bem definidos (1). Para além disso, ainda não é conhecida a forma como é feita a avaliação da vermelhidão (1). O estudo de Fieguth e Simpson (1) mostra a pouca precisão quantitativa e o grau de subjectividade da graduação clínica. Outros resultados (1) mostram que é possível uma associação linear entre métodos de graduação automática e métodos subjectivos.

A alta repetibilidade observada quando se comparam medidas subjectivas, realizadas por observadores, e medidas objectivas, foi demonstrada (2), realçando a necessidade de encontrar métodos objectivos de graduação para minimizar os erros associados à observação humana.

Vários estudos (1,3,4) têm sido realizados na tentativa de encontrar o melhor método para efectuar a graduação automática das diversas patologias que afectam o globo ocular. Apesar das várias tentativas ainda não existe consenso acerca do método ideal para efectuar o referido procedimento automaticamente.

Papas (3) sugere que a percepção subjectiva do eritema, efectuada por observadores não recai primeiramente na cor, apenas envolve a proporção ocupada pelos vasos.

O trabalho de Fieguth e Simpson (1) mostra um método que combina vários factores da imagem para obter a graduação automática da escala de Efron. No referido trabalho, a análise das imagens é efectuada de duas formas. A primeira pela quantidade de vasos vermelhos existentes, que é obtida pelo algoritmo de detecção de arestas de Canny e a segunda pela quantidade total da componente vermelha em cada pixel da imagem. Os dois factores são combinados numa equação, que atribui pesos diferentes a cada um, mediante a comparação com dados subjectivos.

O método desenvolvido e aqui apresentado utiliza a transformada de onduletas para obtenção da graduação automática da escala de Efron.

Actualmente, as onduletas têm sido amplamente utilizadas para análise de textura de imagens (5,6), uma vez que elas fornecem uma partição natural do espectro da imagem em sub-bandas orientadas e de escala variada. Assumindo que a energia de distribuição no domínio da frequência identifica a textura, a energia das sub-bandas da onduleta é tratada como característica de textura.

Outros trabalhos (7) utilizam como método de identificação de texturas, as densidades marginais dos coeficientes das sub-bandas das onduletas. Este é justificado pela recente investigação psicológica na percepção humana da textura, que sugere que duas texturas homogêneas são também dificilmente discriminadas se produzirem uma distribuição marginal semelhante.

No estudo de Do e Vetterli (7), é apresentado um novo quadro estatístico, onde os coeficientes de cada sub-banda da onduleta são independentemente modelados pela densidade Gaussiana generalizada de forma a permitir a classificação de imagem. Este método foi especialmente desenhado para recuperação de dados onde as classes não são definidas.

Encontrar boas medidas de similaridade entre imagens é um desafio, assim como encontrar funções de similaridade que coincidam com a percepção humana. No entanto, a questão do julgamento humano para percepção de similaridade entre imagens continua ainda a ser um tópico que requer muita investigação.

A compressão de cores foi uma das primeiras aplicações das onduletas. É atribuída maior largura de banda à luminância e menos largura de banda à cromaticidade, com base no facto dos seres humanos serem capazes de perceber com melhor resolução a luminosidade do que a cromaticidade (8). A qualidade da reconstrução de uma técnica de compressão de cor é a melhor medida usando uma medida de percepção, em vez de uma medida matemática (8).

A compressão de frequência espacial é mais eficaz para imagens com textura, que contêm uma grande variedade de conteúdo de frequências espaciais (8). Devido à crescente importância dos dados de textura, muitas pesquisas têm-se centrado na compressão baseada na frequência espacial com perdas, que descarta os dados que são imperceptíveis por percepção visual humana. Essa compressão é feita pela decomposição da imagem em múltiplas bandas de frequência espacial, e posteriormente é feita a quantificação de cada banda com um valor que é baseado nos limites da percepção visual humana dentro dessa faixa. Tal como acontece na compressão de cores, a medida da qualidade da reconstrução desta técnica de compressão é melhor usando uma medida de percepção, em vez de uma medida matemática (8).

Estudos psico-visuais indicam que o sistema visual humano processa as informações visuais de uma forma multi-escalar tal como acontece com a transformada de onduletas (8).

No sistema visual humano, o conteúdo da imagem é analisada por um número de canais independentes de frequência espacial. Embora esses canais não interfiram substancialmente uns com os outros, existem alguns pontos na imagem em que a fase espacial de todos (ou a maioria) dos canais se correlacionam uns com os outros, produzindo a percepção de uma determinada característica visual (8). Estes pontos de coerência são conhecidos como coincidentes e surgem quando os sinais de vários canais com diferente frequência espacial, têm valor zero no mesmo local, em todos estes pontos. O grau de correlação espacial destes pontos coincidentes representa o nível de coerência de fase entre as bandas. Imagens que não contêm quaisquer pontos coincidentes são percebidas como não tendo características salientes (8).

A hipótese colocada no estudo de Fahmy, Black e Panchanathan (8), é que estes pontos de coerência (coincidentes) representam os pontos de maior actividade neuronal no sistema visual humano. Baseado nesta hipótese, esses pontos são vistos como características visuais que podem ser usadas para medir a similaridade de textura entre as imagens, possibilitando a classificação das imagens.

No capítulo 5 do trabalho aqui apresentado, é explicado que foram utilizados apenas dois níveis de decomposição da transformada de onduleta, uma vez que são os que melhor representam a textura dos vasos nas imagens usadas. Resultados semelhantes são encontrados noutro estudo (8) onde a maior parte da informação de discriminação de textura reside nos dois primeiros níveis de decomposição da onduleta, uma vez que não ocorreu melhoramento dos resultados á medida que se aumentaram os níveis de decomposição.

O objectivo deste trabalho é desenvolver um método que permita a graduação automática da escala de Efron para o caso particular da hiperémia conjuntival e para isso serão utilizadas onduletas. Nos Capítulos 2 e 3 será feita uma apresentação das diferentes escalas de graduação das patologias oculares, com especial incidência na escala de Efron e ainda a explicação das principais características da hiperémia conjuntival. No Capítulo 4 são apresentados alguns conceitos de análise e processamento de imagem e no Capítulo 5 é explicada a metodologia usada para obter a graduação automática da escala. No Capítulo 6 são apresentadas as conclusões finais.

Capítulo 2 - Escalas

2.1. Introdução

Segundo Efron, uma escala de graduação é definida como uma “ferramenta que permite a quantificação da severidade de uma condição, com referência a um conjunto de descrições ou ilustrações padrão.” (9) A existência destas escalas oferece aos profissionais de saúde visual, uma linguagem comum para descrever uma determinada condição ocular e permite a monitorização das mesmas. As escalas consistem numa série de fotografias ou desenhos pintados que descrevem os vários graus de severidade de uma determinada condição e proporcionam aos clínicos uma referência visual do estado em que se encontra determinada condição. Para além disso, é ainda possível comparar o grau de severidade com futuras observações permitindo avaliar a evolução da condição (9).

2.2. Tipos de escalas

Desde 1984, altura em que surgiu o primeiro formato deste tipo de escalas de graduação, que várias investigações foram feitas nesta área (9).

De uma maneira geral, podemos encontrar duas formas de escalas, as escalas fotográficas e as escalas pintadas. A primeira escala representada na Figura 1, desenhada por Perrin Sparks Smith, é constituída por um conjunto de desenhos, maioritariamente a preto e branco e foi denominada Escala de graduação de Koch (9). Tal como a escala de Koch, também a escala de Annunziato é pintada, sendo que nesta última, os desenhos são totalmente coloridos, como pode ser verificado na Figura 2. Surgiu em 1992 e o seu autor foi o artista oftalmológico Monte Lay (9).

Mais tarde, em 1996 e 1997 respectivamente, surgiram duas escalas fotográficas, a escala Vistakon e a escala CCLRU (“Cornea and Contact Lens Research Unit”) (9). Tal como podemos observar na Figura 3 e Figura 5, são ambas constituídas por um conjunto de fotografias com os diversos graus de severidade das várias condições, no entanto a escala Vistakon é ainda acompanhada por texto descritivo. À semelhança desta, também as anteriormente referidas escalas pintadas, apresentam uma breve descrição das condições oculares. A escala CCLRU foi feita por um conjunto de pessoas, não sendo atribuída autoria a nenhuma especificamente, enquanto que Aderson é o autor da Vistakon (9).

Por fim, surgiu em 1999 a escala de Efron (Figura 4). Sendo uma escala pintada, todas as imagens foram desenhadas por Terry Tarrant (9). Estando esta escala na base deste trabalho, será apresentada em maior detalhe na secção 2.5.




Figura 1 - Representação da escala de Koch para a conjuntivite papilar gigante (9)



Figura 2 - Representação da escala Annunziato para a conjuntivite papilar gigante (9)



Figura 3 - Representação da escala de Vistakon para a conjuntivite papilar gigante (9)



Figura 4 - Representação da escala de Efron para a conjuntivite papilar gigante (9)




Figura 5 - Representação da escala de CCLRU para a conjuntivite papilar gigante (9)

2.3. As características

A escala de Koch e a CCLRU têm em comum o facto de serem formadas apenas por 4 graus de severidade, de 1 até 4. Nas restantes escalas o grau zero é acrescentado para todas as complicações, no caso da Annunziato e Efron, e apenas em algumas no caso da escala da Vistakon. Para além das diferenças no número de graus apresentados, também existem variações na descrição de cada grau de severidade (9).

As escalas de Annunziato, CCLRU e Vistakon possuem ainda a particularidade de apresentarem sub-classificações, isto é em algumas condições na mesma patologia, os diferentes graus de severidade são representados nas várias características que definem essa condição. Para além disso, o número de condições representadas nas diversas escalas também varia. Por exemplo, na escala de CCLRU estão representadas seis condições, enquanto que na de Efron é possível encontrar dezasseis. No conjunto dos cinco sistemas de representação, estão descritas vinte e uma condições e apenas três são comuns nos cinco sistemas de graduação (hiperémia conjuntival, queratite ponteada e conjunctivite papilar) (9).

2.4. Escalas fotográficas versus pintadas

A grande vantagem de utilizar escalas fotográficas, reside no facto de estas utilizarem imagens reais das diferentes condições, sendo a representação mais próxima das observações efectuadas pelos clínicos. No entanto, são várias as desvantagens destas escalas, nomeadamente a dificuldade de encontrar várias fotografias que correspondam exactamente à mesma condição e que manifestem os diferentes graus de severidade da mesma. O facto de estas escalas utilizarem fotografias de diferentes pacientes, que naturalmente possuem características distintas, nomeadamente tamanho pupilar, cor da íris, vasos conjuntivais ou abertura palpebral entre outros, constitui igualmente uma desvantagem a considerar (9).

Outras características como, diferentes ângulos e ampliações entre as fotografias, condições de iluminação distintas, variações nos sistemas de aquisição de imagem e no posterior tratamento das mesmas e ainda a dificuldade de fotografar algumas condições patológicas, representam igualmente desvantagens deste tipo de escalas (9).

Por outro lado, as escalas pintadas possuem características que possibilitam a descrição das condições mais facilmente e com menos factores de variabilidade. Permitem a representação de qualquer complicação, em qualquer grau de severidade; todas as imagens podem ser pintadas usando exactamente as mesmas características, respeitando as mesmas cores, os mesmos ângulos de visão e ampliações e outras características que não são respeitadas nas escalas fotográficas. O uso de desenhos pintados possibilita a eliminação de características indesejadas, como complicações secundárias à condição que se pretende realçar, ou ainda adicionar pormenores para realçar a complicação (9).

2.5. Escala de Efron

A escala de Efron é constituída por dois painéis e neles estão representadas um total de 16 complicações. O primeiro painel (Figura 6) é constituído pelas complicações que surgem mais frequentemente, estando as condições menos comuns reservadas ao segundo painel (Figura 7). Cada condição encontra-se identificada com um título e é constituída por um conjunto de cinco imagens que representam os cinco graus de severidade da cada complicação, desde o grau 0 (normal) até ao grau 4 (severo). A cada um destes graus está associada uma cor que ajuda a interpretar a severidade da condição, por exemplo ao grau zero está associada a cor verde indicando normalidade, enquanto que o vermelho está atribuído à severidade inerente ao grau 4. A graduação das condições efectuada pelos clínicos deve ser realizada com uma sensibilidade de 0,1 (9). Apesar deste procedimento se verificar por vezes complicado, a graduação realizada deste modo, em vez de recorrer exclusivamente aos cinco graus da escala, concede uma melhor graduação e aumenta a sensibilidade da escala de graduação para detectar alterações reais ou diferenças na severidade. Outras informações adicionais, como por exemplo a localização da patologia, devem ser acrescentadas à graduação numérica.

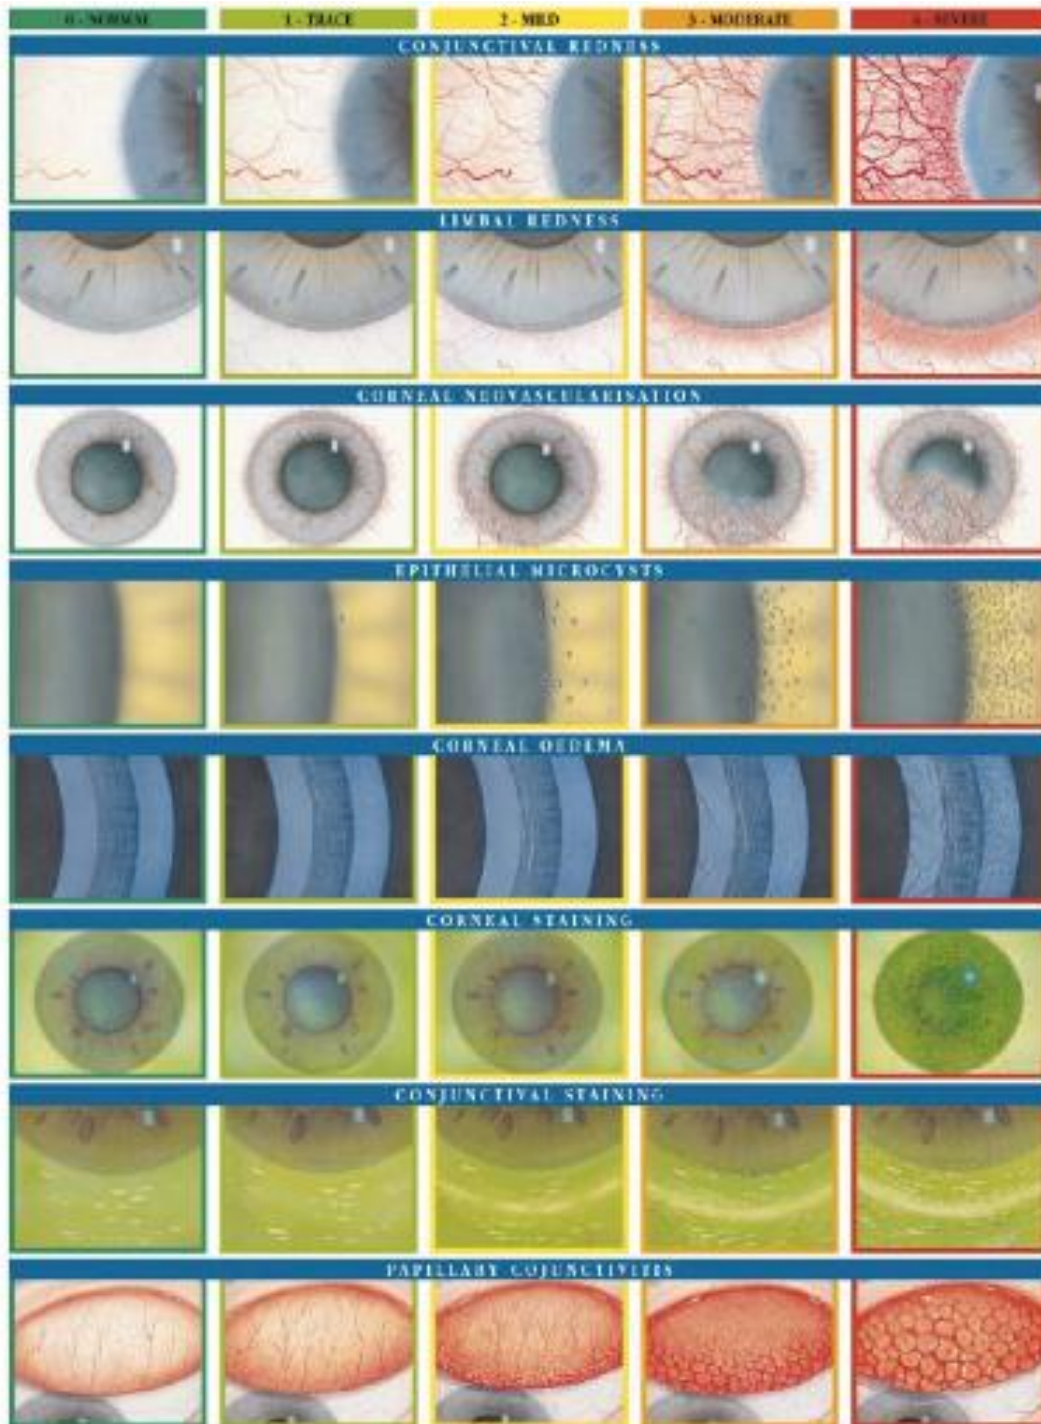


Figura 6 - Primeiro painel da escala de Efron, onde estão representadas oito condições mais frequentes. Cada condição é representada nos cinco graus constituintes da escala (10).




