



UNIVERSIDADE D  
COIMBRA



Catarina Barradas Casteleiro Penacho

**AVALIAÇÃO SETORIAL DE QUALIDADE E DETEÇÃO DE  
ARTEFACTOS EM RETINOGRAFIAS**

VOLUME 1

Dissertação no âmbito do Mestrado Integrado em Engenharia Electrotécnica e de Computadores, ramo de especialização de Automação orientada pelo Professor Doutor Luís Alberto da Silva Cruz e apresentada na Faculdade de Ciências e Tecnologia/Departamento de Engenharia Electrotécnica e de Computadores.

Setembro de 2018





**Universidade de Coimbra**  
Faculdade de Ciências e Tecnologia  
Departamento de Engenharia Electrotécnica e de Computadores

# **Avaliação Setorial de Qualidade e Detecção de Artefactos em Retinografias**

**Catarina Barradas Casteleiro Penacho**

Dissertação submetida ao Departamento de Engenharia Eletrotécnica e de Computadores da Faculdade de Ciências e Tecnologia da Universidade de Coimbra de acordo com os requisitos a cumprir para o grau de Mestre em Engenharia Eletrotécnica e de Computadores.

**Orientador:** Prof. Doutor Luís Alberto da Silva Cruz

**Júri:** Prof. Doutor Hélder de Jesus Araújo  
Prof. Doutor João Pedro de Almeida Barreto  
Prof. Doutor Luís Alberto da Silva Cruz

**Setembro, 2018**



# Agradecimentos

Esta dissertação simboliza a conclusão da última etapa do meu percurso académico na Universidade de Coimbra. A esta instituição e a todas as pessoas que de alguma forma me acompanharam nesta jornada, desde colegas a professores, presto os meus agradecimentos.

Primeiro, gostaria de expressar a minha gratidão ao Professor Doutor Luís Cruz por me ter apresentado a este projeto que me habilitou a expandir os meus conhecimentos e o meu pensamento crítico.

Agradeço também aos meus colegas da Retmarker S.A pelo seu apoio contínuo em especial ao meu supervisor o Eng. Nuno Almeida, mas também aos engenheiros Frederico Teles, João Pinto e João Diogo Ramos.

Também gostaria de mencionar o Instituto de Telecomunicações por me ter fornecido todos os recursos necessários para concluir esta fase de estudos.

Aos amigos e colegas que me acompanharam ao longo destes anos, gostaria de agradecer o vosso apoio e os bons momentos que me proporcionaram. Estou eternamente grata pela vossa amizade, tendo-me auxiliado na ultrapassagem de todas as adversidades ao longo deste curso. Todas as memórias que partilhamos iram-me acompanhar para o resto da vida.

Finalmente, devo expressar a minha profunda gratidão à minha família, especialmente aos meus pais José António e Maria Teresa, à minha avó Idalina e ao meu irmão José Duarte. O seu apoio incondicional e valores transmitidos garantiram a conquista de todos os meus feitos.



# Resumo

Atualmente, devido ao envelhecimento da população, existe um crescimento no número de casos de patologias na retina. Na medida em que estas doenças podem vir a ser tratadas ou até prevenidas, é fundamental detetar antecipadamente, diagnosticar e ter uma avaliação permanente do paciente. Uma das abordagens utilizadas para monitorizar as doenças de forma não invasiva, é o recurso a fotografias digitais da retina avaliadas por um oftalmologista. Contudo, esta requer bastantes profissionais desta área médica e grandes quantidades de armazenamento. Uma resolução prática e económica em termos de custos e tempo é a avaliação automatizada de retinografias digitais. Porém, cerca de 10%-20% das retinografias tiradas nestes exames são consideradas não classificáveis, sendo difícil ou impossível de realizar o diagnóstico exato da doença. Neste contexto, são propostos dois métodos distintos.

O primeiro incide na alteração de um algoritmo já existente de classificação de qualidade usando indicadores genéricos de imagem, de forma a analisar setores oculares individualmente. Após a segmentação do disco ótico, da fóvea e da área restante, as regiões são classificadas em termos de cor, foco, contraste, iluminação e qualidade global. Um estudo sobre o raio das regiões, bem como a substituição dos classificadores utilizados e a incorporação de descritores de textura foram realizados de forma a adaptar o método original. Após as modificações necessárias, o algoritmo de setorização segmentou corretamente as retinografias e, no geral, foi melhorada a performance do algoritmo de classificação de qualidade dos setores.

O segundo consiste num método de classificação de artefactos recorrendo a redes neurais convolucionais. Foram consideradas cinco classes possíveis: imagens contendo artefactos de reflexão de luz, imagens desfocadas, contendo sobreposição luminosa, iluminação insuficiente ou imagens com boa qualidade. Diferentes arquiteturas e valores de parâmetros foram testados, de forma a garantir o melhor desempenho. Implementado o modelo e utilizando 4000 imagens de teste, a exatidão do modelo foi apenas de 77.32%. No entanto, para a classe indicadora de boa qualidade foi obtida uma precisão de 99.13%, uma sensibilidade de 99.375% e uma especificidade de 99.81%.

Apesar de avaliarem aspetos distintos, ambos os métodos enunciados melhoram o ato de aquisição de retinografias em rastreios oftalmológicos, facilitando o processo de diagnóstico.

**Palavras-chave:** Qualidade de Retinografias, Classificação, Setorização, Redes Neurais Convolucionais, Artefactos.



# Abstract

Currently, due to an increase in the aging population, there is a rise in the number of cases of pathologies in the retina. Since these diseases can be treated or prevented, it is essential to detect the pathology in advance, diagnose and evaluate the patient continuously. One of the approaches used to monitor diseases in a non-invasive way, is to resort to digital retinal photographs evaluated by an ophthalmologist. However, for this purpose it is necessary plenty of professionals of this medical field and a large amount of storage. A practical and economic solution in terms of cost and time is the automated evaluation of digital retinographies. However, about 10%-20% of the images taken from these exams are considered not classifiable because it is impossible to carry out a precise diagnosis of the disease. In this context, two different solutions are proposed.

The first proposed solution focuses on altering an already existing quality classification algorithm using generic image indicators, to analyse retinal sectors individually. After the segmentation of the optical disc, fovea and of the remaining area, the regions are classified in terms of colour, focus, contrast, lighting and overall quality. A study on the selection of the radius of the considered regions, as well as the replacement of the classifiers and an incorporation of textural features were carried out in order to adapt the original method. After the necessary modifications were made, the sectorization algorithm segmented correctly the retinographies and, in general, the proposed classifiers offered a better performance than the classifiers of the source project.

The second solution consists of an artifact classification method using convolutional neural networks. Five possible classes were considered: images with light reflection artifacts, blurry images, containing overexposure, insufficient lighting and good quality images. Different architectures and parameter values were tested to ensure the best performance. After implementing the model and using 4000 test images, an accuracy of only 77.32% was obtained. However, for the good quality indicator class an accuracy of 99.13%, a sensitivity of 99.375% and a specificity of 99.81% were obtained. Although these approaches evaluate distinct characteristics, both methods improve the process of acquisition of retinographies in ophthalmologic screenings, facilitating the diagnostic process.

**Key words:** Quality of Retinographies, Classification, Sectorization, Convolutional Neural Networks, Artifacts.



# Símbolos e Abreviações

## Lista de Acrónimos

AD	<i>Área Discal</i>
ANN	<i>Artificial Neural Network</i>
CNN	<i>Convolutional Neural Network</i>
CRR	<i>Correct Recognition Rate</i>
DDO	<i>Diâmetro do Disco Ótico</i>
DET	<i>Detection Error Trade-off</i>
DMI	<i>Degeneração Macular relacionada com a Idade</i>
FAR	<i>False Accept Ratio</i>
FBB	<i>Feed-Forward Backpropagation</i>
FN	<i>False Negative</i>
FOV	<i>Field Of View</i>
FP	<i>False Positive</i>
FRR	<i>False Reject Ratio</i>
GLCM	<i>Gray Level Cooccurrence Matrix</i>
ISC	<i>Image Structure Clustering</i>
KNN	<i>K-Nearest Neighbours</i>
NCHS	<i>National Center for Health and Statistics</i>
NHANES	<i>National Health and Nutrition Examination Survey</i>
OCT	<i>Optical Coherence Tomography</i>
QUARTZ	<i>Quantitative Analysis of Retinal Vessel Topology and size</i>
RAM	<i>Random-Access Memory</i>
ReLU <sub>s</sub>	<i>Rectified Linear Unit</i>
ROC	<i>Receiver Operating Characteristic</i>
ROI	<i>Region Of Interest</i>
SFFS	<i>Sequential Forward Floating Selection</i>
SGD	<i>Stochastic Gradient Descent</i>
SLO	<i>Scanning Laser Ophthalmoscopy</i>

SVM	<i>Support Vector Machine</i>
TP	<i>True Positive</i>
TN	<i>True Negative</i>

## Formulações Matemáticas

### Avaliação Setorial de Qualidade de Retinografias

$u$	<i>Média da intensidade dos pixels de cada circunferência</i>
$P(u)$	<i>Função polinomial que representa a média da intensidade dos pixels de cada circunferência</i>
$N_g$	<i>Tamanho da matriz quadrada de coocorrência</i>
$p(i, j)$	<i>Elemento <math>(i, j)</math> da matriz de coocorrência</i>
$p_x, p_y$	<i>Funções parciais de densidade de probabilidade da matriz de coocorrência</i>
$\mu_x, \mu_y$	<i>Médias de <math>p_x</math> e <math>p_y</math> respectivamente</i>
$\sigma_x, \sigma_y$	<i>Variâncias de <math>p_x</math> e <math>p_y</math> respectivamente</i>
$p_{x+y}(i)$	<i>Probabilidade da soma das coordenadas da matriz de coocorrência ser igual a <math>i</math></i>
$HX, HY$	<i>Entropias de <math>x</math> e <math>y</math> respectivamente</i>
$Q$	<i>Maior valor próprio da matriz de coocorrências</i>

### Apêndice A

$C_{1,2,3}$	<i>Medidas de Cor</i>
$F_{1,2,3}$	<i>Medidas de Foco</i>
$f_1, f_2$	<i>Medidas de informação de Foco</i>
$Ct_{1,2,3,4}$	<i>Medidas de Contraste</i>
$I_{1,2,3,4}$	<i>Medidas de Iluminação</i>

# Conteúdo

Agradecimentos	i
Resumo	iii
Abstract	v
Símbolos e Abreviações	vii
Conteúdo	xi
Lista de Figuras	xvi
Lista de Tabelas	xx
<b>1 Introdução</b>	<b>1</b>
1.1 Motivação e Contextualização do Problema . . . . .	1
1.2 Visão geral do Documento . . . . .	3
<b>2 Anatomia Ocular e Patologias Oftalmológicas</b>	<b>5</b>
2.1 Anatomia Ocular . . . . .	5
2.2 Patologias Oftalmológicas . . . . .	6
<b>3 Avaliação de Retinografias</b>	<b>11</b>
3.1 Qualidade de Retinografias . . . . .	12
3.1.1 Fatores Genéricos . . . . .	12
3.1.2 Fatores Morfológicos . . . . .	13
3.2 Métodos de Avaliação de Qualidade em Retinografias . . . . .	14
3.2.1 Métodos baseados em características genéricas de imagem . . . . .	15
3.2.2 Métodos baseados em características morfológicas . . . . .	19
3.2.3 Métodos baseados em características morfológicas e genéricas de imagem . . . . .	22
3.3 Detecção e Classificação de Artefactos em Retinografias . . . . .	23
<b>4 Materiais e Equipamentos Usados</b>	<b>27</b>
4.1 Bancos de Imagens Públicos . . . . .	27

4.2	Bancos de Imagens Privados . . . . .	27
4.3	Recolha de Imagens de Treino e Teste . . . . .	27
4.4	Plataformas e Software . . . . .	28
<b>5</b>	<b>Avaliação Setorial de Qualidade de Retinografias</b>	<b>29</b>
5.1	Implementação do Método Proposto . . . . .	30
5.1.1	Pré-Processamento e Recolha de Imagens de Teste . . . . .	30
5.1.2	Algoritmo de Setorização . . . . .	30
5.1.3	Optimização . . . . .	33
5.1.3.1	Avaliação dos Classificadores . . . . .	34
5.1.3.2	Implementação dos Descritores de Textura . . . . .	34
5.2	Resultados e Discussão . . . . .	37
5.2.1	Estudo do Efeito da Variação do Raio sobre o Desempenho . . . . .	38
5.2.1.1	Raio da Região do Disco Ótico . . . . .	38
5.2.1.2	Raio da Região da Fóvea . . . . .	39
5.2.2	Análise de Desempenho para Diferentes Classificadores . . . . .	40
5.2.2.1	Classificador da Região do Disco Ótico . . . . .	40
5.2.2.2	Classificador da Região da Fóvea . . . . .	40
5.2.2.3	Classificador da Área Restante . . . . .	41
5.2.2.4	Classificador da Imagem Completa . . . . .	42
5.2.3	Implementação dos Descritores de Textura . . . . .	42
5.2.3.1	Disco Ótico . . . . .	42
5.2.3.2	Fóvea . . . . .	43
5.2.4	Discussão . . . . .	43
<b>6</b>	<b>Método de Classificação de Artefactos em Retinografias</b>	<b>45</b>
6.1	Método Proposto . . . . .	45
6.1.1	Preparação do Conjunto de Imagens de Treino e Teste . . . . .	46
6.1.2	Modelo . . . . .	47
6.2	Resultados e Discussão . . . . .	49
6.2.1	Taxa de Aprendizagem . . . . .	50
6.2.2	Épocas . . . . .	50
6.2.3	Dimensão dos Conjuntos . . . . .	51
6.2.4	Regularização L2 . . . . .	51
6.2.5	Teste do Modelo . . . . .	52
6.2.6	Discussão . . . . .	54
<b>7</b>	<b>Conclusão e Trabalho Futuro</b>	<b>55</b>
<b>A</b>	<b>Avaliação da qualidade de retinografias usando indicadores genéricos de qualidade de imagem</b>	<b>57</b>