Figura 7 - Segundo painel da escala de Efron, onde estão representadas oito condições menos frequentes. Cada condição é representada nos cinco graus constituintes da escala (10).

2.5.1. Precisão

Um estudo (9) com o objectivo de avaliar e comparar a precisão entre os diferentes sistemas revelou diferenças estatisticamente significativas entre as várias escalas de gradação, observadores e condições. Segundo o mesmo estudo, os sistemas pintados oferecem estimativas mais baixas e mais confiáveis do que as escalas fotográficas (9), ou seja a mesma imagem graduada mediante a escala de Efron terá um grau superior a uma imagem graduada

pela escala CCLRU. Este facto é facilmente compreendido pela comparação entre escalas, por exemplo a análise da conjuntivite papilar representada pela escala de Efron, na Figura 4 e na de CCLRU na Figura 5, sugere que os graus mais elevados de conjuntivite papilar na escala pintada representam níveis de severidade superior do que os representados na escala de CCLRU (9).

Nas escalas pintadas, o artista possui mais controlo na progressão da severidade das condições, do que nas escalas fotográficas. É provavelmente por este motivo que a graduação feita com escalas pintadas oferece mais segurança do que com escalas fotográficas (9).

Segundo Efron (9) a fiabilidade das medidas não é afectada pela severidade das condições analisadas. No entanto, a graduação de determinadas condições é mais fiável do que outras, como é o caso da hiperémia conjuntival e da conjuntivite papilar, que são graduadas com níveis de confiança superior comparativamente com os ponteados corneais. O mesmo estudo refere ainda que, este facto pode estar relacionado com a maior variabilidade nas manifestações de ponteados corneais, do que nas outras duas condições que são mais características e previsíveis.

2.5.2. Factores que influenciam a graduação

Independentemente da escala de graduação utilizada, existem vários factores que afectam ou influenciam a precisão e confiança das estimativas feitas pelos clínicos quando fazem a graduação de uma determinada condição (9). Para além dos factores de variabilidade associados ao formato de cada escala, ou à complexidade de cada patologia, existem ainda factores relacionados com o examinador que influenciam as estimativas obtidas. Exemplo disso, são o conhecimento que cada clínico possui, o seu treino e a experiência (9).

Estudos (9) têm sido desenvolvidos com o intuito de averiguar a verdadeira influência dos factores anteriormente referidos. Um estudo (9) efectuado com Optometristas e indivíduos que não são Optometristas revelou que qualquer pessoa, mesmo que não relacionada com Optometria, pode efectuar a graduação de uma patologia com precisão, no entanto apresentam resultados menos fiáveis quando se trata da graduação de sinais clínicos subtis. O referido estudo conclui ainda que após várias graduações feitas por pessoas comuns, a média dessas estimativas é semelhante às obtidas pelos Optometristas. Deste modo, concluiu-se que não são necessárias habilidades clínicas específicas para que se obtenham estimativas de graduação precisas.

Relativamente ao factor de treino, um estudo de Efron (9), demonstrou que estatisticamente a precisão da graduação melhora com alguma experiência, no entanto esta não é clinicamente significativa.

Capítulo 3 - Hiperémia conjuntival

3.1. Introdução

Hiperémia conjuntival consiste num aumento do volume de sangue dos vasos da conjuntiva, causando um aumento da aparência de vermelhidão do olho (9). Muitas vezes o termo eritema encontra-se associado a esta condição, consistindo na vermelhidão da pele produzida pelo congestionamento dos capilares (9).

O termo hiperémia conjuntival pode ser atribuído a várias estruturas do globo ocular, pelo que é necessário fazer uma diferenciação entre hiperémia da conjuntiva bulbar, hiperémia da conjuntiva tarsal ou hiperémia limbal, mediante a estrutura em que a vermelhidão se manifesta (9). O objecto de estudo deste trabalho recai apenas sobre a hiperémia da conjuntiva bulbar.

A escolha desta condição específica neste trabalho, está relacionada com facto de esta ser a primeira a surgir na escala de Efron e por isso encontra-se nas complicações mais frequentemente. Para além disso, esta é uma condição com características bem definidas, onde a quantidade de vasos sanguíneos aumenta e conseqüentemente o aspecto vermelho do olho. Esta vermelhidão acontece numa zona, que no seu estado normal, deveria ser branca não havendo afectação de outras estruturas oculares (como córnea, pálpebras ou cílios) que poderiam tornar a avaliação e o processamento de imagem mais complexo.

3.2. Prevalência

A maior parte dos usuários de lentes de contacto apresentam algum episódio de hiperémia conjuntival (9). No entanto, esta condição pode, ou não estar relacionada com o uso das mesmas.

No entanto, e considerando a sua associação ao uso de lentes de contacto, vários estudos, (9) demonstram que as lentes de silicone hidrogel induzem menores níveis de hiperémia conjuntival, quando comparados com restantes lentes de hidrogel.

Sendo as lentes de silicone hidrogel o resultado da polimerização do silicone (material hidrofóbico) com materiais hidrofílicos, como o PHEMA (“Poly Hydroxy Ethyl MethAcrylate”), favorece a biocompatibilidade com a superfície ocular e confere a este material uma elevada permeabilidade aos gases. A maior passagem de gases faz com que a incidência de complicações oculares, como a hiperémia conjuntival, edema ou sinais de hipoxia, seja bastante reduzida, quando comparada com outros tipos de lentes (11).

3.3. Sinais e sintomas

Geralmente, a hiperémia conjuntival é assintomática, no entanto os pacientes podem apresentar queixas de comichão, congestionamento, irritação ou sensação de frio ou calor. Normalmente, a existência de dor poderá significar o envolvimento de outras estruturas oculares, nomeadamente a córnea (ex: queratite) ou patologia de outros tecidos como é o caso de uveítes ou esclerites (9). Em alguns casos, a hiperémia pode representar um sinal secundário de outras desordens tais como, reacções tóxicas ou alérgicas, entre outras (9).

3.4. Patologia

A conjuntiva bulbar contém uma vasta rede de arteríolas. As paredes destas contêm um tecido conjuntivo elástico que contém uma espessa camada de músculo liso que é controlado pelo sistema nervoso simpático e que podem ser influenciadas por várias alterações locais (9).

Quando se dá a relaxação das camadas de músculo liso, verifica-se um decréscimo da resistência das paredes dos vasos e um aumento do fluxo de sangue através do mesmo induzindo a vasodilatação. Este processo é conhecido como hiperémia activa. No entanto, salienta-se que a vasodilatação pode igualmente ocorrer por mecanismos passivos, como o bloqueio dos vasos (9).

O estado de constrição (tono vascular) que habitualmente o músculo arteriolar apresenta deve-se normalmente a dois factores. O primeiro refere-se à actividade miogénica intrínseca causada por flutuações do potencial da membrana, enquanto o segundo é devido à noroadrenalina libertada pelas fibras do sistema simpático. Uma alteração destes dois mecanismos pode também provocar um aumento ou decréscimo da vasodilatação (9).

3.5. Etiologia

Tal como foi referido anteriormente, a vermelhidão conjuntival está frequentemente associada ao uso de lentes de contacto e são várias as causas que estão na sua origem nomeadamente, influências metabólicas e químicas, reacções tóxicas e alérgicas, controlo neuronal, inflamação e reacções mecânicas (9).

3.5.1. Influências metabólicas e químicas

Durante a actividade metabólica, os tecidos estão constantemente expostos a vários componentes existentes nos fluidos intersticiais. Mudanças nas concentrações destes componentes podem levar a vasodilatação e conseqüentemente aumento do fluxo sanguíneo. Tais mudanças podem verificar-se em condições de hipoxia ou hipercápnia. A hipoxia provocada pelo uso de lentes de contacto, ou seja quando as lentes não permitem a chegada de oxigénio suficiente às células, leva a um aumento da concentração de ácido láctico. Noutras situações, existe uma excessiva acumulação de dióxido de carbono, situação

designada por hipercapnia, na qual se verifica um aumento da concentração de ácido carbónico (9).

A produção de partículas osmoticamente activas influencia igualmente a relaxação dos músculos lisos das arteríolas e consequentemente relaciona-se com o grau de hiperémia conjuntival, assim como o aumento do nível de potássio, uma vez que este não pode ser removido pela bomba de sódio-potássio (9).

Alterações químicas produzidas pelas lentes de contacto, tais como a acidificação do meio e aumento de osmolaridade, também influenciam a hiperémia conjuntival. A introdução de líquidos com pH diferente do dos tecidos oculares provoca igualmente a acidificação do meio e o aumento da osmolaridade resulta da utilização de soluções essencialmente hipertónicas (9).

3.5.2. Reacções tóxicas

Uma reacção tóxica pode ocorrer quando o olho é exposto a agentes potencialmente nocivos presentes nas soluções de lentes de contacto. A utilização de conservantes, agentes enzimáticos ou agentes quelantes, entre outras substâncias químicas estão na origem de algumas reacções adversas (9).

3.5.3. Reacções alérgicas

Este tipo de reacções pode ser originado quer por agentes alergénicos, como pólen, quer por agentes químicos presentes nas soluções de lentes de contacto ou depósitos presentes nas lentes (9).

3.5.4. Controlo neuronal

A enorme enervação, pelo sistema nervoso simpático, das arteríolas da conjuntiva, faz com que este exerça uma grande influência no grau de hiperémia conjuntival. Consequentemente, os fármacos que provocam afectação desta via, influenciam igualmente os níveis de vermelhidão do olho (9).

3.5.5. Inflamação

A inflamação, caracterizada por calor, inchaço, dor, vermelhidão e perda de função, resulta de uma reacção dos tecidos a uma agressão. Efron (9) revela que a alteração de um grau de vermelhidão conjuntival representa uma variação de 0.15° na temperatura da conjuntiva.

Associado ao uso de lentes de contacto, nomeadamente em utilização extensiva verifica-se de forma esporádica uma reacção inflamatória, normalmente unilateral, conhecida como CLARE (“Contact Lens Acute Red Eye”), na qual o paciente experimenta vermelhidão conjuntival e limbal logo pela manhã, desconforto, lacrimejo e fotofobia. Frequentemente, encontram-se infiltrados no estroma anterior junto ao limbo, mas com ausência de ulceração. Este síndrome

pode apresentar várias etiologias, como hipoxia ou hipercápnia, efeitos mecânicos, diminuição da espessura do filme lacrimal ou de toxicidade à presença de detritos entre a lente de contacto e a superfície corneal anterior. No entanto, normalmente é atribuída a uma reacção patológica às proteases libertadas por bactéria Gram-negativa que ficam retidas na lente de contacto. (9).

3.5.6. Influências mecânicas

As lesões mecânicas provocadas pelo uso de lentes de contacto encontram-se frequentemente associadas à hiperémia conjuntival, na medida em que o trauma causado pelas lentes provoca a libertação de histamina. Sendo a histamina, proveniente da degranulação celular, a maior causadora de vasodilatação e inchaço das áreas afectadas, esta situação conduz, como foi explicado anteriormente, à vermelhidão conjuntival (9).

Outras substâncias presentes no organismo são igualmente responsáveis por reacções de hiperémia. Exemplo disso, são as prostaglandinas descritas como hormonas locais, dado que são produzidas localmente, têm um tempo de actuação curto e exercem um efeito rápido e profundo até que ficam biologicamente inactivas (9).

3.6. Diagnóstico diferencial

A condição de olho vermelho quando associado ao uso de lentes de contacto obriga a relacionar os sinais e sintomas com a presença das lentes de contacto. Caso se verifique que as lentes são a origem do problema, a suspensão do uso das mesmas deverá resolver o problema. No entanto, pode acontecer que a causa do problema não esteja relacionada com as lentes e por isso é necessário perceber qual a sua verdadeira origem (9).

Em casos extremos de vermelhidão conjuntival é necessário perceber a extensão da mesma, ou seja se a vermelhidão resulta apenas dos vasos da conjuntiva, ou se esta se estende por zonas mais profundas. Caso haja envolvimento apenas da conjuntiva, verifica-se movimento dos vasos, por outro lado se estes se mantiverem estáticos é sinal de que existe envolvimento de estruturas ciliares (9).

O diagnóstico diferencial da hemorragia sub-conjuntival é facilmente efectuado, devido à forte aparência de olho intensamente vermelho. Esta situação é benigna e auto-limitada (9).

É ainda necessário averiguar se a origem do problema está na córnea ou na conjuntiva. Caso não haja alterações a nível do limbo e ausência de dor, a vermelhidão está relacionada com a conjuntiva. Quando o problema está exclusivamente relacionado com a córnea, existe afectação do limbo e dor na córnea (9).

3.7. Prevenção e tratamento

Sendo a vermelhidão conjuntival uma queixa frequente em usuários de lentes de contacto, esta pode ser considerada um problema crónico e por isso requer uma intervenção activa. Nessas situações devem ser tomadas medidas para melhorar as reacções adversas, tais como alteração do tipo de lente e do sistema de limpeza, melhoramento da higiene com as lentes e uso de fármacos (9).

3.7.1. Alterações no tipo de lente

Um dos problemas do uso de lentes de contacto reside na acumulação de resíduos. O tipo de proteína que fica depositada na lente influi na biocompatibilidade da mesma com o olho (9). Nas lentes de alta ionicidade a compatibilidade das proteínas é preservada, o mesmo não acontece com as lentes não iónicas que atraem e desnaturam as proteínas (9). Deste modo, quanto maior for o número de depósitos de proteínas nas lentes, maior será a acumulação de bactérias que aderem às proteínas. Todo este processo desencadeia a vermelhidão do olho. Assim, por vezes pode ser necessário efectuar alterações no tipo de lente, como por exemplo optar por materiais que não sejam tão propícios aos depósitos de proteínas, usar lentes rígidas ou aumentar a frequência de substituição das lentes, sendo as lentes de substituição diária as mais aconselhadas (9).

3.7.2. Alterações do sistema de limpeza

Quando um paciente inicia o uso de lentes de contacto deve ser consciencializado para uma correcta higienização das suas lentes. Neste procedimento está incluída a limpeza com surfactantes, desinfecção e um tratamento periódico de remoção de proteínas (9).

A introdução destes sistemas de remoção de proteínas, que se aplica quer às lentes hidrófilas, quer às rígidas, ou o incremento da frequência dos mesmos pode aliviar a vermelhidão da conjuntiva crónica.

Por vezes os pacientes podem apresentar intolerância às soluções com conservantes. Nestas situações o uso de sistemas de limpeza sem conservantes pode aliviar esta condição.

3.7.3. Melhoramento da higiene ocular

A higiene pessoal, nomeadamente a correcta limpeza das mãos antes do manuseamento de lentes de contacto e a lavagem frequente da face, traduz-se numa diminuição do olho vermelho. A irrigação do olho com solução salina esterilizada e sem conservantes, constitui um passo adicional que melhora os sintomas de vermelhidão da conjuntiva (9). Este procedimento deve ser efectuado antes e depois da inserção das lentes e periodicamente durante o dia, de forma a remover os agentes agressivos e melhorando o conforto do paciente.

Quando existe suspeita de que as pálpebras poderão ser em parte responsáveis pela vermelhidão da conjuntiva, a limpeza das mesmas pode ser igualmente benéfica.

3.7.4. Aplicação de fármacos

Por vezes é necessário recorrer ao uso de fármacos, nomeadamente descongestionantes (9). Estes fármacos reduzem a vermelhidão do olho e aliviam os sintomas devido à presença de agentes vasoconstritores. Antes da aplicação destes fármacos, devem ser despistadas patologias e outras causas que possam estar associadas a esta condição, de modo a não mascarar a verdadeira origem da vermelhidão da conjuntiva e não piorar ou prolongar os sintomas.

Dentro do grupo dos descongestionantes oculares estão inseridos: a Fenilefrina 0,12%, a Nafazolina 0,01% combinada com hazel 12%, Nafazolina 0,01-0,1% combinada com Antazolina, Xilometazolina 0,05% combinada com Antazolina e Levocabastina 0,05% (9).

A utilização de Fenilefrina pode provocar como reacções adversas hiperémia com desconforto, que pode ocorrer com o uso prolongado, reacções alérgicas e descoloração das lentes de contacto (9). Por outro lado, a concentração de 0,12% é insuficiente para provocar dilatação pupilar.

Quanto à Nafazolina é menos provável que provoque reacções alérgicas ou congestão dos vasos, em comparação com a Fenilefrina, sendo por isso mais estável e de longa acção. Apesar disso, em alguns casos, especificamente em crianças, verifica-se algum efeito sedativo após uso prolongado (9).

Os pacientes que usam descongestionantes devem ser seguidos a cada 3 meses.

Capítulo 4 - Conceitos de Processamento e Análise de Imagem

4.1. Introdução

Um dos principais problemas no processamento de sinal é encontrar uma representação adequada dos dados que facilite a sua análise. Uma forma de o fazer consiste na transformação ou decomposição do sinal num conjunto de funções no domínio da frequência e isso é possível recorrendo a transformadas como a de Fourier ou como a de onduleta. Deste modo, as transformadas têm grande importância no processamento de imagem e têm sido largamente usadas ao longo dos anos em campos como processamento, segmentação, descrição, melhoramento e restauração de imagem (13).

A análise de onduletas é um método relativamente recente, apesar dos seus fundamentos matemáticos remontarem ao trabalho de Joseph Fourier, no século XIX (14).

A investigação passou gradualmente, da análise baseada na frequência para a análise baseada na escala e começou-se a perceber que a medição de flutuações médias em escalas diferentes poderia produzir menos sensibilidade ao ruído (14).

Pensa-se que a primeira referência ao termo "wavelet" remonta a 1909, numa tese de Alfred Haar. Apesar disso, o conceito teórico como é conhecido actualmente foi proposto por Jean Morlet e Alex Grossmann (14).

O algoritmo principal remonta ao trabalho de Stephane Mallat em 1988 e desde aí vários cientistas como Ingrid Daubechies, Ronald Coifman, e Victor Wickerhauser têm estabelecido importantes avanços neste domínio (14).

4.2. Transformada de Fourier

O processamento de sinal foi dominado pela transformada de Fourier. Esta divide um determinado sinal nas suas componentes de frequência, subdividindo-o nas suas funções básicas associadas a ondas sinusoidais complexas $e^{i\omega t}$. Um sinal $f(t)$ definido no domínio temporal e a sua transformada de Fourier $\mathcal{F}(\omega)$, definida no domínio da frequência estão relacionados da seguinte forma (13):

$$\mathcal{F}(\omega) = \int_{-\infty}^{+\infty} f(t)e^{-i\omega t} dt \quad (1)$$

$$f(t) = \frac{1}{2\pi} \int_{-\infty}^{+\infty} \mathcal{F}(\omega)e^{i\omega t} d\omega \quad (2)$$

A utilidade da transformada de Fourier reside na sua capacidade de analisar um sinal $f(t)$ com domínio no tempo, em termos do seu conteúdo em frequência. O sinal pode então ser analisado pelo seu conteúdo de frequência, uma vez que os coeficientes de Fourier da função transformada representam a contribuição de cada frequência. Desde que as funções de base $e^{i\omega t}$ cubram todo o domínio temporal (infinito), $\mathcal{F}(\omega)$ depende dos valores de $f(t)$ para todos os tempos. Desta forma, a transformada de Fourier é uma transformada global que não pode analisar propriedades locais ou transitórias do sinal original $f(t)$ (13).

De modo a captar a frequência de um sinal não estático, as funções base devem ter um suporte compacto em ambos os domínios, de tempo e frequência. Para isso, é necessário introduzir funções de janela $w(t)$ na transformada de Fourier, obtendo-se a transformada de Fourier com janela (WFT) (13):

$$Sf(\omega, t) = \int_{-\infty}^{+\infty} f(\tau)w(t - \tau)e^{-i\omega\tau} d\tau \quad (3)$$




Figura 8 - As abcissas representam a resolução espacial e as ordenadas a resolução de frequência. a) sem localização da frequência. b) Transformada de Fourier (sem localização temporal). c) Transformada de Fourier com janela (caixas de Heisenberg constantes). d) Transformada de Onduleta (caixas de Heisenberg variáveis) (13).

A energia das funções base $g_{\tau\xi}(t) = w(t - \tau)e^{-i\xi t}$ está concentrada na vizinhança do tempo τ ao longo de um intervalo de tamanho σ_t , medido pelo desvio padrão de $|g|^2$. A sua transformada de Fourier dada por $\hat{g}_{\tau,\xi}(\omega) = \hat{w}(\omega - \xi)e^{-i\tau(\omega - \xi)}$, com energia no domínio da frequência localizada em torno de ξ ao longo de um intervalo do tamanho de σ_ω . Num plano de tempo-frequência (t, ω) , a propagação de energia de $g_{\tau\xi}(t)$ é representada pelo rectângulo de Heisenberg com largura de tempo σ_t e largura de frequência σ_ω (13). A forma e o tamanho dos rectângulos de Heisenberg de uma transformada de Fourier com janela, determinam a resolução espacial e de frequência dessa transformada. Na Figura 8 estão representados exemplos de espaço-frequência com rectângulos de Heisenberg. A resolução de análise de uma transformada de Fourier com janela permanece a mesma ao longo de todas as localizações espaciais e de frequência. Isso é visível na Figura 8 c) uma vez que a forma das caixas tempo-frequência, na transformada de Fourier com janela, são idênticas através de todo o plano tempo-frequência.

Na análise de sinais transitórios com várias amplitudes de tempo, é necessário recorrer a funções base tempo-frequência com diferentes tamanhos para localizações temporais diferentes (13). A transformada de onduletas satisfaz estes requisitos tornando-se por isso uma valiosa ferramenta na análise de sinais. Desta forma, para traçar correctamente a trajectória das variações é possível ter uma resolução temporal alta, em estruturas com elevadas frequências e por outro lado, para baixas frequências, permite a utilização de resoluções de frequência absoluta maiores, proporcionando uma melhor medida no valor da frequência (13).

4.3. Transformada de Onduleta

Onduleta é uma função matemática capaz de decompor e descrever outras funções no domínio da frequência, permitindo a análise destas funções em diferentes escalas de frequência (7). A decomposição de uma função recorrendo a onduletas é conhecida como transformada de onduleta que pode ser contínua e discreta (13).

O uso de modelos estatísticos na análise de imagem torna-se mais simples se for precedido por algum pré-processamento das imagens. Tipicamente, o pré-processamento é feito através da transformação dos valores de pixéis da imagem num espaço adequado onde modelos simples, com um pequeno número de parâmetros, pode descrever os dados. As onduletas surgiram recentemente como uma ferramenta eficaz para analisar as informações de textura, uma vez que proporcionam uma partição natural do espectro da imagem num conjunto de múltiplas escalas e orientações dado pelas sub-bandas que resultam das transformações (7).

4.3.1. Transformada de Onduleta Contínua

A amplitude, destas ondas de oscilação rápida, aumenta e diminui rapidamente começando e terminando em zero. Assim, a função onduleta é definida como uma função $\psi \in L^2(\mathbb{R})$ com média zero (13):

$$\int_{-\infty}^{+\infty} \psi(t) dt = 0 \quad (4)$$

A função é normalizada $\|\psi\| = 1$ e centrada na vizinhança de $t = 0$. Através de operações de translação por u e usando factores de escala s obtém-se uma família de funções base tempo-frequência (13):

$$\psi_{u,s}(t) = \frac{1}{\sqrt{s}} \psi\left(\frac{t-u}{s}\right) \quad (5)$$

A transformada de onduleta contínua decompõe um sinal através da dilatação e translação das funções onduletas. Deste modo, a transformada de onduleta de um sinal $f \in L^2(\mathbb{R})$, com tempo u e escala s é dada por (13):

$$Wf(u,s) = \langle f, \psi_{u,s} \rangle = \int_{-\infty}^{+\infty} f(t) \frac{1}{\sqrt{s}} \psi^*\left(\frac{t-u}{s}\right) dt = 0 \quad (6)$$

Assumindo que a sua energia está concentrada num intervalo de frequência positiva centrada em η , o domínio de tempo-frequência da função onduleta $\psi_{u,s}(t)$ é simbolicamente representado pelo rectângulo de Heisenberg centrado em $(u, \eta/s)$, com um domínio de tempo e frequência proporcional a s e $1/s$ respectivamente. Quando s varia, a largura e altura do rectângulo muda, mas a área mantém-se constante (Figura 8 d)).

Na transformada de onduleta contínua, a energia finita de um determinado sinal é projectada numa família de bandas de frequências contínua. Em seguida, o sinal original pode ser reconstruído por uma integração adequada sobre todos os componentes de frequência resultante (13).

Na análise com múltiplas escalas, é importante introduzir a função de escala ϕ , que consiste na agregação de funções onduletas em escalas superiores a um. A função de escala ϕ relaciona-se com a função onduleta da seguinte forma (13):

$$|\hat{\phi}(\omega)|^2 = \int_1^{+\infty} |\hat{\psi}(s\omega)|^2 \frac{ds}{s} \quad (7)$$

A transformada de onduleta contínua, $Wf(u,s)$, de um sinal f unidimensional, é uma representação bidimensional.

4.3.2. Transformada de onduleta discreta e bancos de filtros

Uma vez que não é possível utilizar todos os coeficientes das onduletas para analisar um sinal, pode escolher-se um subconjunto discreto da metade superior para reconstruir o sinal dos coeficientes correspondentes (13).

Dado um sinal 1-D de tamanho N , a transformada de onduleta ortogonal discreta pode ser organizada como uma sequência de funções discretas de acordo com o parâmetro de escala $s = 2^j$ (13):

$$\{L_j f, \{W_j f\}_{j \in [1, J]}\} \quad (8)$$

Onde $L_j f = Lf(2^j n, 2^j)$ e $W_j f = Wf(2^j n, 2^j)$. Os coeficientes de onduleta $W_j f$ na escala $s = 2^j$ têm o tamanho de $N/2^j$ e a maior profundidade de decomposição J é limitada pelo comprimento de sinal N com $\text{sup}(J) = \log_2 N$. Para uma implementação mais rápida são construídos um par de filtros de espelho conjugados, h e g , a partir da função de escala ϕ e a função onduleta ψ (13):

$$h[n] = \langle \frac{1}{\sqrt{2}} \phi\left(\frac{t}{2}\right), \phi(t-n) \rangle \text{ e } g[n] = \langle \frac{1}{\sqrt{2}} \psi\left(\frac{t}{2}\right), \psi(t-n) \rangle \quad (9)$$

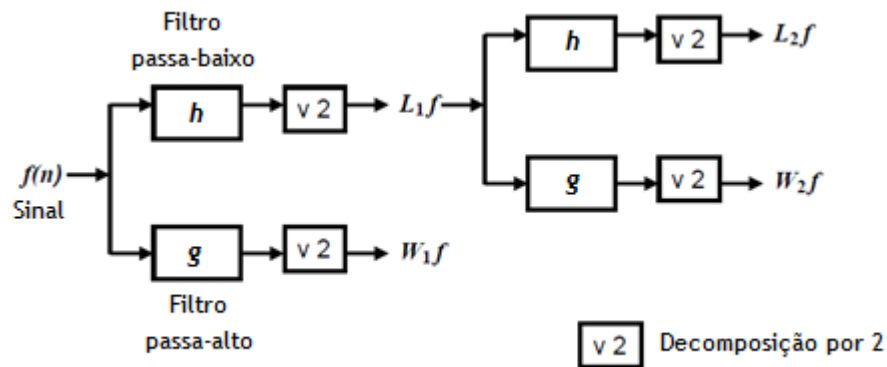


Figura 9 - Esquemática da transformada de onduleta discreta ortogonal de um sinal $f(n)$ (13)

h é um filtro passa-baixo e g é um filtro passa-alto. Aplicando estes dois filtros ao sinal de entrada e decompondo a banda passa-baixo, obtém-se a decomposição da onduleta ortogonal discreta. O sinal de entrada pode ser novamente reconstruído a partir dos coeficientes de onduleta, usando os referidos filtros. Estas filtragens são seguidas de uma sub-amostragem do sinal. Por isso, a quantidade total de dados depois da expansão da onduleta discreta tem o mesmo tamanho do sinal de entrada. A transformada de onduleta fornece uma representação compacta do sinal adequada para a compressão de dados, assim como uma melhor localização de espaço-frequência (13).