<b>B Exemplos de Imagens de Treino</b>	<b>65</b>
<b>C Resultados Adicionais - Avaliação Setorial de Qualidade de Retinografias</b>	<b>67</b>
<b>D Resultados Adicionais - Método de Classificação de Artefactos em Retinografias</b>	<b>79</b>
<b>Bibliografia</b>	<b>81</b>



# Lista de Figuras

2.1	Anatomia do Olho, adaptado de [11]. . . . .	6
2.2	Retinografias com indícios de: (a) Catarata [18], (b) Glaucoma [19], (c) Deslocamento da Retina [20], (d) Degeneração Macular relacionada com a Idade e (e) Retinopatia Diabética não Proliferativa [21]. . . . .	7
3.1	Retinografia com boa qualidade [23]. . . . .	12
3.2	Exemplos de irregularidades na imagem: (a) desfocagem [22], (b) presença de névoa [22], (c) presença de arco [22], (d) pestanejar [23], (e) definição de campo incorreta [24] e (f) iluminação irregular [22]. . . . .	15
3.3	Figura à esquerda corresponde numa retinografia com boa qualidade e a da direita numa com má qualidade. Em baixo encontram-se as respetivas distribuições da magnitude das bordas de acordo com as evidências de Lalonde <i>et al.</i> [30]. As imagens cinzentas estão com as cores invertidas para uma melhor visualização. . . . .	16
3.4	Gráfico de dispersão demonstrando a separabilidade das classes "Boa" ( <i>Good</i> ), "Má" ( <i>Bad</i> ) e "Razoável" ( <i>Fair</i> ), de acordo com as evidências de Lalonde <i>et al.</i> [30]. . . . .	16
3.5	Regiões de processamento delimitadas por uma grelha, de acordo com Davis <i>et al.</i> [8]. . . . .	17
3.6	Comparação entre desempenhos representada pelas curvas DET [55]. . . . .	25
5.1	Retinografia com setores em estudo assinalados. A circunferência azul destaca o disco ótico e a circunferência verde a zona da fóvea. Adaptado de [45]. . . . .	29
5.2	Imagem original e as respetivas secções em estudo: (a) imagem original [45], (b) região do disco ótico, (c) região da fóvea, (d) região restante. . . . .	31
5.3	Máscaras das secções da Fig. 5.2.a : (a) região do disco ótico, (b) região da fóvea, (c) região restante. . . . .	32
5.4	Imagem original e as imagens após cada etapa de filtragem: (a) imagem original [45], (b) após a aplicação do filtro de dilatação, (c) após a aplicação do filtro de erosão, (d) após a aplicação do filtro de mediana. . . . .	33
5.5	Diagrama que descreve o algoritmo de setorização proposto. . . . .	34

5.6	As quatro direções de vizinhança possíveis definidas no cálculo de descritores de Haralick [53]. . . . .	35
5.7	Gráfico obtido variando o raio do disco ótico. O eixo das abcissas representa o rácio entre o raio da região e o raio do disco ótico (intervalos de uma décima) e o eixo das ordenadas representa os valores de precisão. O gráfico refere-se à classificação da qualidade global da imagem. . . . .	39
5.8	Gráfico obtido variando o raio da fóvea. O eixo das abcissas representa o rácio entre o raio da região e o raio da fóvea (intervalos de uma décima) e o eixo das ordenadas representa os valores de precisão. O gráfico refere-se à classificação da qualidade global da imagem. . . . .	39
6.1	Diagrama que descreve as fases de pré-processamento executadas. . . . .	47
6.2	Modelo da Rede Neuronal Convolutacional proposto. . . . .	48
6.3	Gráficos da perda(a) e da exatidão(b) obtidos no treino da rede em estudo. . . . .	53
A.1	Fluxograma do algoritmo proposto por Dias <i>et al.</i> . Adaptado de [9]. . . . .	59
B.1	Exemplos de retinografias do banco de imagens Messidor [50]. . . . .	65
C.1	Gráfico obtido variando o raio do disco ótico. O eixo das abcissas representa os valores multiplicados pelo raio original da zona considerada e o eixo das ordenadas representa os valores de: (a) precisão, (b) sensibilidade, (c) especificidade. O gráfico refere-se à classificação da cor da imagem. Como é possível verificar, no geral, considerando as 3 medidas, os valores aumentam com o crescimento do raio. . . . .	67
C.2	Gráfico obtido variando o raio do disco ótico. O eixo das abcissas representa os valores multiplicados pelo raio original da zona considerada e o eixo das ordenadas representa os valores de: (a) precisão, (b) sensibilidade, (c) especificidade. O gráfico refere-se à classificação do foco da imagem. Como é possível verificar, através da análise da precisão, é alcançada melhor performance quando considerado o raio original. . . . .	68
C.3	Gráfico obtido variando o raio do disco ótico. O eixo das abcissas representa os valores multiplicados pelo raio original da zona considerada e o eixo das ordenadas representa os valores de: (a) precisão, (b) sensibilidade, (c) especificidade. O gráfico refere-se à classificação do contraste da imagem. O gráfico refere-se à classificação do foco da imagem. Como é possível verificar, através da análise da precisão, é alcançada melhor performance quando considerado o dobro do raio. . . . .	68

C.4	Gráfico obtido variando o raio do disco ótico. O eixo das abcissas representa os valores multiplicados pelo raio original da zona considerada e o eixo das ordenadas representa os valores de: (a) precisão, (b) sensibilidade, (c) especificidade. O gráfico refere-se à classificação da iluminação da imagem. Como é possível verificar, considerando as 3 medidas, os valores aumentam com o crescimento do raio. . . . .	69
C.5	Gráfico obtido variando o raio do disco ótico. O eixo das abcissas representa os valores multiplicados pelo raio original da zona considerada e o eixo das ordenadas representa os valores de: (a) sensibilidade, (b) especificidade. O gráfico refere-se à classificação de qualidade global da imagem. Como é possível verificar, considerando as 2 medidas, os valores aumentam com o crescimento do raio. . . . .	69
C.6	Gráfico obtido variando o raio da fóvea. O eixo das abcissas representa os valores multiplicados pelo raio original da zona considerada e o eixo das ordenadas representa os valores de: (a) precisão, (b) sensibilidade, (c) especificidade. O gráfico refere-se à classificação da cor da imagem. Como é possível verificar, considerando as 3 medidas, os valores aumentam com o crescimento do raio. . . . .	70
C.7	Gráfico obtido variando o raio da fóvea. O eixo das abcissas representa os valores multiplicados pelo raio original da zona considerada e o eixo das ordenadas representa os valores de: (a) precisão, (b) sensibilidade, (c) especificidade. O gráfico refere-se à classificação do foco da imagem. Como é possível verificar, no geral, considerando as 3 medidas, os valores aumentam com o crescimento do raio. . . . .	70
C.8	Gráfico obtido variando o raio da fóvea. O eixo das abcissas representa os valores multiplicados pelo raio original da zona considerada e o eixo das ordenadas representa os valores de: (a) precisão, (b) sensibilidade, (c) especificidade. O gráfico refere-se à classificação do contraste da imagem. Como é possível verificar, no geral, considerando as 3 medidas, os valores aumentam com o crescimento do raio. . . . .	71
C.9	Gráfico obtido variando o raio da fóvea. O eixo das abcissas representa os valores multiplicados pelo raio original da zona considerada e o eixo das ordenadas representa os valores de: (a) precisão, (b) sensibilidade, (c) especificidade. O gráfico refere-se à classificação da iluminação da imagem. Como é possível verificar, considerando as 3 medidas, os valores mantêm-se semelhantes ao longo do aumento do raio. . . . .	71
C.10	Gráfico obtido variando o raio da fóvea. O eixo das abcissas representa os valores multiplicados pelo raio original da zona considerada e o eixo das ordenadas representa os valores de: (a) sensibilidade, (b) especificidade. O gráfico refere-se à classificação de qualidade global da imagem. Como é possível verificar, enquanto o raio aumenta, a performance piora. . . . .	72



# Lista de Tabelas

3.1	Comparação de performance entre os métodos de Giancardo <i>et al.</i> e de Niemeijer <i>et al.</i> [38]. . . . .	21
3.2	Comparação de performance entre os métodos de Hunter <i>et al.</i> , de Usher <i>et al.</i> e de Lalonde <i>et al.</i> [40]. . . . .	21
3.3	Performance do método de classificação de Welikala <i>et al.</i> consoante o classificador [42]. . . . .	22
3.4	Performance do método de classificação Paulus <i>et al.</i> [41] consoante os indicadores utilizados (Especificidade de 80%). . . . .	23
3.5	Validação do método de Zhang <i>et al.</i> ao nível do píxel. . . . .	26
4.1	Número de imagens inicial consoante as respetivas classes. . . . .	28
5.1	Número de imagens após o processamento do algoritmo de localização da fóvea e do disco ótico consoante as respetivas classes. . . . .	30
5.3	As medidas de textura utilizadas no projecto de Soh <i>et al.</i> [51] calculadas a partir da GLCM. . . . .	35
5.2	As medidas de Haralick <i>et al.</i> [33] calculadas a partir da GLCM. . . . .	36
5.4	Número de imagens por setor (D.O. significa disco ótico, Fov. fóvea, A.R área restante e total representa a imagem completa) e por classe. . . . .	38
5.5	Valores das medidas de análise dos classificadores de avaliação de qualidade global do disco ótico. . . . .	40
5.6	Valores das medidas de análise dos classificadores de avaliação de qualidade global da fóvea. . . . .	41
5.7	Valores das medidas de análise dos classificadores de avaliação de qualidade global da área restante. . . . .	41
5.8	Valores das medidas de análise dos classificadores de avaliação de qualidade global da retinografia completa. . . . .	42
5.9	Matriz de confusão proveniente da classificação global de qualidade do disco ótico após a inclusão dos descritores de textura. . . . .	43
5.10	Matriz de confusão proveniente da classificação global de qualidade da fóvea após a inclusão dos descritores de textura. . . . .	43
6.1	Parâmetros utilizados e os valores correspondentes. . . . .	49

6.2	Valores de taxa de aprendizagem testados e os respectivos valores de exatidão, utilizando o modelo de CNN apresentado na figura 6.2. . . . . .	50
6.3	Números de épocas testados e os respectivos valores de exatidão, utilizando o modelo de CNN apresentado na figura 6.2. . . . . .	51
6.4	Valores da dimensão dos conjuntos de amostras testados e os respectivos valores de exatidão, utilizando o modelo de CNN apresentado na figura 6.2. . . . . .	51
6.5	Valores de Taxa de Aprendizagem testados e os respectivos valores de exatidão, utilizando o modelo de CNN apresentado na figura 6.2. . . . . .	52
6.6	Matriz confusão relativa ao conjunto de validação. . . . . .	52
6.7	Matriz confusão relativa ao conjunto de teste. . . . . .	53
6.8	Valores das medidas resultantes da matriz confusão 6.6. . . . . .	53
6.9	Valores das medidas resultantes da matriz confusão 6.7. . . . . .	54
A.1	Desempenho do classificador de cor proposto por Dias et al. [9]. . . . . .	61
A.2	Desempenho do classificador de foco proposto por Dias et al. [9]. . . . . .	61
A.3	Desempenho do classificador de contraste proposto por Dias et al. [9]. . . . . .	61
A.4	Desempenho do classificador de iluminação proposto por Dias et al. [9]. . . . . .	62
A.5	Desempenho do classificador global de qualidade proposto por Dias et al. [9]. . . . . .	62
C.1	Valores das medidas de análise dos classificadores de avaliação da cor da região do disco ótico. O classificador retreinado proposto que garantiu melhores resultados foi o classificador de rede bayesiana. Comparando os valores desta tabela, é possível verificar que o classificador com melhor performance foi o classificador concebido por Dias <i>et al.</i> . . . . . .	72
C.2	Valores das medidas de análise dos classificadores de avaliação do foco da região do disco ótico. O classificador retreinado proposto que garantiu melhores resultados foi o classificador fino gaussiano SVM. Comparando os valores desta tabela, é possível verificar que o classificador com melhor performance foi o classificador proposto neste trabalho. . . . . .	73
C.3	Valores das medidas de análise dos classificadores de avaliação do contraste da região do disco ótico. O classificador retreinado proposto que garantiu melhores resultados foi o classificador baseado em instâncias. Comparando os valores desta tabela, é possível verificar que ambos garantem uma performance semelhante. Neste caso a escolha do classificador depende das características do projeto. . . . . .	73
C.4	Valores das medidas de análise dos classificadores de avaliação da iluminação da região do disco ótico. O classificador retreinado proposto que garantiu melhores resultados foi o classificador de rede bayesiana. Comparando os valores desta tabela, é possível verificar que o classificador com melhor performance foi o classificador concebido por Dias <i>et al.</i> . . . . . .	73