Através de diferentes filtros de reconstrução e decomposição, é possível formar uma base bi-ortogonal, que sendo uma generalização da transformada de onduleta, proporciona mais flexibilidade nas funções. Neste caso, a transformada de onduleta de um sinal $s(n)$ é descrita como uma sequência de funções discretas:

$$\{S_M s(n), \{W_m s(n)\}_{m \in \{1, M\}}\}_{n \in \mathbb{Z}} \quad (10)$$

Onde $S_M s(n) = s * \phi_M(n)$.

4.4. Famílias de Onduletas

Dentro das onduletas, podemos encontrar várias famílias de funções. “Haar”, “Daubechies”, “Biorthogonal”, “Coiflets”, “Symlets” e “Morlet” são alguns exemplos destas famílias (14). Neste trabalho para comparação de resultados foram utilizadas apenas onduletas da família das “Haar”, “Daubechies” e “Coiflets” e os seus aspectos teóricos serão explicados nesta secção.

Estas diferentes famílias possuem características que variam de acordo com vários critérios: o suporte das funções onduletas (ψ), e das funções de escala (ϕ); a simetria, que é útil para evitar o desfasamento no processamento da imagem; o número de momentos zero de ψ ou de

ϕ (se existirem), que é útil para a compressão; a regularidade que é útil para a obtenção de boas características, como imagens ou sinais reconstruídos sem irregularidades.

4.4.1. “Haar”

A onduleta “Haar” é uma determinada sequência de funções quadradas redimensionadas que juntas formam uma família de onduletas (14). A sequência “Haar” é reconhecida como a primeira base de onduletas e é amplamente utilizada, uma vez que é o tipo de onduleta mais simples. A função onduleta “Haar” é descrita por (14):

$$\psi(t) = 1 \text{ para } t \in [0, 1/2[\quad (11)$$

$$\psi(t) = -1 \text{ para } t \in [1/2, 1[\quad (12)$$

$$\psi(t) = 0 \text{ para } t \notin [0, 1[\quad (13)$$

$$\phi(t) = 1 \text{ para } t \in [0, 1] \quad (14)$$

$$\phi(t) = 0 \text{ para } t \notin [0, 1] \quad (15)$$




Figura 10 - Representação gráfica da onduleta “Haar” (14)

4.4.2. “Daubechies”

Este tipo de onduletas é caracterizado por um número máximo de momentos iguais a zero para um dado suporte. Os nomes das onduletas da família “Daubechies” são escritos como dbN, onde N é a ordem. Cada onduleta tem um número de momentos zero, ou “momentos de limpeza” que corresponde à ordem da onduleta (14). A onduleta “Daubechies” (db) de ordem 1 representa a onduleta “Haar” que tem 1 momento igual a zero.

A existência de momentos zero, nas funções onduletas, possibilita que a função de escala seja representativa de polinômios. Se uma função onduleta tem momentos zero até uma determinada ordem K-1, todos os coeficientes das onduletas serão zero, para qualquer

polinómio com ordem inferior a k e por isso o sinal fica completamente situado no espaço da função escala (15).

A $db1$, com um momento, codifica facilmente polinómios de um coeficiente ou componente de sinal constantes. A $db2$ codifica polinómios com dois coeficientes, ou seja componentes de sinal constantes e lineares; $db3$ codifica polinómios com três coeficientes, ou seja componentes de sinal constantes, lineares ou quadráticos. Estas onduletas não têm expressões explícitas, excepto a $db1$ (Haar). No entanto, o quadrado do módulo da função de transferência h é descrito da seguinte forma (14):

Com,

$$P(y) = \sum_{k=0}^{N-1} C_k^{N-1+k} y^k \quad (16)$$

Onde, C_k^{N-1+k} representa os coeficientes binominais. Temos:

$$|m_0(\omega)|^2 = \left(\cos^2\left(\frac{\omega}{2}\right)\right)^N P\left(\sin^2\left(\frac{\omega}{2}\right)\right) \quad (17)$$

Onde

$$m_0(\omega) = \frac{1}{\sqrt{2}} \sum_{k=0}^{2N-1} h_k e^{-ik\omega} \quad (18)$$

A dimensão de ψ e ϕ é $2N-1$. A maioria das onduletas da família “Daubechies” não são simétricas e a regularidade aumenta com a ordem. A análise é ortogonal.




Figura 11 - Representação gráfica da família de onduletas “Daubechies” (14)

4.4.3. “Coiflets”

Nesta família de funções (*coifN*), a função onduleta tem $2N$ momentos iguais a zero e a função de escala tem $2N - 1$ momentos. Ambas as funções, de escala e a onduleta, têm que ser normalizadas por um factor $1/\sqrt{2}$. Os coeficientes das onduletas obtêm-se revertendo a ordem dos coeficientes da função de escala e revertendo o sinal de cada um (14).

As funções ψ e ϕ da família das “Coiflets” tendem a aproximam-se mais da simetria do que as da família das *dbN*.




Figura 12 - Representação gráfica da família de onduletas “Coiflets” (14)

4.5. Classificação estatística

A classificação estatística consiste em identificar a sub-população à qual pertencem as novas observações (cuja sub-população é desconhecida) com base num conjunto de dados de treino que foram retirados de uma sub-população conhecida. Assim, os novos itens individuais têm que ser colocados em grupos com base em informação quantitativa sobre uma ou mais medidas e com base no conjunto de treino onde foram previamente estabelecidos grupos (16).

O conjunto de treino é composto pelas informações x e y para cada ponto de dados, onde x geralmente é um vector de características observadas para os dados e y um rótulo do grupo. O rótulo y apenas pode assumir um número finito de valores. Dado o conjunto de treino $\{(x_1, y_1), \dots, (x_n, y_n)\}$ produz-se uma regra, ou classificador h , tal que $h(x)$ pode ser avaliado para qualquer valor possível de x e não apenas para os dados de treino. (16).

4.5.1. “Machine learning”

“Machine learning” é um ramo da inteligência artificial relacionada com a concepção e desenvolvimento de algoritmos que permitem que os computadores desenvolvam comportamentos de aprendizagem com base em características de interesse capturadas a partir de uma série de exemplos (16).

A máquina de aprendizagem aprende a reconhecer padrões complexos automaticamente e tomar decisões inteligentes com base em dados. A dificuldade reside no facto de que o conjunto de todos os comportamentos possíveis, dadas todas as entradas possíveis, é muito grande para ser coberto pelo conjunto de exemplos observados (dados de treino). Assim, deve

ser feita uma generalização a partir dos exemplos dados, de modo a ser capaz de produzir um resultado útil com novos casos (16).

O objectivo da “machine learning” é efectuar classificação de dados, utilizando expressões simples. No processo de decisão, o raciocínio humano deve ser imitado, no entanto apesar do conhecimento humano estar implícito, assume-se que não há intervenção humana na operação (16).

4.5.2. Tipos de algoritmos

Existem vários tipos de classificadores, como por exemplo os lineares, as redes neuronais, “Naive Bayes”, K-NN (K vizinhos mais próximos) e “Support Vector Machine”, entre outros (16).

- Classificadores lineares:
 - Discriminante linear, consiste na classificação baseada exclusivamente nos vectores atribuídos. É definido um hiper-plano que separa as duas classes e a classificação é efectuada mediante o lado do hiperplano em que os pontos de teste se situam. Este método de classificação utiliza funções lineares e pode utilizar dois critérios de separação de dados, o método dos mínimos quadrados ou pela probabilidade máxima (16).
 - Discriminante logístico, é semelhante ao discriminante linear no que diz respeito à escolha do hiper-plano que melhor efectua a separação das classes, mas neste caso o critério de separação das classes é baseado numa probabilidade condicionada maximizada.
 - Discriminante quadrático, efectua a classificação de forma semelhante ao discriminante linear, mas neste caso a discriminação das regiões é feita por funções quadráticas (16).
- Redes Neuronais são um modelo matemático baseado no funcionamento das ligações neuronais biológicas e oferece uma boa medida da taxa de erro. No entanto, as redes neuronais apresentam como desvantagem o facto de serem difíceis de entender. Esta situação prende-se com o facto de a aprendizagem ser uma complexa rede de ligações entre camadas e nós, ligadas a funções não lineares, cuja relação é difícil de descrever em termos quantitativos (16).
- “Naive Bayes” classifica os exemplos utilizando o teorema de Naive. Este método é um bom classificador se, para uma dada classe, os atributos forem independentes. Todas as probabilidades devem ser interpretadas como condicionadas a um determinado exemplo, ou seja, é calculada a probabilidade condicionada de uma determinada classe, dada um determinado dado. A regra de decisão com menor probabilidade de erro é associada à classe com maior probabilidade de ocorrer (16).

- K vizinhos mais próximos (K-NN), que devido à simplicidade de aplicação deste classificador, será um dos métodos aplicados neste trabalho para obtenção da classificação de dados e por isso será desenvolvido em maior detalhe na secção 4.6.
- “Support Vector Machine” (SVM), sendo largamente utilizado actualmente com bons resultados, este método será igualmente aplicado neste trabalho e por esse motivo, alguns dos seus aspectos teóricos serão apresentados na secção 4.7.

4.6. K-NN

O método dos k vizinhos mais próximos (k-NN) permite a classificação de objectos baseado nos exemplos de treino mais próximos num determinado espaço. A Figura 13 representa a classificação utilizando o K-NN, onde um objecto é classificado pela maioria dos votos dos seus vizinhos (elementos mais semelhantes dentro do conjunto de treino), ou seja, é atribuído de acordo com a classe mais frequente entre os seus k vizinhos mais próximos (16). Normalmente, k é um inteiro positivo, pequeno. Se $k=1$, então o objecto é simplesmente atribuído à classe de seu vizinho mais próximo (elemento de treino mais semelhante).

O mesmo método pode ser usado para regressão, ou seja atribuir ao objecto o valor da média entre os valores dos seus k vizinhos mais próximos. Isto pode ser útil para medir o peso da contribuição de cada vizinho. Deste modo, os vizinhos mais próximos contribuem mais para a média do que os vizinhos mais distantes (16). Os vizinhos são retirados de um conjunto de objectos dos quais se conhece a classificação correcta. Este é considerado o conjunto de treino para o algoritmo (16).




Figura 13 - Representação da classificação K-NN. O círculo verde representa o exemplo de teste que se pretende classificar, ou seja vai ser atribuído a uma das duas classes (classe 1 dos quadrados azuis, ou classe 2 dos triângulos vermelhos). Se o $K=3$ o exemplo será atribuído à classe 2, uma vez que dos três vizinhos mais próximos, dois pertencem à classe 2. Se $K=5$ existem três quadrados e apenas dois triângulos, logo o exemplo de teste será atribuído à classe 1 (17).

4.6.1. Algoritmo

Os exemplos de treino são vectores num espaço multidimensional, cada um com um rótulo de

classe. A fase de treino do algoritmo consiste apenas na identificação dos rótulos de classe de cada vector constituinte da amostra de treino (16).

Na fase de classificação, k é uma constante definida pelo utilizador e um vector (de um objecto de teste) é classificado pela atribuição do nível que é mais frequente entre as k amostras de treino mais próximas a esse ponto de teste (16).

A escolha do melhor k depende dos dados. Geralmente k maiores reduzem o efeito do ruído sobre a classificação, mas criam limites entre as classes menos distintas.

Este método apresenta bons resultados, mas para bases de dados grandes, torna-se mais lento. Este problema pode ser minimizado, se for o conjunto de treino for reduzido, mas isso apresentará como consequência uma eventual perda de precisão e sensibilidade (16).

4.7. SVM

“Support Vector Machine” (SVM) é um conceito relacionado com a aprendizagem supervisionada que analisa os dados e reconhece padrões, permitindo a classificação dos mesmos. O SVM é um classificador linear binário não-probabilístico que utiliza um conjunto de dados, para os quais foi inicialmente estabelecida a classe, para prever a qual das duas classes possíveis pertencem os novos dados (18).

Dado um conjunto de exemplos de treino, cada um marcado como pertencente a uma das duas categorias, o algoritmo de treino do SVM constrói um modelo que atribui novos exemplos a uma das duas categorias (18). Um modelo SVM é uma representação dos exemplos como pontos no espaço, mapeados de forma que os exemplos das diferentes categorias são divididos por um intervalo claro que é o mais amplo possível. Novos exemplos são então mapeados para o mesmo espaço e é prevista a categoria a que pertencem com base no lado em que se situam (18).

O SVM linear constrói um hiper-plano ou conjunto de hiper-planos num espaço de alta ou infinita dimensão, que pode ser usado para classificação dos novos dados. O melhor hiper-plano é definido como uma função linear com a maior separação entre os vectores das duas classes, como está representado na Figura 14. A esta separação dá-se o nome de margem máxima (18).

Na “Support Vector Machine”, os pontos dos dados são vistos como vectores, e o objectivo é perceber se é possível separar esses vectores com um hiper-plano. Este é chamado de classificador linear. Há muitos hiper-planos que podem classificar os dados (18). O melhor hiper-plano é aquele que representa a maior separação, ou margem, entre as duas classes (Figura 15).




Figura 14 - Margem máxima, definida pela maior separação entre duas classes. Os exemplos que se encontram nas margens são os vectores de suporte (17).




Figura 15 - Representação de vários hiper-planos. O hiper-plano representado pela linha H3 (verde) não separa as duas classes. O hiper-plano representado pela linha H1 (azul) separa com uma margem pequena e o H2 (linha vermelha) separa com uma margem máxima, sendo este o melhor hiper-plano para classificar os dados (17).

Capítulo 5 - Metodologia

5.1. Introdução

Após a explicação dos aspectos teóricos relacionados com as onduletas e a sua classificação, será apresentada ao longo deste capítulo a metodologia utilizada para cumprir o objectivo deste trabalho, ou seja a obtenção da classificação automática da escala de Efron para a hiperémia conjuntival. Descrevem-se assim as características do sistema, a apresentação do descritor das imagens, a explicação da implementação dos classificadores K-NN e SVM, assim como todo o procedimento seguido. Evidentemente são também apresentados os resultados obtidos com a aplicação deste método.

5.2. Método

Assumindo que o sistema possui uma ferramenta que permite seleccionar apenas as regiões que interessam para a análise das imagens, vamos apenas considerar a porção de imagem que representa a área de interesse para esta condição específica. Desta forma foram eliminados cílios e partes de pálpebras, que surgem frequentemente nas fotografias de olhos.

A ferramenta computacional Matlab foi utilizada para o desenvolvimento dos algoritmos de processamento das imagens e dos resultados.

Neste tipo de processamento é conveniente usar-se um grande número de imagens. No entanto, como este trabalho não tem como objectivo desenvolver um método de captação de imagem, a recolha das mesmas foi efectuada através de pesquisa na internet. Deste modo, obtiveram-se imagens com características muito variadas, nomeadamente na sua qualidade de resolução e tamanho, características estas muitas vezes inadequadas para o processamento de imagem aqui efectuado. Para além disso, é igualmente difícil encontrar uma grande quantidade de imagens para cada grau da escala de Efron. Para minimizar o problema da escassez de imagens o número de imagens de treino foi aumentado, efectuando cortes ao longo de cada imagem (havendo sobreposição de partes da mesma). Assim obtiveram-se várias imagens de treino a partir da mesma, como se pode verificar pelo exemplo representado na Figura 16.