C.5	Valores das medidas de análise dos classificadores de avaliação da cor da região da fóvea. O classificador retreinado proposto que garantiu melhores resultados foi o classificador linear SVM. Comparando os valores desta tabela, é possível verificar que o classificador com melhor performance foi o classificador proposto.	74
C.6	Valores das medidas de análise dos classificadores de avaliação do foco da região da fóvea. O classificador retreinado proposto que garantiu melhores resultados foi o classificador <i>Bagged Trees</i> . Comparando os valores desta tabela, é possível verificar que o classificador com melhor performance foi o classificador proposto.	74
C.7	Valores das medidas de análise dos classificadores de avaliação do contraste da região da fóvea. O classificador retreinado proposto que garantiu melhores resultados foi o classificador de rede bayesiano. Comparando os valores desta tabela, é possível verificar que o classificador com melhor performance foi o classificador proposto.	74
C.8	Valores das medidas de análise dos classificadores de avaliação da iluminação da região da fóvea. O classificador retreinado proposto que garantiu melhores resultados foi o classificador de árvore simples. Comparando os valores desta tabela, é possível verificar que o classificador com melhor performance foi o classificador proposto.	75
C.9	Valores das medidas de análise dos classificadores de avaliação da cor da região restante. O classificador retreinado proposto que garantiu melhores resultados foi o classificador cubico SVM. Comparando os valores desta tabela, é possível verificar que o classificador com melhor performance foi o classificador Dias <i>et al.</i>	75
C.10	Valores das medidas de análise dos classificadores de avaliação do foco da região restante. O classificador retreinado proposto que garantiu melhores resultados foi o classificador fino gaussiano SVM. Comparando os valores desta tabela, é possível verificar que o classificador com melhor performance foi o classificador Dias <i>et al.</i>	75
C.11	Valores das medidas de análise dos classificadores de avaliação do contraste da região restante. O classificador retreinado proposto que garantiu melhores resultados foi o classificador perceptrão de camada múltipla. Comparando os valores desta tabela, é possível verificar que o classificador com melhor performance foi o classificador proposto.	76
C.12	Valores das medidas de análise dos classificadores de avaliação da iluminação da região restante. O classificador retreinado proposto que garantiu melhores resultados foi o classificador de perceptrão de camada múltipla. Comparando os valores desta tabela, é possível verificar que o classificador com melhor performance foi o classificador concebido por Dias <i>et al.</i>	76

C.13	Valores das medidas de análise dos classificadores de avaliação da cor da imagem completa. O classificador retreinado proposto que garantiu melhores resultados foi o classificador de regressão logística aditiva. Comparando os valores desta tabela, é possível verificar que o classificador com melhor performance foi o classificador concebido por Dias <i>et al.</i> . . . . .	77
C.14	Valores das medidas de análise dos classificadores de avaliação de foco da imagem completa. O classificador retreinado proposto que garantiu melhores resultados foi o classificador de <i>weighted KNN</i> . Comparando os valores desta tabela, é possível verificar que o classificador com melhor performance foi o classificador concebido por Dias <i>et al.</i> . . . . .	77
C.15	Valores das medidas de análise dos classificadores de avaliação do contraste da imagem completa. O classificador retreinado proposto que garantiu melhores resultados foi o classificador de perceptrão de camada múltipla. Comparando os valores desta tabela, é possível verificar que o classificador com melhor performance foi o classificador proposto. . . . .	77
C.16	Valores das medidas de análise dos classificadores de avaliação de iluminação da imagem completa. O classificador retreinado proposto que garantiu melhores resultados foi o classificador de perceptrão de camada múltipla. Comparando os valores desta tabela, é possível verificar que o classificador com melhor performance foi o classificador proposto. . . . .	78
C.17	Matriz de confusão proveniente da classificação do contraste da região do disco ótico após a inclusão dos descritores de textura. . . . .	78

# Capítulo 1

## Introdução

### 1.1 Motivação e Contextualização do Problema

Atualmente, devido ao aumento populacional e ao crescimento associado da população envelhecida, existe um incremento significativo no número de casos de indivíduos com patologias oculares. De facto, é estimado que 253 milhões de pessoas tenham algum impedimento na sua visão, sendo que 36 milhões são consideradas cegas e 217 milhões têm impedimento de visão moderado ou acentuado. Inclusive, é previsto que 38.5 milhões de pessoas estejam cegas em 2020 e 114.6 milhões em 2050 [1].

Patologias na retina são as principais causas destes problemas, sendo que erros de refração não corrigidos e cataratas têm maior preponderância. Também é relevante mencionar a importância de doenças como glaucoma, degeneração macular relacionada com a idade (DMI) e retinopatia diabética como proeminentes contributos da cegueira a nível mundial [2]. Esta última doença é provocada pela subida dos níveis de açúcar no sangue associada à diabetes e tem-se tornado numa prioridade a nível global devido ao aumento do número de casos da doença associada. Efetivamente, o número de pessoas com diabetes subiu de 108 milhões em 1980 para 422 milhões em 2014 e é esperado que se torne na sétima principal causa de morte em 2030 [3].

Na medida em que estas doenças podem vir a ser tratadas ou até prevenidas, estas são as principais prioridades de iniciativas como a VISION 2020, iniciativa global criada em 1999 pela *World Health Organization*, que visa acabar com a cegueira e outros impedimentos de visão revogáveis. Esta organização preocupa-se em criar infraestruturas para difundir informação sobre estas doenças, detetar antecipadamente a doença, diagnosticar corretamente e avaliar continuamente o paciente de forma a cumprir os seus objetivos [4]. Uma das abordagens utilizadas para detetar e monitorizar as doenças expostas em cima, de forma não invasiva, é o recurso a fotografias digitais da retina [5]. Estas imagens são posteriormente avaliadas por um oftalmologista ou optometrista.

Contudo, são precisas tomar mais medidas, visto que o acompanhamento destas pato-

logias requer bastantes profissionais desta área médica, grandes quantidades de armazenamento e vários recursos logísticos. Uma solução será facilitar a carga de trabalho destes especialistas, optando por uma resolução prática e económica em termos de custos e de tempo tal como a avaliação automatizada de imagens digitais da retina. Neste momento, existem vários sistemas disponíveis que desempenham estas funções, como por exemplo o produto Retmarker®<sup>(R)</sup>, desenvolvido pela Retmarker S.A, empresa que se foca na inovação e na área de prevenção da perda de visão. Porém, de acordo com vários estudos [6, 7, 8], cerca de 10% a 20% das retinografias tiradas nestes exames são consideradas não classificáveis, devido a fatores como a inexperiência do fotógrafo, movimento da cabeça ou dos olhos do paciente, pestanejar ou artefactos nas lentes, podendo influenciar o diagnóstico da doença e implicando a nova captura das imagens.

Uma imagem é considerada não classificável caso não sejam visíveis componentes morfológicos do olho (como o disco ótico e a zona macular que compreende a fóvea) ou se, através da análise da imagem, for difícil ou impossível de realizar o diagnóstico preciso do paciente. Para o efeito, vários estudos foram realizados de forma a classificar a qualidade das retinografias previamente à avaliação automática de patologias nas imagens. Estes contributos científicos dividem-se em três categorias: métodos dependentes da estrutura do olho, métodos baseados em parâmetros genéricos de qualidade de imagem e métodos baseados em características morfológicas e genéricas de imagem. Um trabalho foi proposto [9], que determina a qualidade de imagem baseada na fusão dos indicadores de qualidade genéricos de imagem de cor, foco, contraste e iluminação. Esta tese tem como principal fundamento este mesmo trabalho.

Nesta dissertação, alterações ao referido método foram feitas, de forma a que o algoritmo de classificação de qualidade de imagem processasse setores morfológicos do olho para além da imagem completa, com o objetivo de diminuir o número de imagens descartadas em rastreio. Este procedimento tem como fundamento o facto de que grande parte dos sintomas das doenças da retina, são encontrados próximos de certos elementos da retina, nomeadamente o disco ótico e a fóvea. Para além do desenvolvimento do algoritmo de setorização, foram feitas modificações ao algoritmo base, de forma a adaptar o mesmo aos setores em análise.

Para facilitar e melhorar o momento de aquisição de imagens do fundo do olho, foi concebido um algoritmo de aprendizagem profunda para classificar artefactos em retinografias. A rede neuronal convolucional classifica as imagens de acordo com a presença de quatro artefactos. Para o efeito, foi estudada a composição da arquitetura da rede e os valores dos parâmetros a utilizar, de forma a conseguir a combinação que forneça os melhores resultados em termos de precisão e tempo computacional. O conteúdo desta tese foi desenvolvido em conjunto com a Retmarker S.A.

## 1.2 Visão geral do Documento

Este documento é constituído por sete capítulos. O conteúdo de cada um é o seguinte:

- No Capítulo 1, a motivação e os principais objetivos bem como o delineamento do documento são estabelecidos;
- No Capítulo 2, são explorados conceitos sobre a anatomia do olho e as suas patologias mais comuns;
- No Capítulo 3, são enumerados os principais fatores que comprometem a qualidade de imagens da retina e são apresentadas revisões dos estudos publicados sobre avaliação de qualidade de imagens retinianas e sobre a classificação e deteção de artefactos em retinografias;
- No Capítulo 4, é exposta uma listagem de materiais utilizados no desenvolvimento desta dissertação;
- No Capítulo 5, o método de avaliação de qualidade de imagens da retina por setores do olho proposto é descrito e os seus resultados são discutidos;
- No Capítulo 6, o algoritmo de classificação de artefactos é relatado e os seus resultados são analisados;
- No Capítulo 7, são feitas conclusões finais e são referidas sugestões para trabalho futuro.



## Capítulo 2

# Anatomia Ocular e Patologias Oftalmológicas

### 2.1 Anatomia Ocular

O olho humano é constituído por três camadas concêntricas: a camada externa, a camada média e a camada interna. A camada externa é composta pela esclerótica, estrutura que é formada por tecido conjuntivo protegendo os conteúdos intraoculares e que preserva a forma do globo ocular, e pela córnea, disco convexo responsável pela refração da luz que entra no olho. A camada média ou úvea é formada por uma estrutura contínua que compreende a íris, a coróide e o corpo ciliar. A coróide consiste numa camada fina e castanha extremamente vascular que nutre as camadas exteriores da retina, enquanto o corpo ciliar é onde se dá a produção controlada de líquido humor aquoso. A íris contém uma abertura circular (pupila), e a sua dilatação e contração permite o controlo da quantidade de luz que entra no olho. A camada interna, ou retina, é a membrana que se encontra mais no interior do globo ocular e onde é formada a imagem ótica [10, 12]. Esta membrana sensorial trata-se do componente ocular mais relevante para este trabalho.

A retina é constituída por dois tipos de fotorreceptores: os cones e os bastonetes, responsáveis por receberem os raios luminosos que atingem a retina e convertê-los em impulsos nervosos, impulsos estes que permitem a criação de sensações visuais pelo cérebro. Estas células têm finalidades diferentes: os bastonetes estão encarregues de detetar movimento, de permitir a visão em ambientes com pouca luz e produzir imagens a preto e branco, enquanto os cones estão incumbidos da visão central, visão a cores e estão melhor adaptados à luz clara. A densidade destes neurónios também varia consoante a sua localização, influenciando a qualidade da visão e duas dessas regiões são a mácula e o disco ótico [10, 12].

Tanto a mácula como o disco ótico são marcos óticos de extrema importância. A mácula encontra-se no centro da zona posterior da retina. Contem uma concavidade no seu centro denominada por *fovea centralis* que nela se localiza a maior concentração de neurónios cone no olho, não existindo neurónios bastonetes nem vasos sanguíneos subjacentes. Devido à

sua composição, à localização privilegiada e ao seu desnível, a fóvea permite que a luz que entra no olho tenha maior acesso a um número maior de fotorreceptores que noutra região da retina, tornando a mácula responsável pela nitidez da imagem criada [10, 12].

No disco ótico os vasos centrais entram e saem da retina, sendo que o nervo ótico responsável por conduzir os impulsos nervosos até ao cérebro sai desta região. É geralmente de cor branca, ou bastante mais pálido que a zona à sua volta e não existem células cones ou bastonetes nesta região, sendo assim insensível à luminosidade e referido como ponto cego. De notar que tanto a mácula como o disco ótico são zonas muito sensíveis que, contendo alguma invulgaridade, podem comprometer ou até impossibilitar a visão do paciente [10, 12]. Por conseguinte, ambas as regiões são de grande relevância para este trabalho.

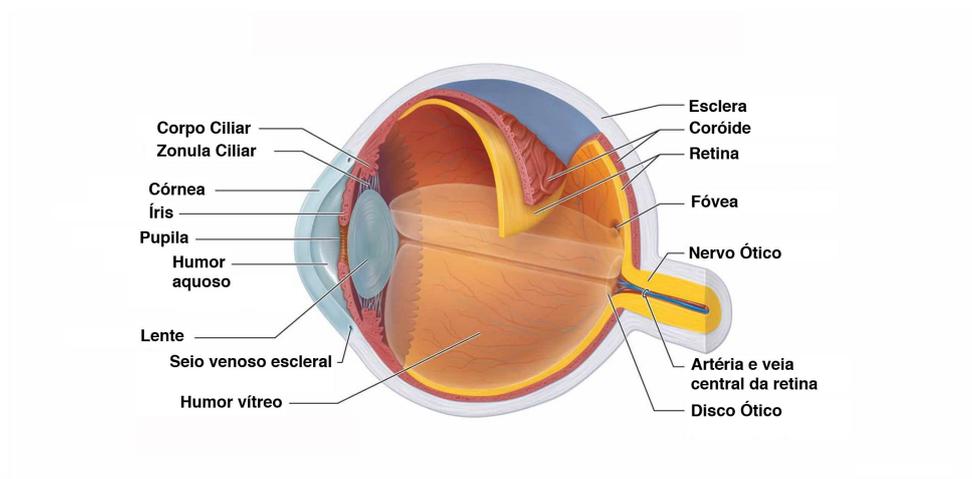


Figura 2.1: Anatomia do Olho, adaptado de [11].