Figura 16 - Representação dos vários cortes que foram efectuados ao longo das imagens. Desta forma, foi possível obter várias imagens a partir da mesma, aumentando o número de imagens do grupo de treino.

5.3. Descritor

Cada imagem foi analisada pelas suas componentes vermelha, verde e azul separadamente e ainda pelo nível de cinzentos.

Para cada imagem, de treino e de teste, foi aplicada a transformada de onduleta discreta 2-D (inicialmente com o filtro db1), tendo sido utilizados dois níveis de decomposição, ou seja, foram utilizadas duas bandas da transformada, conforme representado na Figura 17.

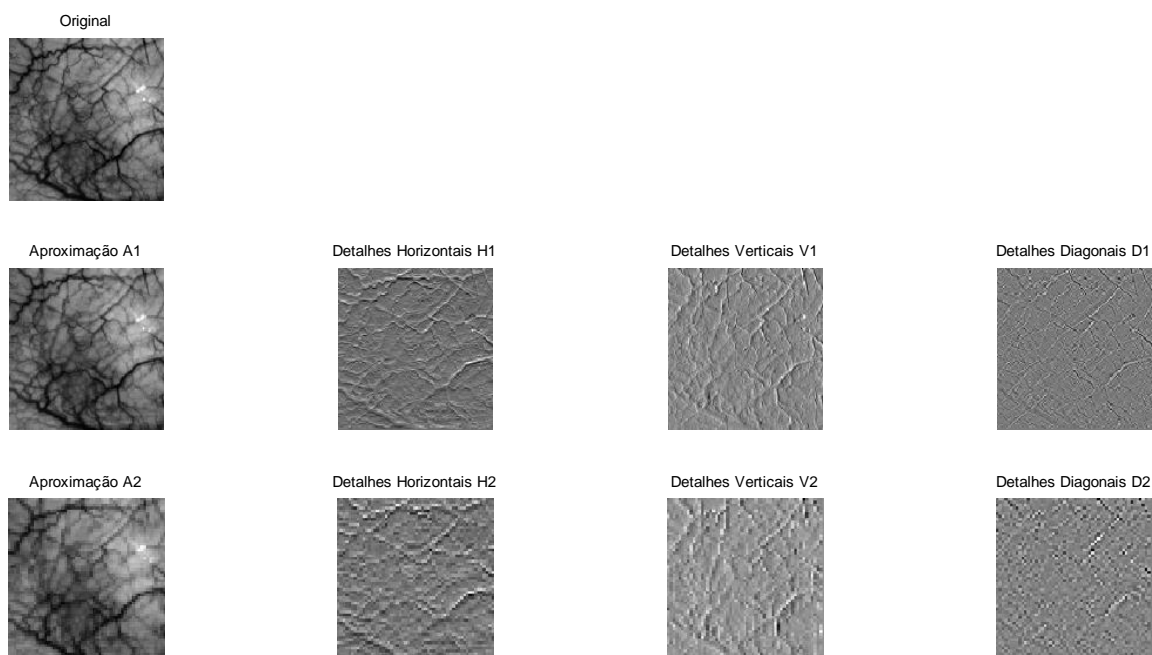


Figura 17 - Representação da aplicação de dois níveis de decomposição da onduleta. A partir da imagem original são obtidas duas aproximações e de cada uma são apresentados os detalhes horizontais, verticais e diagonais, que formam os coeficientes da imagem.

Desta forma, são obtidos quatro coeficientes para cada nível. Para o nível 1 temos o coeficiente da primeira aproximação (cA1), o coeficiente dos detalhes horizontais (cH1), o coeficiente dos detalhes verticais (cV1) e o coeficiente dos detalhes diagonais (cD1). O mesmo sucesso com o nível 2.

Posteriormente, é efectuado o cálculo da média e do desvio padrão de cada coeficiente, através das seguintes equações:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (19)$$

$$s = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2} \quad (20)$$

É ainda efectuada a normalização do descritor, na qual o valor do desvio padrão de cada coeficiente é dividido pela diferença entre o máximo do máximo de cada coeficiente e o mínimo do mínimo de cada coeficiente, ou seja:

$$D_{dp} = \frac{s(c)}{\max(\max(c)) - \min(\min(c))} \quad (21)$$

Em que D_{dp} representa um dos elementos do descritor do desvio padrão normalizado.

A normalização da média é efectuada pelo quociente da média de cada coeficiente pela soma da mesma.

$$D_m = \frac{\bar{x}}{\text{sum}(\bar{x})} \quad (22)$$

Em que D_m representa o descritor da média normalizado.

Desta forma, foram inicialmente formados três descritores:

- Descritor constituído pela média normalizada dos oito coeficientes resultantes da transformada
- Descritor constituído pelo desvio padrão normalizado dos oito coeficientes resultantes da transformada
- Descritor constituído pela normalização da média e desvio padrão (juntos) dos referidos coeficientes.

Na análise dos resultados efectuada posteriormente, cedo se constatou que o descritor da média não é efectivo na comparação das imagens e por esse motivo, os resultados para este descritor não serão incluídos no trabalho. Deste modo, sempre que ao longo do trabalho for feita referência aos descritores das imagens, será sempre ao descritor do desvio padrão e ao descritor da média com o desvio padrão juntos.

5.4. Classificação

Depois de definidos os descritores, pode agora ser feita a classificação das imagens nos diferentes graus da escala de Efron. Para isso, foram utilizados dois tipos de classificadores, o K-NN e o SVM.

Para a aplicação destes dois classificadores é necessário definir dois grupos, um de treino e um de teste. Neste trabalho, infelizmente foram apenas utilizadas 51 imagens, das quais 29 pertencem ao grupo de treino e 22 são usadas para teste. As 29 imagens do grupo de treino foram agrupadas da seguinte forma:

Tabela 1 - Número de imagens de treino utilizadas para cada grau da escala de Efron

| Grau | Número de imagens de treino |
|------|-----------------------------|
| 0 | 4 |
| 1 | 5 |
| 2 | 6 |
| 3 | 5 |
| 4 | 9 |

Inicialmente, do conjunto de todas as imagens representativas da hiperémia conjuntival foram seleccionadas as imagens do conjunto de treino que melhor representavam a escala de Efron. No fundo, este é um processo de calibração que permitirá melhorar o desempenho do sistema desenvolvido. Para isto, foi efectuada a análise do gráfico da Figura 18, onde são representadas as distâncias euclidianas entre os descritores calculados para todas as imagens recolhidas. Se uma imagem apresenta uma distância pequena em relação às imagens do seu grupo e uma distância grande em relação a todas as outras imagens, é uma boa imagem de treino. Se uma imagem apresenta uma distância semelhante entre todas as outras imagens do conjunto, não é uma boa imagem de treino e por isso é excluída.




Figura 18 - Distâncias do conjunto de imagens inicialmente recolhido. O gráfico representa a distância euclidiana dos descritores do desvio padrão entre todas as imagens. Neste exemplo a imagem 31 (de grau 2) apresenta uma distância pequena em relação às restantes do seu grupo (imagens 28 à 40) e uma distância superior em relação às dos outros graus e por isso é uma boa imagem de treino pertencente ao grau 2.

5.4.1. K-NN

O K-NN (K vizinhos mais próximos) classifica as imagens de teste, com base na classe atribuída às imagens do grupo de treino. A Figura 19 e Figura 20 representam o modo como é feita a classificação que é aplicada da seguinte forma:

- É criada uma matriz Grupo (Figura 19), que é constituída por cinco vectores (cinco linhas).
- Cada vector identifica um grau da escala de Efron, ou seja marca como positivas (com 1) as imagens que pertencem a cada grau. Assim, às quatro imagens que pertencem ao grau zero da escala de Efron, é atribuída classe 1 (na primeira linha da matriz) e é atribuída classe 0 às restantes imagens do conjunto de treino; às cinco imagens de grau 1 da escala de Efron é atribuída classe 1 (na segunda linha da matriz) e às restantes imagens do conjunto é atribuída classe 0. Este procedimento é repetido sucessivamente para os restantes graus da escala.
- Cada imagem do grupo de teste é classificada cinco vezes, ou seja o K-NN é aplicado utilizando como vector de classe, cada um dos cinco vectores definidos anteriormente.

- Em cada classificação obtém um resultado positivo (igual a 1) ou negativo (igual a 0). O resultado final das cinco classificações, esquematizado na Figura 20, permite encontrar o grau da imagem testada. No exemplo apresentado, o resultado positivo é obtido quando é usado como vector de classe o terceiro vector, que classifica as imagem do grau 2 da escala de Efron, por isso a imagem de teste é classificada com grau 2.

A utilização do K-NN como classificador binário, seguindo o esquema descrito, melhora o desempenho do sistema. No entanto, o K-NN poderia ser utilizado como um classificador de múltiplas classes, ao contrário do que acontece com o SVM.

| | | Imagens de treino | | | | | | | | | | | | | | | | | |
|--------------------------------|--------|-------------------|-------|-------|-------|-------|-------|-------|-------|-------|----------|----------|----------|----------|----------|----------|----------|-----|----------|
| | | I_1 | I_2 | I_3 | I_4 | I_5 | I_6 | I_7 | I_8 | I_9 | I_{10} | I_{11} | I_{12} | I_{13} | I_{14} | I_{15} | I_{16} | ... | I_{29} |
| Classe imagens de treino | Grau 0 | 1 | 1 | 1 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | ... | 0 |
| | Grau 1 | 0 | 0 | 0 | 0 | 1 | 1 | 1 | 1 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | ... | 0 |
| | Grau 2 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 | 1 | 1 | 1 | 1 | 1 | 1 | 0 | ... | 0 |
| | ⋮ | | | | | | | | | | | | | | | | | | |

Figura 19 - Esquematização da matriz Grupo, que representa a classe de cada imagem de treino.




Figura 20 - Exemplificação da classificação atribuída a uma imagem de teste

O número de vizinhos mais próximos usados para a classificação foi 1, ou seja a imagem de teste é simplesmente atribuída à classe de seu vizinho mais próximo.

Para comparação de resultados foram usadas diferentes distâncias, a euclidiana, a distância L_1 (“Manhattan”) e a correlação.

Considerando $p = (p_1, p_2, \dots, p_n)$ e $q = (q_1, q_2, \dots, q_n)$ dois vectores descritores, a distância euclidiana entre p e q é definida por:

$$d(p, q) = d(q, p) = \sqrt{\sum_{i=1}^n (q_i - p_i)^2} \quad (23)$$

Por outro lado, a distância L_1 entre p e q é definida por:

$$dc(p, q) = \sum_{i=1}^n |q_i - p_i| \quad (24)$$

A correlação C é definida por:

$$C(p, q) = \frac{cov(p, q)}{\sqrt{cov(p, p)cov(q, q)}} \quad (25)$$

Onde cov é a covariância, dada por:

$$cov(p, q) = E[(p - \mu_p)(q - \mu_q)] \quad (26)$$

Sendo E a esperança e $\mu_p = E(p)$

5.4.2. SVM

O classificador SVM atribui a classe às imagens de teste, usando apenas dois grupos, ou seja, a matriz Grupo tem que obrigatoriamente ser constituída por duas classes, tal como foi explicado na secção anterior. No entanto, com este classificador foi ainda necessário um passo adicional, em virtude do facto de em algumas situações se verificarem mais do que um resultado positivo na classificação das imagens de teste. Deste modo, quando esta situação se verifica, cada vector da matriz Grupo é constituído apenas pela classe de dois graus da escala (Figura 21), ou seja a classificação da imagem de teste é obtida comparando graus dois a dois. Observando o esquema da Figura 22, cada imagem é testada para o grau 0. Caso o resultado seja positivo, a imagem é classificada como pertencente a esse mesmo grau. Caso contrário, a operação é repetida para o grau 1. Se o resultado do SVM for 1, a imagem de teste é classificada com grau 1, caso contrário o processo é repetido para os graus seguintes.

| | Imagens de treino | | | | | | | | | | | | | | | | | | | |
|--------|-------------------|-------|-------|-------|-------|-------|-------|-------|-------|----------|----------|----------|----------|----------|----------|----------|----------|----------|----------|-----|
| | I_1 | I_2 | I_3 | I_4 | I_5 | I_6 | I_7 | I_8 | I_9 | I_{10} | I_{11} | I_{12} | I_{13} | I_{14} | I_{15} | I_{16} | I_{17} | I_{18} | I_{19} | ... |
| Grau 0 | 1 | 1 | 1 | 1 | 0 | 0 | 0 | 0 | 0 | | | | | | | | | | | |
| Grau 1 | | | | | 1 | 1 | 1 | 1 | 1 | 0 | 0 | 0 | 0 | 0 | 0 | | | | | |
| Grau 2 | | | | | | | | | | 1 | 1 | 1 | 1 | 1 | 1 | 0 | 0 | 0 | 0 | 0 |
| ⋮ | | | | | | | | | | | | | | | | | | | | |

Figura 21 - Esquematização dos vectores Grupo do SVM, que representam a classe de cada imagem de treino. A classificação é binária e foi efectuada testando dois graus de cada vez.

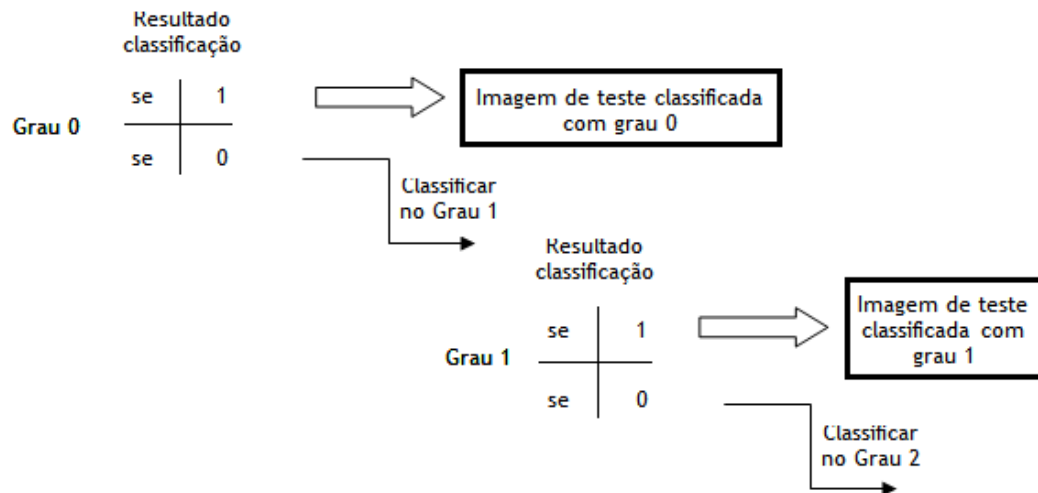


Figura 22 - Esquematização da classificação efectuada com o SVM. Cada imagem é testada para o grau 0, se o resultado for positivo, obtém-se a classe da imagem, se for negativo a operação é repetida para o grau seguinte, até que seja obtido um resultado positivo e consequentemente a classe da imagem de teste.

Foram usadas várias funções do núcleo de forma a seleccionar a que melhor se ajusta aos dados e por isso a que produz melhores resultados. As funções do “kernel” utilizadas foram a linear, quadrática e polinomial.