## 2.2 Patologias Oftalmológicas

O olho é o órgão humano responsável pela percepção e interpretação do espaço envolvente e, dado à sua fragilidade, é facilmente alvo de várias doenças. Algumas das mais frequentes são [2, 13, 14]:

- **Astigmatismo:** Esta doença provoca visão desfocada devido a uma alteração na curvatura da córnea, podendo ter sido causada por algum trauma ocular ou ter origem genética. Pode ser corrigida através do uso de óculos, lentes ou através de cirurgia refrativa.
- **Estrabismo:** Estrabismo causa o desalinhamento do olho, estando relacionado com a eficácia da contração dos músculos óticos. É de origem genética e requer acompanhamento da pessoa, podendo ser tratada através do uso de óculos ou efetuando cirurgia.

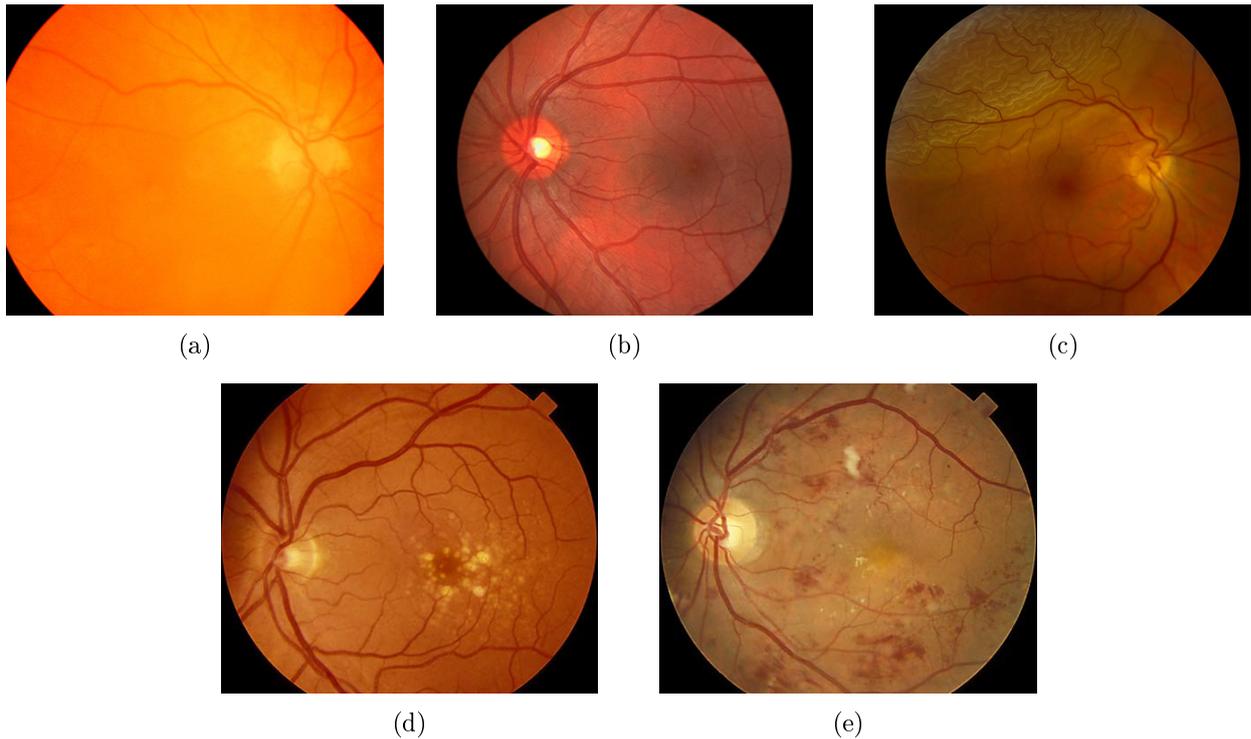


Figura 2.2: Retinografias com indícios de: (a) Catarata [18], (b) Glaucoma [19], (c) Deslocamento da Retina [20], (d) Degeneração Macular relacionada com a Idade e (e) Retinopatia Diabética não Proliferativa [21].

- **Miopia:** Doença que afeta a visão, nomeadamente a qualidade da visão ao longe. Deve-se ao facto de o globo ocular ser maior que o habitual, provocando a focagem da imagem à frente da retina. Pode ser de origem hereditária, trauma ocular ou surgir devido ao uso excessivo da visão ao perto. É corrigida através do uso de óculos, lentes ou cirurgia.
- **Hipermetropia:** Patologia que perturba a visão, mais especificamente a visão ao perto. Esta é provocada pelo tamanho menor que o normal do globo ocular, sendo que a imagem é projetada atrás da retina. Normalmente tem origem genética, sendo mais comum nas crianças. É facilmente retificada através do uso de óculos, lentes ou cirurgia.
- **Conjuntivite:** Doença de origem viral, bacteriana ou alérgica, provocando a inflamação da conjuntiva, membrana que reveste a parte interna da pálpebra. Caso seja de estipe viral ou bacteriana é contagiosa sendo necessário ter cuidados redobrados. O tratamento varia consoante a severidade, podendo passar normalmente ou através do recurso a antibióticos.
- **Catarata:** Esta doença causa diminuição da visão devido à opacidade parcial ou total do cristalino, lente transparente do globo ocular, que ao longo do tempo se vai tornando mais baça, dificultando o acesso da luz. É causada normalmente devido ao

envelhecimento, mas pode estar associada a outras doenças ou causas. Pode ser tratada através de cirurgia onde o cristalino é substituído (ver Fig.2.2.a).

- **Glaucoma:** Esta patologia é uma das principais causas de cegueira a nível mundial, sendo fulcral o seu diagnóstico prematuro para ser prevenida. É originada pela acumulação de fluidos intraoculares com o conseqüente aumento de pressão sobre as células responsáveis pela visão. Normalmente associada à miopia, hipertensão arterial ou diabetes, podendo ter influência genética. Pode vir a ser tratada através de cirurgia ou da aplicação de substâncias que permitam controlar a pressão intraocular (ver Fig.2.2.b).
- **Deslocamento da Retina:** Como o nome sugere, aparece quando se dá a desagregação da retina da sua conexão, causando visão turva e manchas no campo de visão. Se esta doença não for tratada de imediato, pode causar cegueira. Advém de trauma ocular, infecção, doença ou associada ao envelhecimento e é solucionada através de cirurgia (ver Fig.2.2.c).
- **Degeneração Macular relacionada com a Idade (DMI):** Doença degenerativa que afeta a zona central da retina, mais propriamente a zona da mácula, prejudicando a visão central do paciente. Como o nome indica, esta doença está associada ao envelhecimento, correspondendo à principal causa de impedimento de visão em pessoas com idade superior a 55 anos. Caso não seja diagnosticada e tratada atempadamente pode causar cegueira, sendo que os danos originados pela mesma geralmente são irreversíveis. Habitualmente associada à velhice, pode ter origens genéticas e o seu aparecimento é influenciado pelo consumo de tabaco. Consoante a severidade, pode tomar três formas [15] (ver Fig.2.2.d):
  - DMI precoce: também conhecida como Maculopatia da Idade, normalmente sem sintomas aparentes, caracterizada pela existência de drusas, depósitos de algumas substâncias (lipofuscina), de cor branca ou amarela, que surgem debaixo da retina. A existência das mesmas não impede a visão, mas danifica a mácula, podendo degradar os fotorreceptores aí presentes. Como a DMI precoce é assintomática, é imperativo que pessoas com mais de 50 anos façam exames médicos regularmente.
  - DMI seca: devido à danificação da mácula ao longo do tempo, a visão também vai piorando gradualmente, sendo que cerca dos 80-90% dos pacientes com DMI possuem esta estirpe. A DMI seca evolui muito lentamente e devido aos seus sintomas muitas vezes é diagnosticada incorretamente. Esta estirpe pode evoluir para a forma exsudativa caso o paciente não seja monitorizado. Tanto a forma seca e a forma precoce são tratadas através de uma alimentação cuidada, com possível recurso a suplementos alimentares, e uso de óculos adequados.
  - DMI Exsudativa: resulta do desenvolvimento de neovasos anómalos sob a mácula. Estes vasos ao sangrarem exsudam na mácula e causam danos com possível perda

de visão central. Esta perda pode ser muito rápida e podem causar vários sintomas desde alteração da percepção das cores, a aparecimento de manchas no campo visual. Nesta fase, certos danos são irreversíveis. Devido à gravidade da forma exsudativa, é recomendado o tratamento imediato que passa por cirurgia laser e outros métodos terapêuticos.

- **Retinopatia Diabética:** como o nome indica, trata-se de uma manifestação da doença diabetes *mellitus*, tornando esta doença numa das principais causas de cegueira em países desenvolvidos. O seu aparecimento deve-se principalmente ao elevado nível de glicémia no sangue que provoca o vazamento dos vasos na retina perturbando a visão, ou, numa fase mais avançada, provoca neovascularização na retina e conseqüentemente perda de células fotorreceptoras. Existem quatro fases consoante a progressão da doença [16]:

- Retinopatia não proliferativa leve: nesta fase é possível verificar os primeiros sinais da doença, tais como microaneurismas (inchaço dos vasos sanguíneos), pequenas hemorragias e exsudatos duros (resíduos de lípidos de capilares danificados) na retina.
- Retinopatia não proliferativa moderada: Devido ao progresso da doença, os vasos sanguíneos deixam de ter capacidade de nutrir a retina provocando o inchaço e a distorção dos vasos. Estas manifestações podem contribuir para o aparecimento de edemas maculares caso existam fugas de fluído na mácula, causando a dilatação e conseqüente degradação da mácula. Apesar do aparecimento destes edemas ser mais comum em fases mais avançadas da doença, também pode aparecer nos estados iniciais.
- Retinopatia não proliferativa severa: Ao longo do tempo, regiões da retina vão ficando sem fornecimento de sangue devido ao aumento dos bloqueios nos vasos sanguíneos. Perante esta ocorrência, as áreas subnutridas sinalizam a retina de forma a que esta desenvolva novos vasos (ver Fig.2.2.e).
- Retinopatia diabética proliferativa: O continuado crescimento anormal de vasos sanguíneos na superfície da retina em direção ao vítreo agrava a condição do paciente, pois estes novos vasos rompem com muita facilidade, podendo atingir a cavidade vítrea, causando perda de visão ou até mesmo cegueira. Juntamente com a neovascularização, dá-se o crescimento de tecido cicatricial que possibilita o deslocamento da retina e conseqüente perda permanente de visão.

Infelizmente, os danos causados por esta doença são irreversíveis. No entanto, o seu diagnóstico e tratamento atempado pode reduzir o risco de cegueira. Desta forma, é fulcral a monitorização continuada dos pacientes e que estes tomem as precauções devidas. Caso a doença atinja uma fase mais grave, é possível controlar a neovascularização através de cirurgia ou outros tratamentos.

Graças à facilidade da visualização da vascularização da retina, é possível detetar não só a diabetes, como também outras doenças em que ocorram alterações nos vasos sanguíneos. Doenças cardiovasculares, cerebrovasculares ou risco de hipertensão são facilmente detetadas através do recurso a exames da retina [17]. Esta característica privilegiada do olho (que permite ser visto de forma não invasiva) facilita em grande parte o trabalho dos profissionais de saúde.

## Capítulo 3

# Avaliação de Retinografias

O uso de imagens da retina, veio possibilitar a documentação do estado da retina e a criação do registo histórico de saúde ocular de um paciente. Os dois tipos de imagens do fundo do olho mais frequentemente utilizadas são: imagens do fundo do olho e tomografias de coerência ótica [25].

A técnica que produz tomografias de coerência ótica (ou OCT) consiste num exame suplementar de diagnóstico semelhante à ecografia, mas no lugar da utilização de ondas acústicas, é usado um feixe de luz sobre as estruturas oculares, que fornece imagens do corte transversal da retina e de outras estruturas intraoculares. As imagens do fundo do olho ou retinografias são obtidas através de várias técnicas, sendo que são consideradas retinografias todas as representações 2D resultantes de luz refletida, da estrutura 3D da retina [26]. Devido à simplicidade das técnicas de obtenção de retinografias, estas imagens acabam por ser as mais populares e mais utilizadas em diagnóstico, particularmente a modalidade digital, pois agiliza o processo de obtenção das fotografias e facilita o seu armazenamento.

As fotografias digitais são normalmente classificadas manualmente por técnicos especializados ou médicos oftalmologistas. Estes regem-se por um conjunto generalizado de regras de avaliação, como o protocolo criado pelo programa *National Health and Nutrition Examination Survey* (NHANES), da autoria da *National Center for Health Statistics* (NCHS), que visa avaliar a saúde e estado nutricional dos adultos e crianças nos Estados Unidos da América. O protocolo de classificação de imagens digitais da retina permite auxiliar na avaliação da presença e severidade das doenças presentes no olho, sendo que os avaliadores das fotografias usam as seguintes convenções [26]:

- **Nenhuma:** usada na ausência de lesão ou caso existam menos de 50% de certezas que uma lesão esteja presente.
- **Questionável:** usada para indicar a possibilidade de existência de lesões. Usada em duas situações, caso o avaliador tenha mais de 50% e menos de 90% de certezas que uma lesão está presente, ou se o avaliador acha que existe uma lesão, mas não tem certeza se outros avaliadores concordariam com a análise.

- **Definitivamente:** indica presença de uma lesão, i.e. o avaliador tem 90% de certeza que uma lesão está presente.
- **Não classificável:** usada para indicar que a lesão é não classificável devido à qualidade de imagem, i.e. se não houver evidência que existe uma lesão e mais de 50% da região a analisar está ausente ou ocultada.

## 3.1 Qualidade de Retinografias

A aquisição de retinografias é um processo especializado com várias etapas, sendo que em qualquer uma delas pode ocorrer um incidente que compromete a qualidade da fotografia. Desta forma, a qualidade das imagens está dependente não só do técnico responsável por produzir estas fotos, mas também da condição da câmara e da cooperação do paciente [27]. Consequentemente, como é feita a avaliação das imagens de acordo com a presença de patologias, também é necessário avaliá-las de acordo com a sua qualidade. Excepcionalmente, surgem irregularidades nas fotografias estando relacionadas com o procedimento da criação da fotografia e não com o objeto a ser fotografado [26, 28]. Estas irregularidades que afetam a qualidade das retinografias podem ser classificadas como fatores genéricos ou fatores morfológicos.



Figura 3.1: Retinografia com boa qualidade [23].

### 3.1.1 Fatores Genéricos

Fatores genéricos afetam a qualidade de imagem de forma arbitrária, não afetando nenhum local característico. Normalmente a irregularidade é encontrada repetidamente nas imagens do mesmo momento de captura. As mais comuns são:

- **Foco:** Relativo à nitidez da imagem, é fundamental na detecção de alterações na vascularização da retina e de danos na zona da mácula. Uma imagem é considerada focada se os vasos estiverem bem definidos tal como pequenas lesões na retina. Se apenas grandes lesões forem detetáveis, se a qualidade da focagem dificultar a avaliação das lesões, ou se a desfocagem apenas afetar porções da imagem, o foco é considerado

limitativo. Se existir um declínio evidente na definição dos constituintes da retina ou se não for possível diferenciar lesões maiores, a imagem é considerada desfocada (ver Fig.3.2.a).

- **Névoa:** Este efeito pode ter duas variantes: névoa total ou parcial. O efeito névoa total é caracterizado pelo decréscimo global da nitidez, produzindo uma imagem mais baça e mais amarelada que o habitual. O efeito névoa parcial surge nos limites da retinografia, habitualmente de cor branca e de opacidade mais elevada na periferia da fotografia, tornando-se mais translúcido em direção ao centro da imagem (ver Fig.3.2.b).
- **Pó:** Manchas de pó na lente são normalmente definidas por zonas circulares desfocadas de limites pouco pronunciados, pois como se encontram na lente da câmara, estão num plano de foco diferente da retina. Manchas maiores e mais irregulares podem ser resultantes do óleo de dedadas.
- **Pestanas:** Provoca um efeito branco ou amarelado e é amplificado desde o limite do campo até ao centro da fotografia. Tal como o pó, estes artefactos estão noutra plano de foco que a retina e normalmente surgem no fundo da imagem.
- **Arcos:** Provocado pelo incorreto posicionamento do paciente, é caracterizado pelo aparecimento de um arco na imagem, habitualmente no setor nasal ou na margem temporal. Pode ser de várias cores, como azul ou amarelo e pode ter vários tamanhos diferentes. (ver Fig.3.2.c).
- **Canal Vermelho:** Ocorre quando o canal vermelho da fotografia RGB é saturado ou insípido, provocado por um efeito de superexposição. Caracterizado pela cor mais vermelha ou clara da retina.
- **Pestanejar:** O paciente pestaneja criando um artefacto branco/amarelado brilhante que oculta a retina, podendo também ter uma forma assimétrica por causa das pestanas. Caso este artefacto ocorra, a imagem é não classificável (ver Fig.3.2.d).

### 3.1.2 Fatores Morfológicos

Fatores morfológicos afetam a qualidade em locais característicos da imagem, afetando o visionamento de certos marcos oculares. As irregularidades mais comuns são:

- **Definição de campo:** Relacionado com o correto posicionamento do disco ótico e da mácula quando a fotografia é tirada. Idealmente a mácula tem de estar presente na fotografia e o disco ótico deve estar entre o equivalente a três meios do diâmetro do disco ótico (DDO) e cinco meios DDO. Existem duas configurações do campo de visão (FOV) aceitáveis: a configuração campo 1 é centrada no nervo ótico e a configuração campo 2 é centrada na mácula. A definição de campo é afetada se o disco ótico estiver afastado mais que um DDO do setor nasal e se a mácula estiver ocultada (ver Fig.3.2.e).

- **Disco ocultado ou ausente:** Como o nome indica, ocorre quando qualquer fração do disco é ocultado por um artefacto, como uma sombra ou por causa de um pestanejo, ou se encontra ausente devido à definição de campo inadequada.
- **Mácula ocultada ou ausente:** Quando a mácula está ocultada, normalmente em consequência de uma sombra gerada pela pouca dilatação da pupila, ou ausente devido à fraca definição de campo. Para a mácula ser considerada ocultada, a região sombreada deve ser maior que uma área discal (1 AD) e, em casos de iluminação irregular, completamente obscurecida (ver Fig.3.2.f).
- **Iluminação:** Este parâmetro é avaliado consoante o aparecimento de sombras que prejudiquem a visibilidade de parte da retina. Geralmente este artefacto é classificado por regiões, sendo examinadas independentemente as zonas da mácula, do disco ótico e das extremidades da retinografia (ver Fig.3.2.f).

Devido à importância da qualidade das fotografias no diagnóstico de patologias oculares, este tema tem sido objeto de estudo intensivo. Desta forma, o estado-da-arte em avaliação da qualidade de imagens retinianas é descrito na próxima secção.

## 3.2 Métodos de Avaliação de Qualidade em Retinografias

As retinografias de olhos saudáveis contêm várias marcas morfológicas exclusivas da retina que exigem diferentes métodos de processamento de imagem. As retinografias que estão assinaladas com presença de patologia tornam-se ainda mais interessantes devido ao número distinto de padrões e propriedades que podem vir a ser partilhadas por várias doenças. Deste modo, é indispensável que as imagens tenham qualidade suficiente para não interferir com o diagnóstico.

De facto, devido ao crescente uso de imagens digitais, diversos estudos foram desenvolvidos com o efeito de encontrar melhores soluções para manter, controlar, melhorar e classificar automaticamente a qualidade destas imagens. A secção seguinte irá abordar os desenvolvimentos científicos efetuados na área da avaliação de qualidade de retinografias.

Os vários métodos científicos desenvolvidos para avaliar a qualidade de imagens do fundo do olho geralmente são categorizados consoante os princípios em que são baseados. Por conseguinte, são consideradas as seguintes categorias:

- **Métodos baseados em características genéricas de imagem:** estes métodos não exigem segmentação do olho, apenas consideram as propriedades intrínsecas da fotografia, tal como a iluminação e o contraste;
- **Métodos baseados em características morfológicas:** têm em consideração a anatomia do olho na qualificação da imagem e normalmente recorrem a algoritmos de segmentação do olho ou outro tipo de algoritmo de reconhecimento;

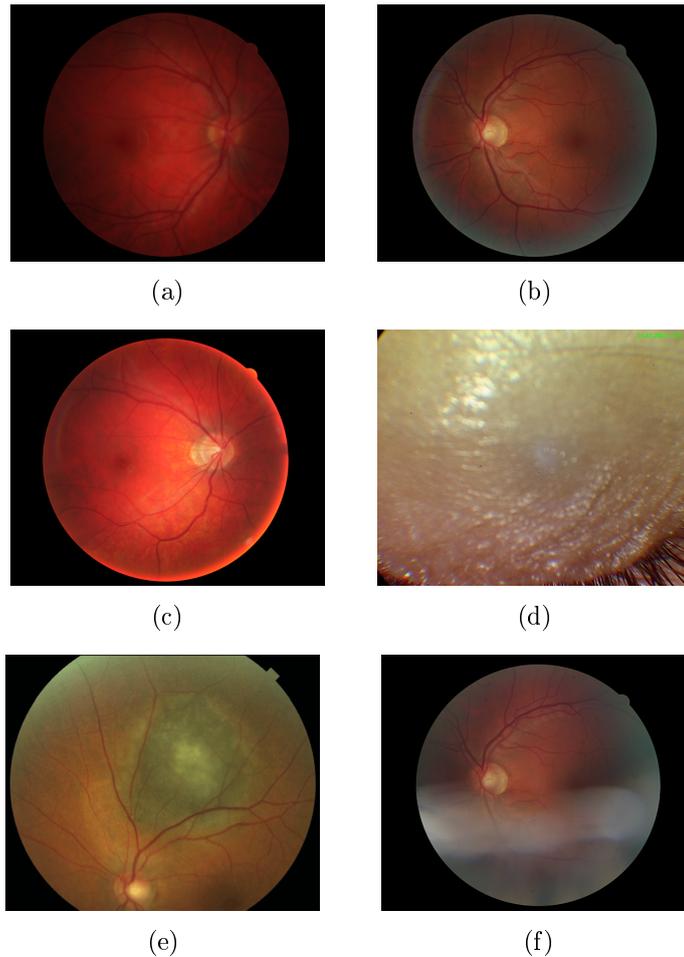


Figura 3.2: Exemplos de irregularidades na imagem: (a) desfocagem [22], (b) presença de névoa [22], (c) presença de arco [22], (d) pestanejar [23], (e) definição de campo incorreta [24] e (f) iluminação irregular [22].

- **Métodos baseados em características morfológicas e genéricas de imagem:** avaliam a imagem considerando uma combinação de ambos os métodos referidos acima.

### 3.2.1 Métodos baseados em características genéricas de imagem

O primeiro artigo científico a abordar a avaliação de qualidade de imagens retinianas foi apresentado por Lee *et al.* [29] em 1999. Os autores calcularam um histograma de intensidade genérico utilizando um conjunto de retinografias de boa qualidade e fizeram a convolução deste com o histograma de intensidade da imagem em estudo. Esta convolução resultou num índice de qualidade  $Q$  que toma valores entre 0 e 1 (se  $Q$  for igual a 0 significa que a imagem é não classificável). Esta abordagem baseada num histograma permite obter informação de forma a estimar o contraste, brilho e a relação sinal-ruído da fotografia.

Em 2011, Lalonde *et al.* [30] seguiu uma abordagem de histograma um pouco diferente que veio a refutar o estudo de Lee *et al.*.

Estes autores desenvolveram dois critérios para determinar a qualidade de uma imagem.

O primeiro critério,  $d_{edge}$ , representa uma medida que relaciona a distribuição da magnitude das bordas da imagem com um modelo derivado de um conjunto de imagens com boa qualidade. Foi observado que a distribuição da magnitude dos bordas de uma imagem com boa qualidade é semelhante a uma distribuição Reyleigh, adquirindo um declive mais suave à medida que a intensidade cresce, enquanto que numa imagem com má qualidade a distribuição diminui abruptamente, como é possível verificar na Fig. 3.3.

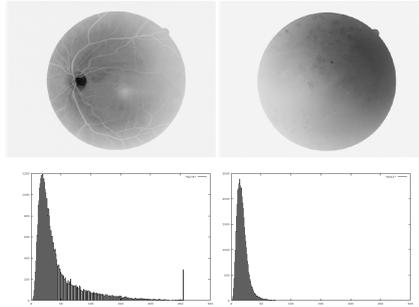


Figura 3.3: Figura à esquerda corresponde numa retinografia com boa qualidade e a da direita numa com má qualidade. Em baixo encontram-se as respetivas distribuições da magnitude das bordas de acordo com as evidências de Lalonde *et al.* [30]. As imagens cinzentas estão com as cores invertidas para uma melhor visualização.

Foi definido um segundo critério,  $d_{intensity}$ , numa tentativa de analisar a iluminação irregular numa imagem. Este critério foi adotado a partir da abordagem de Lee *et al.*, em que foi definido um histograma de intensidade genérico a partir de um conjunto de imagens com boa qualidade e foi efetuada uma análise por região da imagem.

Lalonde *et al.* utilizando estes dois critérios  $d_{edge}$  e  $d_{intensity}$ , criou um quadro de decisão contendo três classes que permitem definir a qualidade de uma retinografia: “Boa”, “Razoável” e “Má”, como é possível de verificar através da Fig. 3.4.

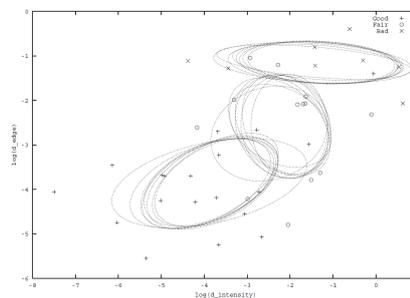


Figura 3.4: Gráfico de dispersão demonstrando a separabilidade das classes "Boa" (*Good*), "Má" (*Bad*) e "Razoável" (*Fair*), de acordo com as evidências de Lalonde *et al.* [30].

Como é possível de observar, este método obteve bons resultados, mediante as poucas imagens que utilizaram, sendo imperativo que um teste com mais imagens seja feito para este método ser validado.

Tanto a abordagem de Lee *et al.* como a de Lalonde *et al.* foram testadas com poucas imagens e os resultados obtidos resultam de propriedades de histogramas. Por conseguinte, estes métodos dificilmente conseguem interpretar *datasets* contendo imagens demasiado distintas entre si, algo que não é desejado quando são analisadas retinografias.

Mais tarde, em 2009, Bartling *et al.* [31] apresentou um novo método baseado em medidas de iluminação e nitidez para qualificar numericamente retinografias. Este procedimento aceita qualquer tipo de campo de visão da retina e não requer a presença do disco ótico nem da mácula na imagem. Após a divisão em quadrados mais pequenos da imagem a testar, a estrutura destes quadrados era avaliada através de um operador Laplaciano seguido do cálculo do desvio padrão da imagem, resultando numa medida de conteúdo estrutural. Aos quadrados com conteúdo estrutural suficiente, era lhes aplicada uma transformada de onda discreta de duas dimensões. Ao serem analisados em termos das suas magnitudes de alta frequência, a nitidez era avaliada, visto que magnitudes de alta frequência resultam numa melhor nitidez.

A análise da iluminação foi calculada a partir de dois parâmetros, o brilho e o contraste. Foram criadas duas funções de ponderação para cada um destes parâmetros, tendo em consideração a abordagem de Lalonde *et al.* para calcular a distribuição de intensidade das imagens. O brilho é calculado através da respetiva função de ponderação e do valor da intensidade média de cada quadrado da imagem, enquanto que o contraste utiliza o valor do desvio padrão de cada quadrado e a sua função de ponderação. O valor global da iluminação resulta na soma destes dois parâmetros.