5.5. Tratamento estatístico

A Sensibilidade (S) consiste no número de casos positivos classificados como verdadeiros, dividido pelo número total de casos positivos existentes, ou seja:

$$S = \frac{VP}{VP + FN} \quad (27)$$

Onde VP é o número de casos verdadeiros positivos, ou seja, o número de casos correctamente classificados como positivos e FN é o número de falsos negativos, ou seja o número de casos erradamente classificados como negativos.

A Precisão (P) consiste no número de casos positivos classificados como verdadeiros, dividido pelo número total de casos classificados como positivos, isto é:

$$P = \frac{VP}{VP + FP} \quad (28)$$

Onde FP é o número de casos falsos positivos, ou seja aqueles que são erradamente classificados como positivos.

Desta forma, quando um resultado tem uma precisão de 100% significa que todos os dados classificados como pertencendo a uma determinada classe, pertencem de facto a essa classe, no entanto nada diz acerca do número de casos da classe que não são classificados

correctamente. Por outro lado, quando a sensibilidade é de 100% significa que todos os dados da classe foram classificados como pertencentes à mesma classe. No entanto, nada diz acerca do número de casos que são incorrectamente classificados como pertencentes à classe.

5.6. Resultados

Após a aplicação da transformada para obtenção dos descritores das imagens e classificação das mesmas, foram efectuadas várias comparações de resultados em termos de precisão e sensibilidade, de modo a perceber com que características se obtêm os melhores resultados. As comparações efectuadas foram as seguintes:

1. Comparação de resultados usando diferentes canais da imagem, ou seja utilização isolada dos canais verde, vermelho e azul da imagem e ainda o nível de cinzentos;
2. Comparação entre dois classificadores K-NN e SVM
3. Comparação de resultados usando os diferentes filtros das onduletas (“haar”, “daubechies2” e “coiflet1”);
4. Comparação dos resultados usando diferentes funções de “kernel” com o classificador SVM (linear, quadrática e polinomial)
5. Comparação dos resultados usando diferentes distâncias no K-NN (euclidiana, distância L_1 e correlação)

Em algumas situações estes resultados são ainda apresentados para os dois descritores, desvio padrão apenas e média e desvio padrão juntos.

5.6.1. Comparação de resultados usando diferentes canais da imagem

Da Figura 23 à Figura 30, estão representados o primeiro e segundo níveis de decomposição das imagens após a aplicação da transformada de onduleta para os diferentes canais da imagem, verde, vermelho e azul isoladamente e ainda para o nível de cinzentos. Nas Figura 23 e Figura 24, em que apenas é usado o canal verde da imagem, os vasos vermelhos encontram-se mais salientes, após o cálculo dos coeficientes da transformada das onduletas. Pelo contrário, os vasos estão mais atenuados na Figura 27 e Figura 28, onde foi seleccionado apenas o canal vermelho.

Da mesma forma, analisando o gráfico da Figura 31, onde estão representados os resultados dos dois descritores (descritor do desvio padrão representado por DP e descritor da média e desvio padrão juntos representado por MD) para a componente verde das imagens, para valores de sensibilidade entre 70% e 100% para os graus 1, 2, 3 e 4 da escala de Efron obtêm-se valores de precisão entre os 70% e 100%, quando é aplicado o K-NN. Para o grau 0 é obtida uma precisão de 100% para apenas 50% de sensibilidade. Neste caso os resultados são iguais para ambos os descritores. Relativamente aos resultados obtidos para as imagens analisadas apenas pela componente azul (Figura 32) e vermelha (Figura 33), estes são bastante mais

dispersos e inferiores, havendo valores de precisão e sensibilidade de 25% para o grau 3, no primeiro caso e 20% para o grau 2 na componente vermelha. No gráfico da Figura 34, que mostra os resultados obtidos com as imagens convertidas para cinzento, observamos que apesar de estes serem melhores do que os da componente vermelha ou azul, são inferiores aos da componente verde.




Figura 23 - Exemplo do primeiro nível de decomposição de uma imagem pertencente ao grupo de treino, após aplicação da transformada de onduleta à componente verde da imagem.




Figura 24 - Exemplo do segundo nível de decomposição de uma imagem pertencente ao grupo de treino, após aplicação da transformada de onduleta à componente verde da imagem.

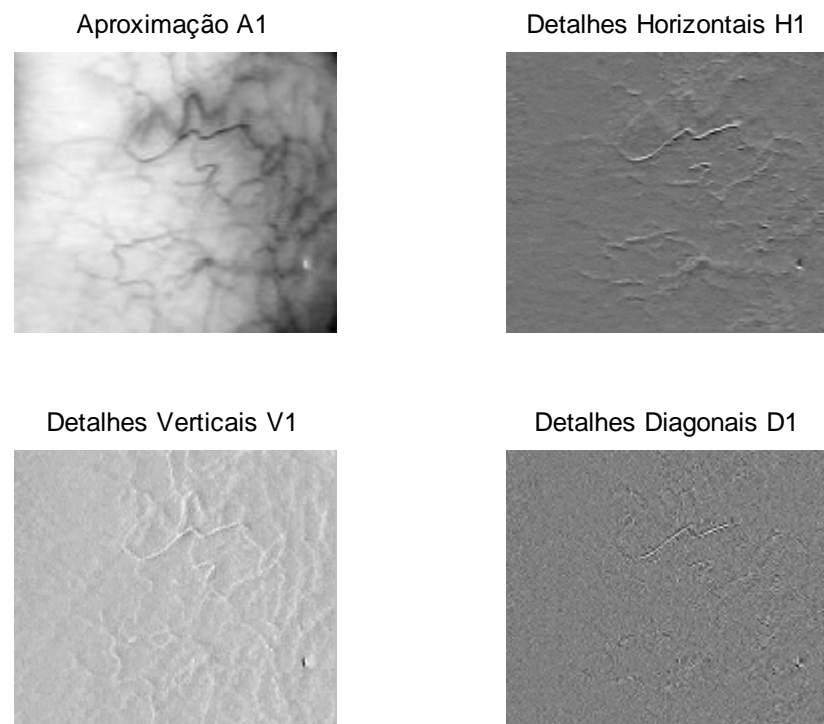


Figura 25 - Exemplo do primeiro nível de decomposição de uma imagem pertencente ao grupo de treino, após aplicação da transformada de onduleta à componente azul da imagem.




Figura 26 - Exemplo do segundo nível de decomposição de uma imagem pertencente ao grupo de treino, após aplicação da transformada de onduleta à componente azul da imagem.




Figura 27 - Exemplo do primeiro nível de decomposição de uma imagem pertencente ao grupo de treino, após aplicação da transformada de onduleta à componente vermelha da imagem.




Figura 28 - Exemplo do segundo nível de decomposição de uma imagem pertencente ao grupo de treino, após aplicação da transformada de onduleta à componente vermelha da imagem.




Figura 29- Exemplo do primeiro nível de decomposição de uma imagem pertencente ao grupo de treino, após aplicação da transformada de onduleta aos níveis de cinzentos da imagem.

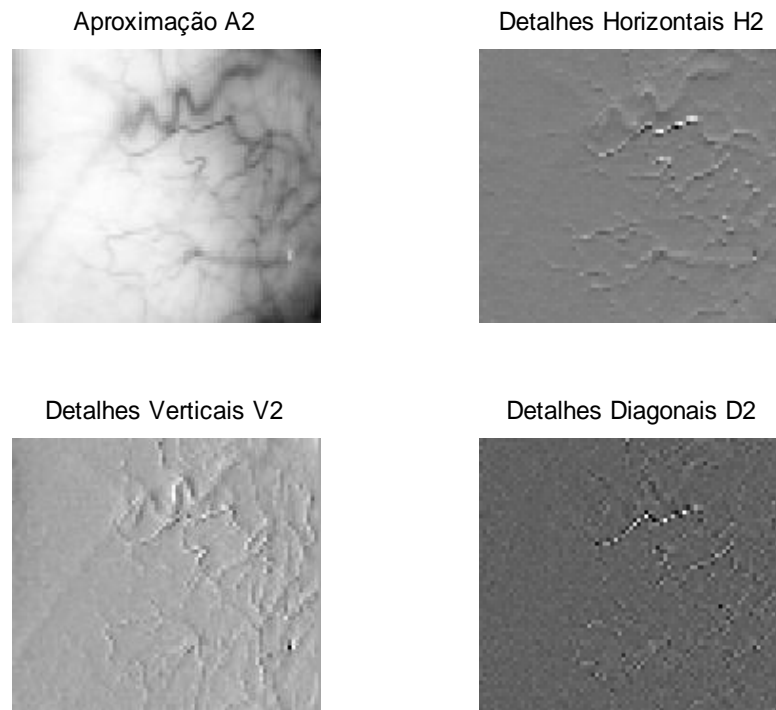


Figura 30 - Exemplo do segundo nível de decomposição de uma imagem pertencente ao grupo de treino, após aplicação da transformada de onduleta aos níveis de cinzentos da imagem.

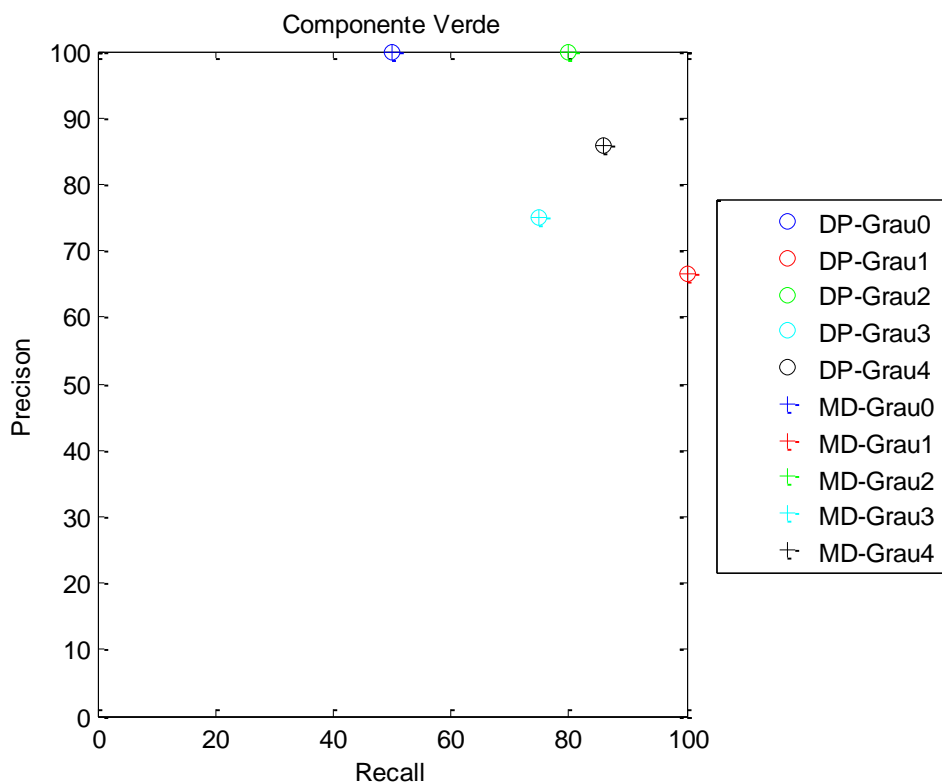


Figura 31 - Gráfico precisão/ sensibilidade para os cinco graus da escala de Efron e para ambos os descritores, desvio padrão e média com o desvio juntos, tendo sido seleccionada a componente verde das imagens. Foi usado o classificador K-NN com a distância euclidiana e o filtro da onduleta é o db1.

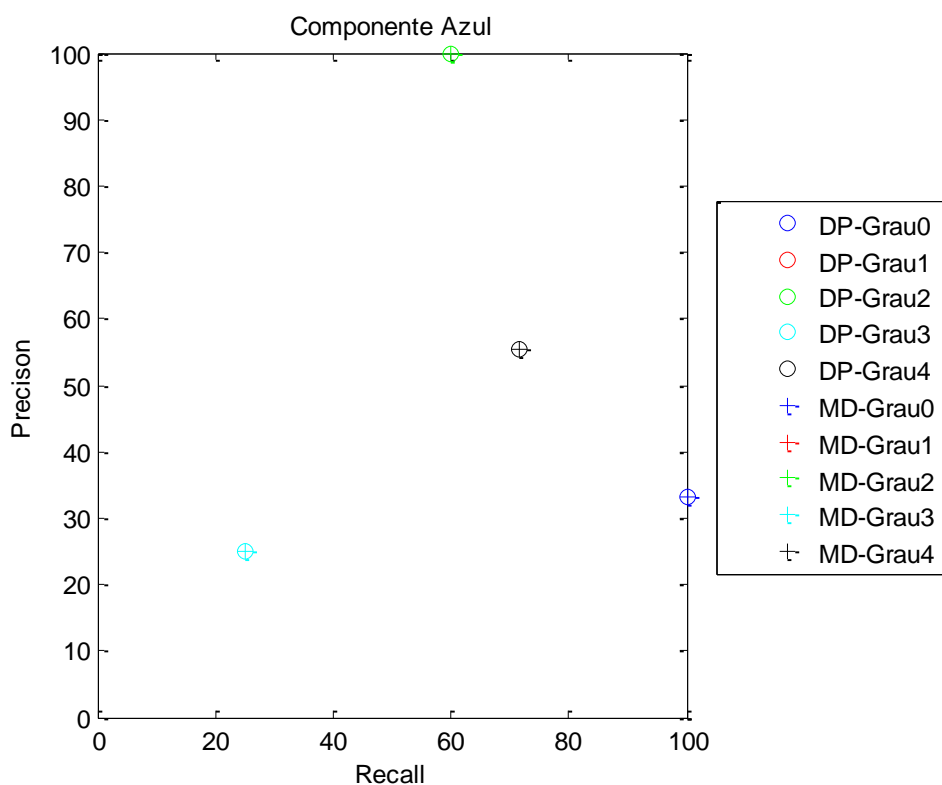


Figura 32 - Gráfico precisão/ sensibilidade para os cinco graus da escala de Efron e para ambos os descritores, desvio padrão e média com o desvio juntos, tendo sido seleccionada a componente azul das imagens. Foi usado o classificador K-NN com a distância euclidiana e o filtro da onduleta é o db1.