Posteriormente ao cálculo das medidas de iluminação e nitidez, as imagens são classificadas mediante quatro classes distintas de qualidade: “Muito Boa”, “Boa”, “Aceitável” e “Não Aceitável”. Utilizando uma abordagem de valor de kappa [32], os autores conseguiram igualar os resultados que obtiveram aos valores obtidos por observadores humanos qualificados, sendo que obtiveram um kappa médio de 0.64 num intervalo de 0.52 a 0.68. Apesar dos resultados não terem sido excecionais, foi possível provar que a avaliação automática de qualidade de retinografias é exequível e equiparável a avaliações feitas por profissionais.

No mesmo ano, Davis *et al.* [8] criou uma nova forma de avaliar a qualidade de imagens da retina recorrendo ao cálculo de 17 descritores para cada canal CIELab e para cada um dos sete setores da retinografia representados na Fig 3.5. O modelo de cor CIELab relaciona adequadamente as cores com a perceção visual humana.

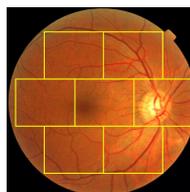


Figura 3.5: Regiões de processamento delimitadas por uma grelha, de acordo com Davis *et al.* [8].

Davis et al. pretendia analisar a cor, a luminância e o contraste de cada imagem para alcançar um valor de qualidade global. Deste modo, para medir a cor de cada setor, foi calculada a média, o 1<sup>o</sup> e 3<sup>o</sup> quartis para cada canal de cor CIELab. Para quantificar a luminância foi calculada a intensidade média, a assimetria e a curtose (medida que retrata a comparação entre o pico de um histograma e uma distribuição normal). Em relação ao contraste, foi calculada a variância da intensidade, o contraste genérico baseado em matrizes de coocorrência dos descritores de Haralick [33], entropia dos descritores de Haralick e a frequência espacial. Foi constatado que, caso não fosse descartado nenhum dos descritores, o seu cálculo demorava menos de um segundo num computador normal e, num conjunto de 200 imagens, eram obtidos 100% de sensibilidade e 96% de especificidade na identificação de imagens não classificáveis.

Em 2014, Dias *et al.* [9] propôs um método baseado na fusão de quatro indicadores genéricos de qualidade: cor, foco, contraste e iluminação da imagem que derivou ótimos resultados. Este algoritmo calcula medidas representativas de cada indicador, e fundindo-as origina uma classificação final que determina se uma imagem é classificável ou não classificável. Por conseguinte, foi obtida uma sensibilidade de 99.07%, especificidade de 97.95% e exatidão de 98.03%. Devido a esta dissertação ter como base este método, no apêndice A este trabalho é descrito aprofundadamente e não vai ser desenvolvido na secção presente.

Um algoritmo inovador foi proposto por Mahapatra [44] em 2016 que recorria ao uso de aprendizagem supervisionada e não supervisionada para qualificar a qualidade de retinografias.

Numa primeira fase, é obtido o mapa de saliências local da imagem, calculando o valor de saliência de cada pixel. Como a avaliação de qualidade de imagem deve incorporar indicadores locais e globais, são considerados diferentes tamanhos de vizinhança do pixel alvo. Em seguida, as imagens são convertidas em tons de cinza e são obtidos os mapas de curvatura e de textura. Os mapas de saliência são gerados a partir destes 3 mapas de descritores. Finalmente é calculada uma função ponderada a partir destes valores de forma a avaliar a singularidade do pixel em relação à sua vizinhança. Na medida em que são utilizadas 5 escalas diferentes, são originados 15 mapas. Cada mapa é dividido em blocos 64x64 totalizando em 64 blocos por imagem. Desta forma, no total haverão 960 descritores.

A segunda fase é dedicada à conceção da arquitetura e ao treino da rede neuronal convolucional (CNN). A rede sugerida possui 5 camadas de convolução e processos de discretização (*maxpooling*). Depois das 5 camadas convolucionais, existem 3 camadas totalmente conectadas, seguidas de uma camada softmax que classifica as imagens como classificáveis ou não classificáveis.

O conjunto de descritores que resulta dos mapas de saliência e o vetor de 1000 dimensões que advém da última camada totalmente conectada são utilizados para treinar dois classificadores aleatórios de floresta (*Random Forest*) diferentes. O resultado final consiste na média de ambos os valores relativos a cada classificador.

Os resultados foram obtidos recorrendo a 9653 imagens marcadas como não classificáveis

e 11347 imagens marcadas como classificáveis. Estas imagens têm uma FOV de 45° e como não foram consideradas suficientes para treinar a rede, sofreram modificações sintéticas de forma a aumentar 50 vezes o conjunto disponível para treino. Foi obtida uma sensibilidade de 98.2%, uma especificidade de 97.8% e uma exatidão de 94.7%. O tempo médio de classificação de uma imagem é de 8.2 segundos, utilizando um algoritmo não-otimizado e uma máquina com um CPU Intel® Core™ 2.3GHz i5 com 8 GB de RAM.

Este método veio a introduzir o uso de redes neuronais convolucionais na quantificação de qualidade de retinografias. Os autores admitem que tiveram ótimos resultados devido ao tamanho do seu conjunto de treino e da fusão de métodos de aprendizagem não supervisionada e supervisionada.

Os avanços científicos efetuados neste tipo de métodos, revelam resultados muito precisos e são relativamente “leves” a nível computacional, podendo ser aplicados em plataformas com diferentes níveis de processamento. Como se tratam de procedimentos não dependentes de componentes morfológicos, podem ser utilizados noutras áreas médicas ou até fora do âmbito medicinal.

### 3.2.2 Métodos baseados em características morfológicas

O primeiro método de avaliação de qualidade de retinografias baseado em características morfológicas foi concebido por Usher *et al.* [34] em 2003. Os autores basearam-se no facto de que uma retinografia para possuir boa qualidade tem de ter uma vascularização visível e detetável. Deste modo, consideraram um valor limite de qualidade para agrupar as imagens em duas classes (classificáveis e não classificáveis).

Foram utilizadas 1746 imagens de teste e, na identificação de pacientes com pelo menos uma imagem não classificável, foi obtida uma sensibilidade de 84.3% e uma especificidade de 95%. Estes resultados poderiam ser melhores, pois alguns vasos mais finos não são detetados e se existirem bastantes vasos espessos, estes podem aumentar o erro produzido pelo algoritmo.

Em 2005, Lowell *et al.* [35] publicou um novo método de avaliação de qualidade de retinografias baseando-se no trabalho de Usher *et al.*[34]. O algoritmo analisava os vasos sanguíneos de uma zona circular rodeando a mácula e qualificava a imagem de acordo com a deteção efetuada.

Apesar de terem sido obtidos bons resultados, este método está altamente dependente da qualidade das imagens de teste, pois necessita que a mácula e os vasos sejam segmentados.

Um ano depois, Niemeijer *et al.* [36] apresentou um método constituído por três etapas.

Na primeira etapa denominada por “Aglomerado de Estruturas da Imagem” (ISC - *Image Structure Clustering*), são agrupados conjuntos de pixéis usando uma variedade de filtros passa banda de forma a analisar elementos presentes nas imagens. Cada um destes conjuntos de pixéis representa um outro conjunto idêntico numa imagem diferente, podendo associar a estruturas típicas do olho e reunir informação sobre as diferentes especificações possíveis

destas estruturas.

Na segunda etapa ocorreu o cálculo do histograma dos descritores de imagem resultante dos grupos de pixels obtidos anteriormente. Finalmente, na terceira etapa os autores aplicaram um procedimento de seleção flutuante sequencial dianteiro (SFFS) para efetuar a seleção de descritores. Em seguida as imagens foram classificadas utilizando esta triagem.

O classificador que garantiu os melhores resultados foi o classificador SVM (Support Vector Machine). Após vários testes com 1000 imagens (500 com boa qualidade e 500 com má qualidade), foi obtida uma área ROC (Receiver Operating Characteristic) de 0.9968.

Em conclusão, este procedimento garante bons resultados sem ser necessário uma segmentação do olho muito precisa. Contudo, foi reportado que cada imagem de teste demorava 30 segundos a ser processada, sendo uma grande desvantagem na aplicação desta abordagem em sistemas de tempo real.

No mesmo ano de 2006, Fleming *et al.* [6] criou um novo método dependente da vascularização do olho. Na primeira fase é efetuada a avaliação da claridade da imagem. Nesta fase, a fóvea é detetada e é definida uma região circular à sua volta em que os vasos abrangidos são analisados utilizando a transformada de Hough [37].

A segunda fase proporciona a avaliação da definição de campo. Os autores definiram um conjunto de medidas que avaliavam este parâmetro, como o diâmetro do disco ótico, a distância entre a fóvea e o disco, o comprimento dos vasos de arcada e o alinhamento vertical da imagem.

Utilizando estas duas avaliações num teste com 1039 imagens, Fleming *et al.* obteve 99.1% de sensibilidade e 89.4% de especificidade na deteção de imagens não classificáveis. Como este método é dependente da vascularização e da definição de campo, é impraticável em imagens com muita má qualidade.

Baseando-se no trabalho de Niemeijer *et al.*, Giancardo *et al.* [38] apresentou um novo trabalho em 2008 independente do campo de visão das retinografias. Este método começa por calcular a máscara da imagem em estudo e procede com a segmentação da vascularização do olho [39].

Na etapa seguinte são adquiridos os descritores da imagem. Uma elipse é encaixada a um conjunto de pontos na máscara e posteriormente são obtidas as densidades dos vasos locais utilizando janelas polares referentes à elipse determinada previamente. A este conjunto de descritores são adicionados mais cinco, relativos à normalização e variação unitária do histograma de cada canal de cor RGB.

Utilizando um conjunto de 84 imagens centradas na mácula e uma máquina 2.4GHz com 2 GB de RAM, foram testados vários classificadores para conceder às imagens uma medida de qualidade. Esta medida representa a probabilidade posterior para um dado conjunto de descritores pertencer à classe de qualidade “Boa”. Os resultados obtidos estão apresentados na tabela 3.1.

Hunter *et al.* [40] em 2011 propôs um novo procedimento de quantificação de retinografias. O método começa por detetar a fóvea de acordo com o algoritmo apresentado por

		Classificação da Qualidade de Retinografias			
Abordagem	Classificador	"Good"	"Fair"	"Poor"	"Outlier"
Giancardo et al.	SVM ()	100%	83%	0%	11%
	SVM	100%	91%	0%	11%
	kNN (k=1)	100%	66%	0%	11%
	kNN (k=8)	100%	83%	0%	66%
Niemeijer et al.	ISC,SVM	83%	41%	0%	0%

Tabela 3.1: Comparação de performance entre os métodos de Giancardo *et al.* e de Niemeijer *et al.* [38].

Lowell *et al.* e por segmentar os vasos do olho a partir de um método criado anteriormente por Hunter *et al.*. A avaliação de qualidade de imagem é iniciada com a análise dos vasos a uma unidade ODD da fóvea.

Posteriormente, para a avaliação do contraste foram definidas duas regiões concêntricas centradas na fóvea: uma região circular com um raio de 10 pixéis e uma região em forma de anel com um raio interior de 30 pixéis e um raio exterior de 60 pixéis. Após a delimitação destas zonas, é calculado o contraste entre as mesmas.

O teste deste procedimento foi efetuado utilizando um conjunto de 200 imagens retinianas. Os resultados obtidos foram comparados com outros métodos de qualificação de qualidade de retinografias, como é possível observar na tabela 3.2.

		Classificação da Qualidade de Retinografias		
Método	Sensibilidade	Especificidade	Exatidão	
Hunter <i>et al.</i>	100%	93%	94%	
Usher <i>et al.</i>	100%	87%	88%	
Lalonde <i>et al.</i>	100%	19.5%	28%	

Tabela 3.2: Comparação de performance entre os métodos de Hunter *et al.*, de Usher *et al.* e de Lalonde *et al.* [40].

A desvantagem deste procedimento é ser demasiado dependente da região macular, acabando por não analisar outros componentes morfológicos de igual importância. No entanto, os autores referiram que é necessário continuar o desenvolvimento deste algoritmo de forma a incluir parâmetros como a claridade do disco ótico e o alinhamento da fotografia.

Mais recentemente, em 2016, Welikala *et al.* [42] publicou o primeiro método de classificação de qualidade de imagem com o propósito de ser utilizado em estudos epidemiológicos.

Este método utiliza o sistema automatizado QUARTZ criado pelos autores, que efetua a segmentação da vascularização do olho e recolhe informação sobre toda a retina [43].

Este sistema implementa um detetor de linhas de escala múltipla que calcula a média dos níveis de cinza dos pixéis ao longo de uma linha com diferentes orientações. Inicialmente é criada uma janela quadrada centrada no pixel alvo e é calculado o valor médio de cinza dos pixéis incluídos. A força dos valores da linha é obtida através da subtração entre a

orientação que obteve o valor mais alto de intensidade e esta média de cinza. A designação escala múltipla advém do facto de vários comprimentos de linha terem sido definidos. A força final dos valores da linha resulta da combinação linear dos resultados obtidos das linhas com diferentes comprimentos. A segmentação termina com a aplicação de uma reconstrução morfológica baseada na limiarização da histerese.

Seguidamente são calculados os descritores das imagens. Foram utilizados 3 tipos de descritores: a soma de todos os pixéis segmentados (área), o número de componentes conectados dividido pela soma de todos os pixéis segmentados (fragmentação) e o número de segmentos dividido pela soma de todos os pixéis (complexidade).

A classificação foi feita utilizando os classificadores SVM e um classificador de Árvores de Decisão. Para o efeito foram utilizadas 800 retinografias. Estas imagens foram classificadas como adequadas ou inadequadas. Os resultados dos dois classificadores estão representados na tabela 3.3.

Método	Área ROC	Sensibilidade	Especificidade
SVM	0.9828	95.33%	91.13%
Árvores de Decisão	0.9726	95.33%	89.09%

Tabela 3.3: Performance do método de classificação de Welikala *et al.* consoante o classificador [42].

Embora tenham sido obtidos bons resultados, como este método apenas se preocupa com a qualidade da visibilidade dos vasos sanguíneos, regiões da imagem que abrangem outros componentes do olho não são avaliadas.

A principal inconveniência destes algoritmos dependentes da segmentação do olho, é o facto destes métodos dependerem da deteção dos componentes da retina, acabando por ser inexecutáveis e propensos a erros quando analisam imagens com qualidade muito inadequada ou com certos componentes ocultados. Também de referir que normalmente estes procedimentos acrescentam custos no tempo de computação e a nível de processamento do sistema utilizado. Contudo, caso bem construídos, a etapa de segmentação pode ser usada para relacionar a qualidade de certas regiões do olho com a sua significância no diagnóstico. Inclusive, pode vir a ser útil não só em algoritmos de avaliação de qualidade de imagem, mas também na deteção automática de patologias.

### 3.2.3 Métodos baseados em características morfológicas e genéricas de imagem

Em 2010 surgiu um novo método de avaliação de qualidade de imagens retinianas desenvolvido por Paulus *et al.* [41]. Este método combina procedimentos de segmentação do olho e indicadores genéricos de qualidade de imagem.

A fase de segmentação é semelhante à fase ISC apresentada no trabalho de Niemeijer

*et al.*, exceto que Paulus *et al.* utiliza o algoritmo de aglomerado *K-means* diretamente na intensidade do pixel, desta forma também incluindo informação global do pixel.

Posteriormente à segmentação do olho, são determinadas duas medidas genéricas: a nitidez e o contraste. Para além destes indicadores, são introduzidas as medidas de entropia, de energia e de contraste desenvolvidas por Haralick [33].

Foram utilizadas 301 imagens retinianas (236 com boa qualidade e 65 com má qualidade) possuindo 22.5<sup>o</sup> FOV, tendo sido também realizados vários testes com diferentes combinações de indicadores. Para o efeito, foi utilizada uma máquina Intel<sup>®</sup> Core<sup>™</sup> 2 Duo Quad Q9550 a correr com 2.4 GHz e com 3 GB de RAM. Todo o processamento demorou 5.4 segundos. Os resultados podem ser observados na tabela 3.4:

Indicadores	Classificação da Qualidade de Retinografias		
	Sensibilidade	Exatidão	Área ROC
ISC	78.5%	86.7%	87.2%
Nitidez	46.2%	79.4%	60.9%
Aglomerado	89.2%	86.3%	90.7%
Haralick	90.7%	89.7%	92.7%
Aglomerado + Nitidez	87.7%	86.4%	89.3%
Haralick + Aglomerado	93.9%	90.4%	94.0%
Haralick + Nitidez	95.4%	91.0%	94.8%
Haralick + Aglomerado + Nitidez	96.9%	91.7%	95.3%

Tabela 3.4: Performance do método de classificação Paulus *et al.* [41] consoante os indicadores utilizados (Especificidade de 80%).

Este tipo de técnicas reúnem as melhores vantagens de métodos baseados em indicadores genéricos e métodos de segmentação morfológica, sendo esperado que um algoritmo mais robusto e preciso seja desenvolvido. Todavia, este procedimento é demasiado dependente da FOV, pois apenas funciona para FOV de 22.5<sup>o</sup> e não para outros tipos de FOV existentes.

Como foi demonstrado pelo conjunto de algoritmos mencionados acima, a avaliação automática de qualidade de imagens da retina tem sido alvo de grande interesse e pesquisa nas últimas duas décadas. Inclusive novos métodos de classificação estão a começar a ser utilizados nesta área, tal como métodos de aprendizagem profunda. Também é de constatar que, devido à versatilidade de muitos dos métodos expostos, existe a possibilidade dos mesmos serem aplicados noutras áreas médicas.

### 3.3 Deteção e Classificação de Artefactos em Retinografias

O maior obstáculo na análise automática de imagens do fundo do olho é a qualidade inadequada das imagens em estudo. A presença de artefactos neste tipo de imagens provoca a obstrução de sintomas, afetando a realização do correto diagnóstico de doenças na retina.

Existem várias maneiras de abordar este problema e uma delas é recorrer à avaliação de qualidade das retinografias.

Como mencionado na secção anterior, os procedimentos de Lee *et al.* [29] e de Lalonde *et al.* [30] avaliam a qualidade de uma imagem de acordo com uma distribuição de referência anteriormente calculada. Infelizmente, existem elementos da retina que se assemelham a certos tipos de artefactos, tornando este processo numa solução pouco viável. Os métodos propostos por Fleeming *et al.* [6], Niemeijer *et al.* [36] e outros trabalhos baseados em características morfológicas são ineficazes caso a qualidade da imagem seja extremamente negativa. Algoritmos de classificação binária, tal como a metodologia proposta por Dias *et al.* [9], apesar de garantirem boa performance, não lidam com os artefactos presentes nas retinografias, não existindo aproveitamento das zonas restantes da imagem, potencialmente aptas para serem utilizadas em diagnóstico. A solução passa pela deteção, avaliação e possível eliminação de artefactos.

Uma abordagem possível é desenvolver técnicas de deteção para só um tipo de artefacto. Nomeadamente, na deteção de pestanas, Zhang *et al.* [54] em 2006 criou um método que remove pestanas das imagens utilizadas nos algoritmos de reconhecimento da íris humana.

Na medida em que as pestanas provocam descontinuidades nas suas bordas, é utilizado um filtro de Sobel, seguido pelo cálculo da direção da variação do gradiente com o fim de detetar as bordas da pestana e classificar os pixéis afetados pela presença da mesma. Finalmente, é utilizado um filtro não-linear para remover os objetos. Este altera a intensidade do pixel caso a intensidade ultrapasse um valor limiar. Utilizando este método, foi alcançado um valor de taxa de reconhecimento correto (CRR) de 100%. Apesar dos ótimos resultados, o recurso a parâmetros e valores limiares selecionados experimentalmente, torna este método vulnerável ao nível de ruído presente e às condições de aquisição das imagens.

Mais tarde, tendo em consideração o trabalho de Zhang *et al.*, em 2009 Min *et al.* [55], concebeu uma metodologia de deteção automática de pálpebras e pestanas utilizando o modelo parabólico de Hough e o método de limitação de Otsu [56], respetivamente. A primeira fase deste algoritmo concentra-se na aplicação da transformada de Hough na imagem da íris normalizada para detetar as extremidades da pálpebra. É utilizada esta transformada devido à robustez que é verificada na deteção de formas parabólicas. A segunda fase é dividida noutras duas etapas: uma de extração de descritores baseada na intensidade e desvio padrão e outra de classificação automática da região ocupada por pestanas.

Nesta primeira etapa, após a aplicação de um filtro de desvio padrão numa janela em cada pixel, são calculados os valores de intensidade e desvio padrão normalizados. Na segunda etapa, é aplicado o método de Otsu na imagem empregando o cálculo dos descritores combinados. O método de Otsu efetua delimitação automática baseada no histograma da imagem, criando duas classes de pixéis: pertencentes a pestanas e pertencentes à pálpebra. Uma das medidas de avaliação usadas neste método, foi a curva de compensação do erro de deteção (DET). Esta curva reflete a relação entre duas medidas: o rácio de falsa aceitação (FAR) que consiste na probabilidade de um objeto não autorizado ser identificado, e a

medida oposta, o rácio de falsa rejeição (FRR). Este método foi comparado com outros 6 (incluindo o de Zhang *et al.*). O resultado desta comparação está exposto na imagem 3.6, sendo possível verificar que o método proposto demonstra a melhor performance.

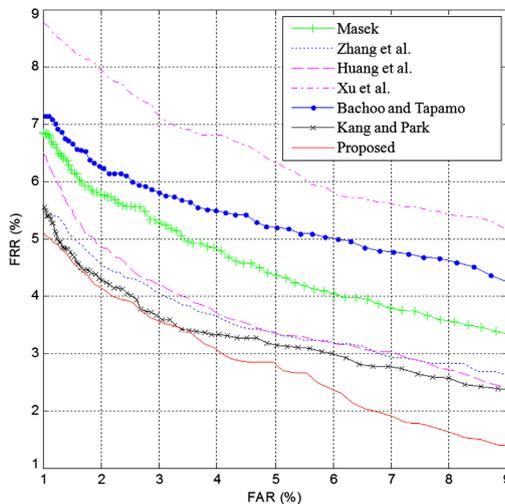


Figura 3.6: Comparação entre desempenhos representada pelas curvas DET [55].

Haleem *et al.* [57], em 2015 construiu um classificador capaz de excluir zonas que contêm artefactos (pestanas ou pálpebras) de imagens fotografadas em oftalmoscopia a laser de varredura (SLO). A primeira fase diz respeito à conceção do classificador, em que as imagens são treinadas consoante a catalogação da área em redor da retina.

Na fase seguinte, o conjunto de imagens de teste é executado e a performance do classificador é avaliada. Neste procedimento foram utilizados descritores de textura [33], gradiente de cinza e descritores regionais. Os primeiros dois tipos de descritores referidos, são incumbidos de avaliar o foco e iluminação respetivamente, enquanto que os últimos medem o formato dos conjuntos de superpixéis anteriormente calculados, pois estes na presença de artefactos apresentam uma forma irregular. Seguidamente foi efetuada seleção de descritores utilizando a abordagem SFFS que resultou na escolha de 33 descritores. O classificador utilizado foi uma rede neuronal artificial (ANN) possuindo apenas uma camada oculta com 10 neurónios. Na última fase é realizada a extração automática da zona da retina contendo artefactos. Para este procedimento foi alcançada uma exatidão de 92% quando avaliada a segmentação da área sem artefactos.

Quanto à segmentação de zonas com iluminação irregular, Ravishankar *et al.* [58] em 2009, criou um método de localização de diferentes componentes morfológicos e lesões da retina. Um dos passos referidos neste trabalho foi a deteção e localização de exsudatos. Na medida em que a aparência destas lesões assemelha-se a contaminação de luz, foi construído um classificador para diferenciar os dois tipos de áreas claras. Após ser feita a delimitação das lesões utilizando operações morfológicas, são retiradas todas as regiões em que as médias das intensidades do canal verde são superiores a uma fração da intensidade máxima do canal.

Seguidamente é seleccionada a magnitude do gradiente do canal verde. Esta magnitude

é limitada pelo valor obtido do treino de outro grupo de imagens, e são contados o número de pixels brancos da região delimitada. Caso o número de pixels da região não corresponda às especificações de brilho e de gradiente definidas, as regiões são classificadas como artefactos e são descartadas. A solução proposta passa pela deteção e mascaramento do disco ótico na operação de classificação de exsudatos, devido às semelhanças entre ambos. Neste procedimento foi obtida uma sensibilidade de 95.7% e uma especificidade de 94.2%.

Zhang *et al.* [59] em 2014, propôs novos métodos de pré-processamento de retinografias. Estes não só estão encarregues de normalizar o ruído de fotografias, mas também detetam reflexões, artefactos e constituintes da retina na imagem. Neste contexto, após a segmentação do disco ótico, é realizado um procedimento de deteção e classificação de exsudatos.

A etapa de pré-processamento começa por remover estruturas mais escuras da imagem como vasos e algumas lesões, seguida pela remoção de estruturas claras como nervos óticos ou reflexões dos vasos sanguíneos. Os candidatos a exsudatos são detetados e é feita a sua classificação. Nesta última etapa, são utilizadas técnicas de aprendizagem automatizada para diferenciar as lesões dos artefactos. Foi utilizado o classificador aleatório de floresta, em que foram estabelecidas 500 árvores de decisão. Em termos de validação ao nível do pixel foram alcançados os valores descritos na tabela 3.5. É possível verificar que alguns pixels

Valor Limitante	Sensibilidade (%)	Valor Preditor Positivo (%)
0	83	49
0.4	74	72
0.8	30	92

Tabela 3.5: Validação do método de Zhang *et al.* ao nível do píxel.

não são detetados mesmo diminuindo o valor limitante utilizado. Estes valores normalmente estão associados a exsudatos muitos pequenos e com contraste reduzido.

Recentemente, em 2016, Porwal *et al.* [60], apresentou um trabalho que efetuava o mascaramento de diferentes tipos de artefactos luminosos, podendo estes ser removidos. No primeiro passo, é extraído o canal azul da imagem, pois este tende a realçar zonas claras. Posteriormente, é utilizada uma metodologia de interpolação linear encarregue de calcular os valores dos quantis. Em seguida é criada a máscara do artefacto utilizando o sexto quartil (escolhido empiricamente) como valor limitante. Utilizando um banco de 2308 imagens, foram detetados corretamente 92% dos casos com exsudatos sem a existência de falsos positivos.

Como é possível inferir, o domínio da deteção e classificação de artefactos é relativamente recente. Inclusive, esta área de investigação é ideal para o uso de mecanismos de aprendizagem automatizada devido à natureza das retinografias. Por conseguinte, é esperado que novos métodos recorrendo à aplicação das mais variadas técnicas de classificação/deteção surjam de forma a melhorar e facilitar o diagnóstico das patologias oculares.

# Capítulo 4

## Materiais e Equipamentos Usados

Com o intuito de testar e construir os métodos propostos, foram utilizadas diferentes plataformas de processamento (computadores), softwares e vários bancos de imagens, tanto públicos como privados. Este capítulo expõe os materiais utilizados nesta dissertação.