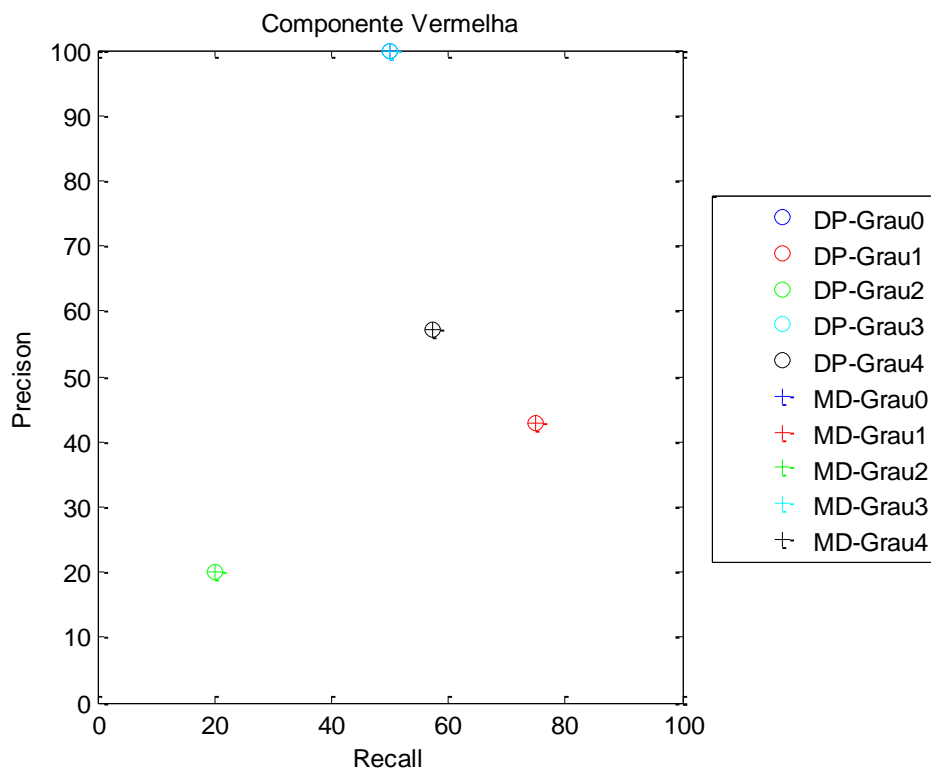


Figura 33 - Gráfico precisão/ sensibilidade para os cinco graus da escala de Efron e para ambos os descritores, desvio padrão e média com o desvio juntos, tendo sido seleccionada a componente vermelha das imagens. Foi usado o classificador K-NN com a distância euclidiana e o filtro da onduleta é o db1.




Figura 34 - Gráfico precisão/ sensibilidade para os cinco graus da escala de Efron e para ambos os descritores, desvio padrão e média com o desvio juntos, tendo sido as imagens convertidas para cinzentos. Foi usado o classificador K-NN com a distância euclidiana e o filtro da onduleta é o db1.

Tal como se pode verificar nos gráficos das Figura 31 à Figura 34, nesta situação em que são comparados os diferentes canais da imagem, os resultados são exactamente iguais quando se utiliza o descritor do desvio padrão (isolado) e o descritor da média e desvio padrão (juntos).

5.6.2. Comparação entre os classificadores KNN e SVM

Como já foi referido foram usados dois classificadores, o KNN e o SVM que foram testados com os dois descritores definidos. A relação Precisão/Sensibilidade relativamente a estes classificadores quando são utilizados os descritores obtidos a partir do desvio padrão dos coeficientes das onduletas, está apresentada no gráfico da Figura 35. Observamos que relativamente ao SVM, os valores de sensibilidade e precisão para os graus 0, 1 e 3 da escala, são inferiores a 80% e 40% respectivamente, enquanto que nos os graus 2 e 4, para sensibilidades de 100% e 90%, obtêm-se uma precisão de 60% e 90% respectivamente. Apesar disso, estes resultados são bastante mais dispersos e inferiores quando comparados com os do K-NN.

No caso do descritor da média com o desvio padrão juntos (Figura 36), os resultados são semelhantes aos obtidos apenas com o desvio padrão.

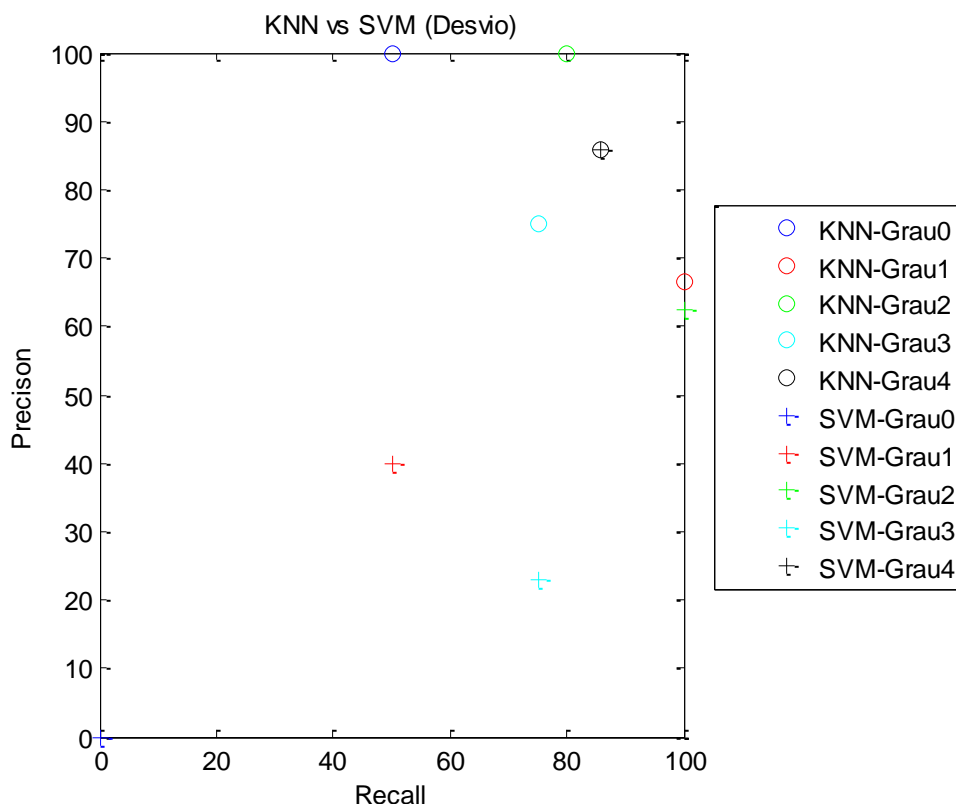


Figura 35 - Gráfico precisão/ sensibilidade para os cinco graus da escala de Efron. São comparados os dois classificadores KNN com SVM, utilizando o descritor com o desvio padrão. Foi seleccionada a componente verde das imagens, usada a “kernel function” linear no SVM e a distância euclidiana no K-NN. O filtro da onduleta usado foi o db1.




Figura 36 - Gráfico precisão/ sensibilidade para os cinco graus da escala de Efron. São comparados os dois classificadores KNN com SVM, utilizando o descritor com a média e o desvio padrão juntos. Foi seleccionada a componente verde das imagens, usada a “kernel function” linear no SVM e a distância euclidiana no KNN. O filtro da onduleta usado foi o db1.

5.6.3. Comparação de resultados usando os diferentes filtros das onduletas (“haar”, “daubechies2” e “coiflet1”);

Observando as Figura 37, Figura 38 e Figura 39, que representam o primeiro nível de decomposição resultante da aplicação da transformada com os diferentes filtros das onduletas, podemos mais uma vez constatar que os vasos sanguíneos (característica que queremos realçar nesta patologia específica) são realçados de maneira diferente, dependendo neste caso do filtro da onduleta que é usado. Assim, podemos verificar com este exemplo, que os vasos são mais facilmente identificados quando o filtro utilizado é o db1.

Da mesma forma, analisando o gráfico da Figura 40, onde são comparados os resultados utilizando os filtros db1, db2 e coif1, constatamos que os valores de precisão e sensibilidade com os filtros db2 e coif1 são inferiores aos resultados obtidos com o filtro db1. Com o filtro db2 os valores de sensibilidade e precisão situam-se entre os 20% e os 80%. Com o filtro coif1, os valores são ligeiramente melhores com sensibilidade entre os 40% e 60% e precisão entre os 40% e 70% para todos os graus excepto o grau 1, no qual os referidos valores são de 100% e 80%, respectivamente. Contudo, é com o filtro db1 que se obtêm resultados superiores.

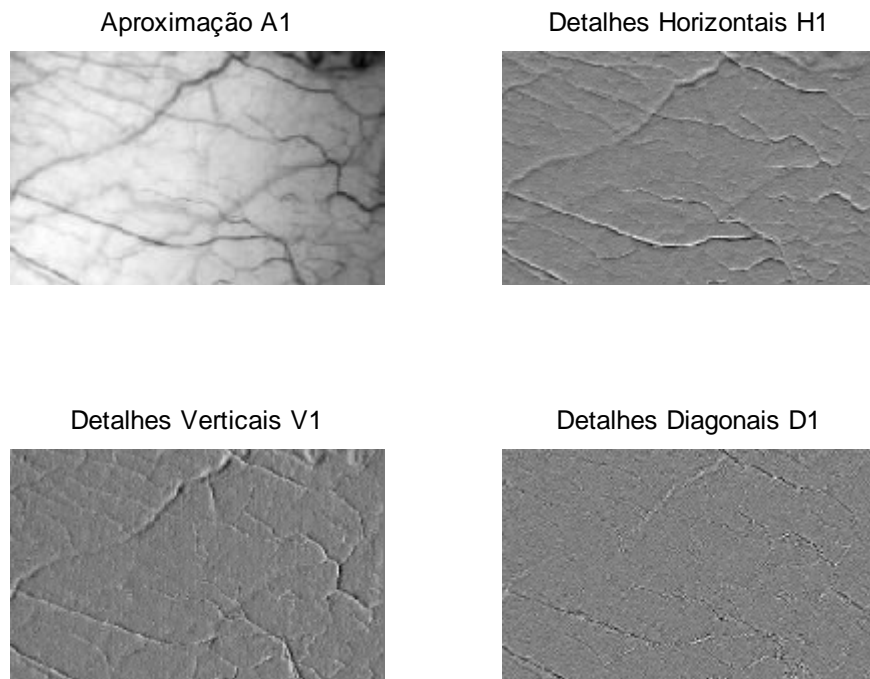


Figura 37 - Exemplo do primeiro nível de decomposição de uma imagem pertencente ao grupo de treino, após aplicação da transformada de onduleta com filtro db1.

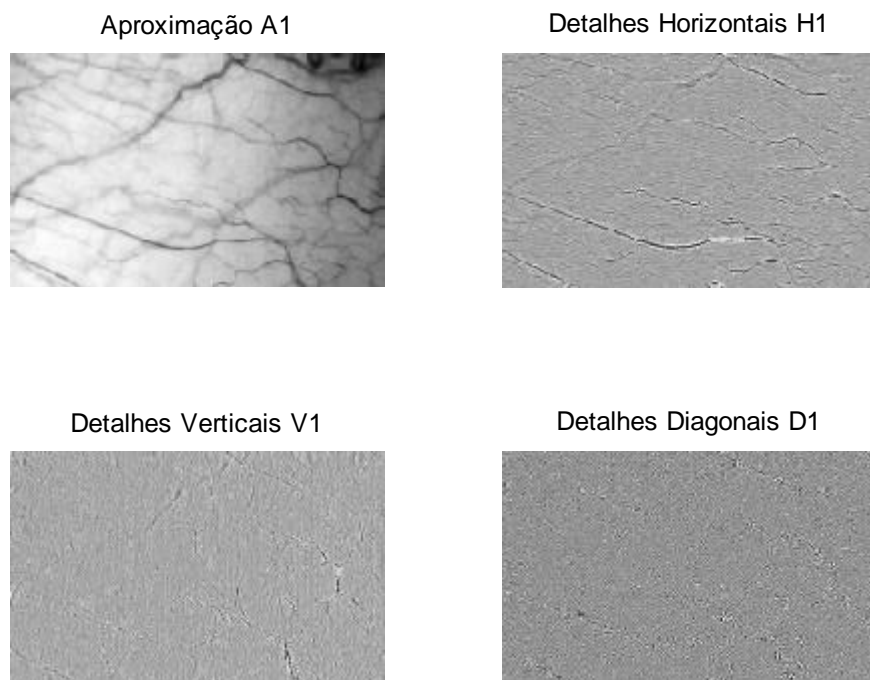


Figura 38 - Exemplo do primeiro nível de decomposição de uma imagem pertencente ao grupo de treino, após aplicação da transformada de onduleta com filtro db2.




Figura 39 - Exemplo do primeiro nível de decomposição de uma imagem pertencente ao grupo de treino, após aplicação da transformada de onduleta com filtro coif1.

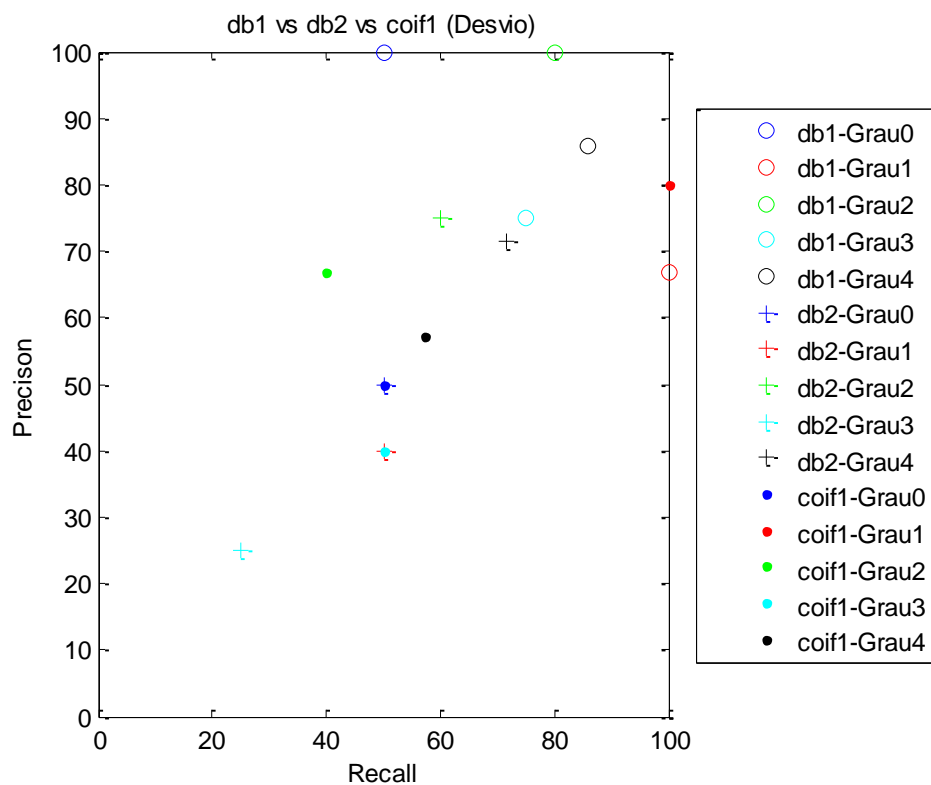


Figura 40 - Gráfico precisão/ sensibilidade para os cinco graus da escala de Efron. São comparados três filtros da onduleta, db1, db2 e coif1 para o descritor do desvio padrão. O classificador utilizado é o K-NN com a distância euclidiana e foi seleccionada a componente verde das imagens.

5.6.4. Comparação dos resultados usando diferentes funções “kernel” no SVM (linear, quadrática e polinomial)

Na comparação das diferentes funções “kernel” com o descritor do desvio padrão (Figura 41), é possível observar que os melhores resultados de Precisão/Sensibilidade, para qualquer uma das situações previamente especificadas, foram obtidos para os graus 2 e 4 (representados no gráfico a verde e preto) da escala de Efron. Com a utilização da função de “kernel” linear, para sensibilidades de 100% e 90%, nos referidos graus, obtêm-se valores de precisão de 60% e 90%, respectivamente. Com as funções quadrática e polinomial, os resultados são inferiores. No caso da função quadrática, apesar de se obterem valores de precisão e sensibilidade de 70% e 100% para o grau 4, para os restantes graus estes valores não vão além dos 60% e 80%, respectivamente. Quanto à polinomial, observamos que a sensibilidade se situa entre os 50% e 90%, para uma precisão que não ultrapassa os 60%.

Com o segundo descritor (com a média e desvio juntos), os melhores resultados continuam a ser para os graus 2 e 4, como é possível observar no gráfico da Figura 42. No entanto, em qualquer uma das funções utilizadas, os valores de precisão e sensibilidade são bastante dispersos, tal como se verifica com o descritor do desvio padrão.

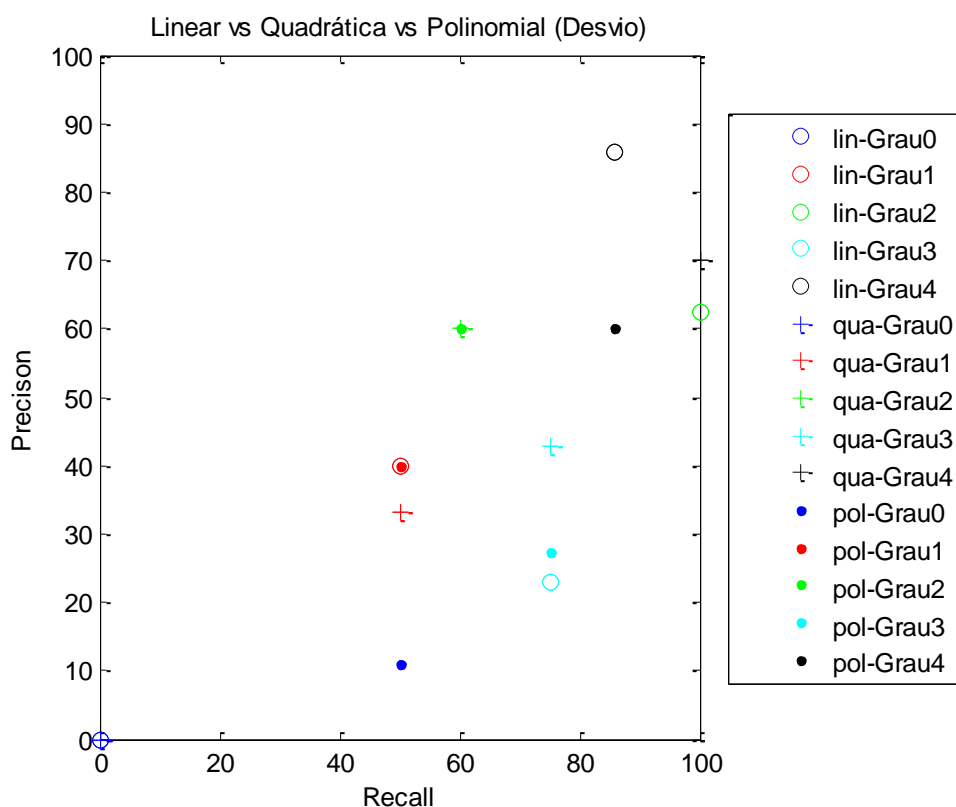


Figura 41- Gráfico precisão/ sensibilidade para os cinco graus da escala de Efron, onde são comparadas três “kernel function” do classificador SVM, linear, quadrática e polinomial, utilizando o descritor com o desvio. Foi seleccionada a componente verde das imagens e o filtro da onduleta usado foi o db1.




Figura 42 - Gráfico precisão/ sensibilidade para os cinco graus da escala de Efron, onde são comparadas três “kernel function” do classificador SVM, linear, quadrática e polinomial, utilizando o descritor com a média e o desvio juntos. Foi seleccionada a componente verde das imagens e o filtro da onduleta usado foi o db1.

5.6.5. Comparação dos resultados usando diferentes distâncias no K-NN (euclidiana, distância L_1 e correlação)

Através da observação dos gráficos das Figura 43 e Figura 44, podemos constatar que para a correlação, ao contrário do que acontece nas comparações das secções anteriores, obtêm-se melhores resultados com o descritor com a média e o desvio padrão juntos, do que usando apenas o desvio padrão. No caso da distância L_1 , os resultados são idênticos em ambos os descritores. Ainda assim, a distância euclidiana é a que oferece melhores resultados em ambos os descritores, estando estes mais concentrados na parte superior direita dos gráficos.

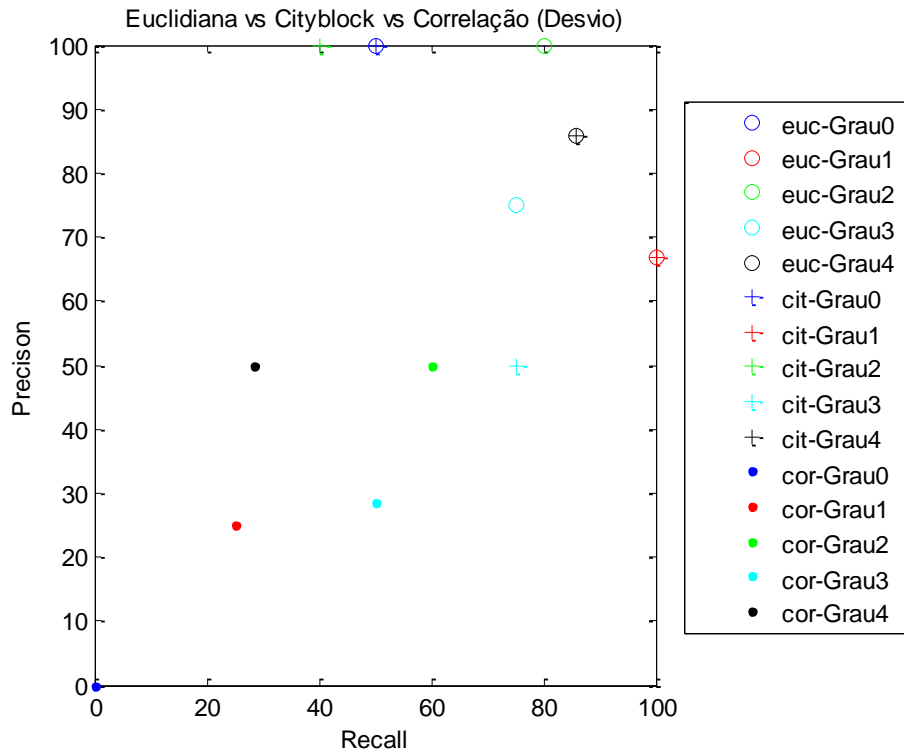


Figura 43 - Gráfico precisão/ sensibilidade para os cinco graus da escala de Efron, onde são comparadas três distâncias do classificador KNN, euclidiana, cityblock e correlação, utilizando o descritor com o desvio. Foi seleccionada a componente verde das imagens e o filtro da onduleta usado foi o db1.

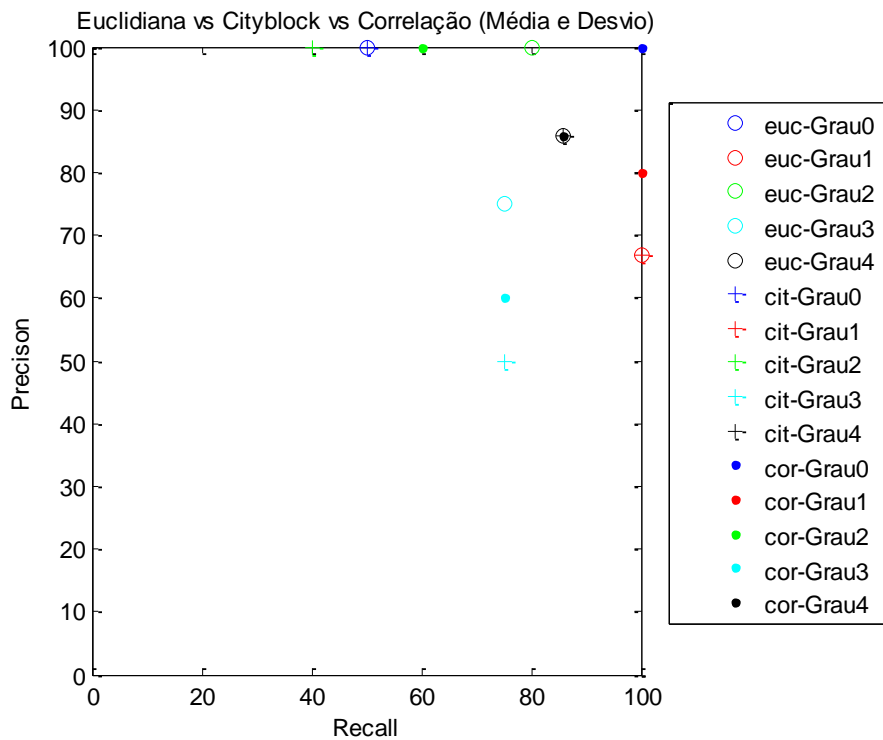


Figura 44 - Gráfico precisão/ sensibilidade para os cinco graus da escala de Efron, onde são comparadas três distâncias do classificador KNN, euclidiana, cityblock e correlação, utilizando o descritor com a média e o desvio juntos. Foi seleccionada a componente verde das imagens e o filtro da onduleta usado foi o db1.

Capítulo 6 - Conclusões

Ao longo deste trabalho foram efectuadas várias comparações de resultados, de modo a encontrar as características que os optimizam.

Relativamente ao uso isolado das diferentes componentes de cor da imagem, é possível constatar que os melhores resultados são obtidos usando apenas a componente verde de cada imagem. Esta situação deve-se ao facto de o verde ser a componente das imagens que melhor contraste apresenta em imagens do olho com hiperémia conjuntival. Ou seja, para esta condição específica (hiperémia conjuntival) as imagens são constituídas por vasos de cor vermelha sobre um fundo branco (esclera). A esclera, sendo branca possui as três componentes, verde, vermelho e azul, e os vasos sendo vermelhos, possuem maioritariamente componente vermelha, sendo o verde praticamente inexistente. Assim, quando é seleccionada apenas a componente verde das imagens, existe uma diferenciação clara entre a esclera e os vasos que consequentemente aparecem mais realçados. Quando a análise das imagens é efectuada apenas pela sua componente vermelha, obtêm-se os piores resultados, pela razão já explicada. Ou seja, os vasos (vermelhos) não proporcionam um contraste aceitável sobre a componente branca da esclera (porque as cores brancas são ricas em componente vermelha). A componente azul apresenta um comportamento intermédio.

Nos testes efectuados, o K-NN proporciona melhores resultados de classificação do que o SVM. No entanto é possível constatar que o SVM também apresenta bons resultados, para ambos os descritores, nos graus 2 e 4. Estes dois graus correspondem aos grupos que apresentam maior número de imagens de treino e é essa a razão pela qual surge essa melhoria. Na realidade, caso os grupos de treino tivessem maior número de imagens nos restantes graus da escala de Efron, possivelmente os resultados de classificação obtidos com o SVM seriam melhores.

Relativamente aos vários filtros da onduleta comparados, db1, db2 e coif1, verifica-se que é com o db1 que se obtêm os melhores resultados.

Quanto às diferentes funções de “kernel” utilizadas é com a linear que se obtêm os melhores resultados, mas mesmo neste caso, os resultados só são bons para dois graus, 2 e 4, devido à escassez de imagens de treino que se conseguiram coleccionar, tal como foi referido anteriormente.

Por outro lado, a distância euclidiana origina melhores resultados do que as distância L_1 e correlação. Esta situação pode estar relacionada com o facto de na selecção das imagens de treino terem sido usadas as distâncias euclidianas entre as várias imagens para analisar o gráfico das distâncias. Esta selecção funciona como uma calibração do sistema, podendo-se

escolher as imagens mais adequadas como imagem de treino e que por isso permitem um melhor desempenho do sistema de classificação.

Relativamente aos dois descritores usados, o desvio padrão normalizado, origina de forma geral melhores resultados do que o conjunto formado pelas médias normalizadas e desvios padrão normalizado dos coeficientes das onduleta.

Deste modo, pode-se concluir que os melhores resultados, para classificar automaticamente imagens na escala de Efron, são obtidos utilizando a componente verde das imagens, com a onduleta db1, o descritor obtido a partir do desvio padrão dos coeficientes das onduletas e usando como classificador o K-NN com a distância euclidiana.

Bibliografia

1. Fieguth P, Simpson T. Automated measurement of bulbar redness. *Investigative Ophthalmology Visual Science* 2002;43(2):340-7.
2. Sorbara L, Simpson T, Duench S, Schulze M, Fonn D. Comparison of an objective method of measuring bulbar redness to the use of traditional grading scales. *Journal of British Contact Lens Association* 2007;30(1): 53-9.
3. Papas EB. Key factors in the subjective and objective assessment of conjunctival erythema. *Investigative Ophthalmology Visual Science* 2000 Mar;41(3):687-91.
4. Peterson RC, Wolffsohn JS. Objective grading of the anterior eye. *Optometry and Vision Science* 2009 Mar;86(3):273-8.
5. Laine A, Fan J. Texture classification by wavelet packet signatures. *IEEE Transactions on Pattern Analysis and Machine Intelligence* 1993 Nov;15(11):1186-90.
6. Unser M. Texture classification and segmentation using wavelet frames. *IEEE Transactions on Image Processing* 1995 Nov;4(11):1549-60.
7. Do MN, Vetterli M. Wavelet-based texture retrieval using generalized gaussian density and kullback-leibler distance. *IEEE Transactions on Image Processing* 2002 Feb;11(2):146-58.
8. Fahmy G, Black J, Panchanathan S. Texture characterization for joint compression and classification based on human perception in the wavelet domain. *IEEE Transactions on Image Processing* 2006 Jun;15(6):1389-96.
9. Efron N. Contact lens complications. Butterworth Heineman; 2004. p. 69-75,223-38.
10. Conselho regional de óptica e optometria [Online]. [citado: 2011 Out 17]; Disponível em: URL:<http://www.croosp.org.br/work/ensino/index5.html>
11. Oliveira ER, González-Méijome JM. Materiais utilizados no fabrico de LC. Em: González-Méijome JM, editor. *Contactologia*. 2005.
12. Jin Y, Angelini E, Laine A. Wavelets in medical image processing: de-noising, segmentation, and registration. Em: Wilson DL, Laxminarayan S, Suri JS. *Handbook of biomedical image analysis. volume I: segmentation models part A*. New York (NY): Kluwer Academic/ Plenum Publishers; 2005. p. 305-16.

13. MathWorks [Online]. 1984-2011 [citado: 2011 Set 20]; Disponível em: URL:<http://www.mathworks.com/help/toolbox/wavelet/gs/f3-996747.html>
14. Qiao F, Milam R. Moments and vanishing wavelet moments. [Online]. [citado: 2011 Out 18]; Disponível em: URL:<http://cnx.org/content/m11156/2.1/>
15. Michie D, Spiegelhalter DJ, Taylor CC. Machine learning, neural and statistical classification. 1994. p. 2-15,17-27,30-5.
16. Wikipedia, the free encyclopedia [Online]. [citado: 2011 Ago 20]; Disponível em: URL:http://en.wikipedia.org/wiki/Support_vector_machine
17. Cortes C, Vapnik V. Support-Vector Networks. Boston: Kluwer Academic Publishers; 1995. p. 273-97.