### 4.1 Bancos de Imagens Públicos

- **Messidor [45]**: Banco com 1200 imagens marcadas com boa qualidade, provenientes de três departamentos oftalmológicos franceses distintos. Todas as imagens têm 45º de FOV e podem ter três resoluções diferentes: 1444 por 960 pixels, 2240 por 1488 pixels ou 2304 por 1536 pixels. Exemplos destas imagens estão apresentados na secção B.1.

### 4.2 Bancos de Imagens Privados

- **Banco de Imagens Privado #1**: 216 imagens provenientes de um rastreio público, marcadas pelo fotógrafo como tendo alguma irregularidade na imagem e escolhidas consoante os seus problemas de qualidade. Todas as imagens têm resolução 2448 por 2448 pixels e são centradas no disco ótico ou na mácula.
- **Banco de Imagens Privado #2**: 4408 imagens provenientes de um rastreio público, sem nenhum comentário sobre as irregularidades presentes na imagem. Todas as imagens têm resoluções diferentes e são centradas no disco ótico ou na mácula.

### 4.3 Recolha de Imagens de Treino e Teste

Para a conceção dos métodos seguintes, uma categorização das imagens teve de ser efetuada. Logo, o primeiro passo antes de qualquer processamento, foi realizar uma etiquetagem das imagens consoante o tipo de irregularidades que afetam a sua qualidade. Por conseguinte, para as 4408 imagens disponibilizadas inicialmente, foram consideradas as seguintes

classes de retinografias: imagens possuindo marcas de reflexão de luz (“Artef.”), sem problemas de qualidade (“Boas”), com sintomas de cataratas (“Cata.”), corrompidas (“Corromp.”), desfocadas (“Desf.”), fotografias com problemas de enquadramento (“Enquad.”), imagens que sofriam sobre-exposição de luz (“M. Luz”), que foram etiquetadas apenas como não classificáveis (“N. Clas.”), com regiões ou totalmente obscurecidas (“P. Luz”) e imagens que sofriam algum corte na área abrangida pelo olho ou distorções relacionadas com o seu dimensionamento (“Dist.”). O número de imagens em cada categoria está descrito na tabela 4.1. De notar, que uma imagem pode ter mais que um tipo de defeito, sendo assim classificada em várias categorias diferentes. Todas as catalogações de imagens referidas nesta dissertação, tiveram como referência as regras de classificação expostas nos protocolos [26, 28].

"Artef."	"Boas"	"Cata."	"Corromp."	"Desf."	"Enquad."	"M. Luz"	"N. Clas."	"P. Luz"	"Dist."
628	338	2375	68	60	3	1385	68	852	44

Tabela 4.1: Número de imagens inicial consoante as respetivas classes.

## 4.4 Plataformas e Software

Na medida em que existem dois métodos em análise neste trabalho, foram utilizadas plataformas diferentes consoante as necessidades e exigências de cada. O primeiro método exposto no capítulo 5, foi realizado e processado no software interativo MATLAB<sup>®</sup> e foi utilizada a primeira máquina exposta para processar o método descrito. A exploração de dados foi efetuada no programa WEKA e na aplicação Classification Learner do MATLAB<sup>®</sup>.

- **Sistema Operativo:** Windows 8.1;
- **Processador:** Intel<sup>®</sup> Core<sup>™</sup> i7-4510U CPU 2 GHz;
- **RAM:** 8 GB;
- **Gráfica:** AMD Radeon R7 M260, Intel<sup>®</sup> HD Graphics Family.

O computador com as especificações seguintes foi utilizado para processar o método descrito no capítulo 6. Este algoritmo foi criado e processado no MATLAB<sup>®</sup>.

- **Sistema Operativo:** Windows 10;
- **Processador:** Intel<sup>®</sup> Core<sup>™</sup> i5-7600 CPU 3.5 GHz x 4;
- **RAM:** 32 GiB;
- **Gráfica:** GeForce GTX 1080 Ti/Pcle/SSE2.

## Capítulo 5

# Avaliação Setorial de Qualidade de Retinografias

A avaliação de qualidade de imagens da retina, normalmente executada por um médico ou técnico experiente, recorre à verificação de diversos parâmetros específicos da imagem. Neste tipo de exames médicos também é analisada a influência da qualidade de imagem na capacidade de visualização de certos componentes da retina onde existe uma maior probabilidade de possuir sintomas específicos de certas doenças. Dado que, em muitos casos, a qualidade da imagem deteriora apenas parte da imagem, existem muitas retinografias que são avaliadas como não classificáveis quando as secções do olho estão perfeitamente visíveis.

Por conseguinte, este método visa alterar o algoritmo de avaliação de qualidade de imagens baseado em indicadores genéricos proposto por Dias *et al.* [9], de forma a que haja um melhor aproveitamento das imagens obtidas em rastreios médicos. A solução sugerida compreende o mesmo procedimento de avaliação desenvolvido por Dias *et al.*, mas em vez da imagem ser analisada na sua totalidade, a retinografia é dividida em setores morfológicos e estes são avaliados independentemente. Este capítulo é dedicado à descrição pormenorizada do método proposto e à análise detalhada dos resultados conseguidos.

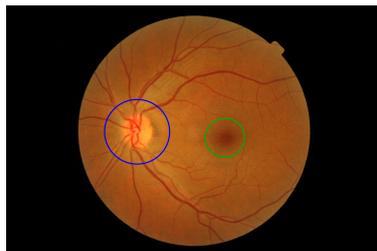


Figura 5.1: Retinografia com setores em estudo assinalados. A circunferência azul destaca o disco óptico e a circunferência verde a zona da fóvea. Adaptado de [45].

## 5.1 Implementação do Método Proposto

O desenvolvimento do algoritmo proposto foi feito em duas fases: uma fase inicial de tratamento e pré-processamento de imagens e uma segunda fase em que foi criado o algoritmo de setorização e foram efetuadas modificações ao algoritmo concebido por Dias *et al.*. Informações detalhadas sobre estas fases serão retratadas nas próximas partições.

### 5.1.1 Pré-Processamento e Recolha de Imagens de Teste

O método proposto requer conhecimento prévio da estrutura do olho, deste modo, antes de executar o procedimento de setorização, cada imagem é sujeita a uma fase de pré-processamento em que são localizados o disco ótico e a fóvea na imagem. Para o efeito, a Retmarker S.A. disponibilizou um algoritmo de deteção destes componentes morfológicos. Este método devolve os limites do disco ótico e o centro da fóvea na imagem processada em pixéis, para além de outras informações sobre a retinografia analisada. Consequentemente, foi necessário verificar e etiquetar as imagens processadas mediante as seções detetadas.

Na fase seguinte as imagens foram categorizadas manualmente consoante o correto posicionamento da fóvea, do disco ótico, ou de ambos. Contudo, devido à sua extrema carência de qualidade ou pouca resolução, existiram fotografias que não possibilitaram que os marcos pretendidos fossem detetados, outras em que o algoritmo devolveu as coordenadas erradas. Portanto, das 4408 imagens iniciais, apenas restaram 1812 com pelo menos um dos elementos pretendidos devidamente localizado. As imagens resultantes por classe estão apresentadas na tabela 5.1.

Tipo de Imagem	"Artefactos"	"Boas"	"Cataratas"	"Desfocadas"	"Muita Luz"	"Pouca Luz"
Quantidade	232	6	1670	15	1287	887

Tabela 5.1: Número de imagens após o processamento do algoritmo de localização da fóvea e do disco ótico consoante as respetivas classes.

Após o processamento efetuado restaram poucas imagens nas classes “Boas” e “Desfocadas”. Consequentemente, após ser feita a localização dos componentes morfológicos, foram adicionadas 200 imagens do banco de imagens Messidor [45] à classe “Boas” e foram adicionadas 216 fotografias de um banco de imagens privado à classe “Desfocadas”. No total, foram recolhidas 2228 imagens aptas para serem utilizadas na etapa seguinte.

### 5.1.2 Algoritmo de Setorização

O algoritmo proposto realiza a setorização das imagens do fundo do olho tendo em conta a localização das regiões principais da retina. Para o efeito foram consideradas três regiões: a região do disco ótico, a região da fóvea e a região restante. A escolha das secções a delimitar teve como suporte vários estudos científicos [13, 14, 15, 16, 46] e a opinião de

um médico oftalmologista, sendo verificado que a maioria dos sintomas de doenças oculares localizavam-se sobretudo nas proximidades do disco óptico ou da zona da mácula.

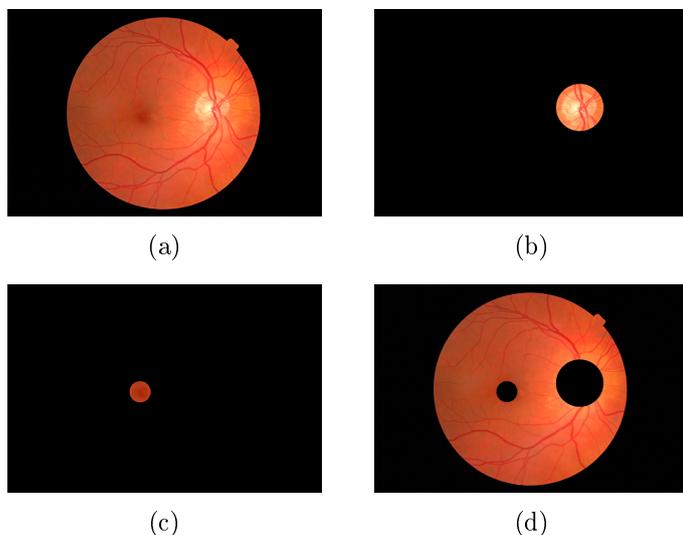


Figura 5.2: Imagem original e as respectivas secções em estudo: (a) imagem original [45], (b) região do disco óptico, (c) região da fóvea, (d) região restante.

O processo de setorização é iniciado com a delimitação das regiões a serem processadas. Independentemente da região, a sequência é fundamentalmente a mesma: definição da zona de interesse seguida do cálculo da máscara correspondente. Mascaramento de imagem consiste no método de catalogação de conjuntos de pixéis, considerados irrelevantes, como fundo de imagem. Neste âmbito, estas zonas correspondem aos pixéis a preto que rodeiam a retina. A abordagem utilizada recorre a um valor limiar para definir a região de interesse. Este valor limiar é aplicado ao canal verde da imagem e, depois de localizar o centro da região a considerar e a sua extensão (raio no caso das circulares), é criada uma imagem binarizada com os pixéis de interesse a branco. Para o efeito, foi realizado um estudo empírico com 80 imagens possuindo diferentes problemas de qualidade que permitiu definir o melhor valor limiar para cada região, tendo sido estabelecido um valor de 20 para a região do disco óptico e um de 14 para a região da fóvea. Este método funciona adequadamente devido à diferença de luminosidade das zonas em estudo em relação ao resto da retina, especificamente a zona da fóvea é mais escura e a zona do disco óptico é mais clara. Exemplos das máscaras obtidas estão representadas na Fig. 5.3.

Caso o disco óptico seja corretamente localizado, tendo em conta as coordenadas provenientes do algoritmo de pré-processamento, o raio do disco óptico é calculado e a região é mascarada. Contudo, no caso da deteção da fóvea, é necessário calcular o raio que melhor define a depressão da mácula.

Esta cavidade normalmente assemelha-se a uma pequena zona circular ensombrada, facilmente distinguível. Nas circunstâncias em que a fóvea é detetada, são aplicados um conjunto de filtros para facilitar a segmentação. Nomeadamente, são aplicados um filtro de dilatação,

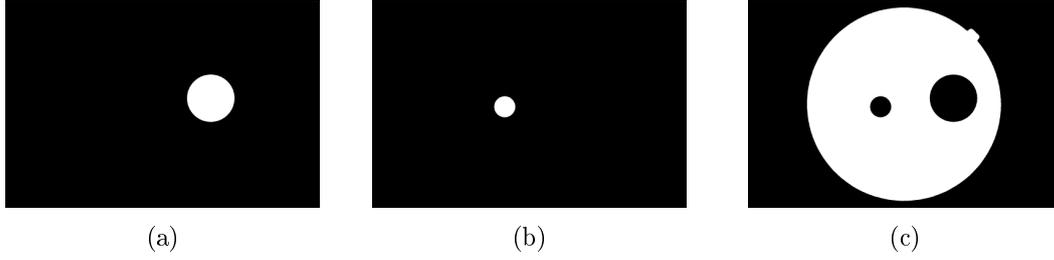


Figura 5.3: Máscaras das secções da Fig. 5.2.a : (a) região do disco ótico, (b) região da fóvea, (c) região restante.

seguido por um filtro de erosão e finalmente um filtro de mediana ao canal verde da imagem. Estes filtros são muito utilizados nas fotografias médicas de modo a sobressair certas regiões de interesse na imagem [48, 49]. Mais precisamente, estas operações permitem configurar o contraste e luminosidade da imagem original. O filtro de dilatação evidencia as áreas mais claras da imagem e menores que a máscara do filtro. Este filtro é obtido ao subtrair a abertura da imagem à imagem original. O filtro de erosão comporta-se de maneira contrária, distinguindo as áreas mais escuras e menores que a máscara do filtro e removendo o plano de fundo. Consequentemente, este filtro resulta da subtração entre a imagem original e o fecho da imagem. Contudo, como é desejado sobressair a zona da fóvea, ambos os filtros foram subtraídos à imagem original de forma a escurecer as zonas escuras e retirar possíveis contaminações de luz que ocultem parte da imagem. Para retirar o ruído restante, é aplicado um filtro de mediana. Este filtro suaviza a imagem removendo o ruído, mas preservando descontinuidades num conjunto de pixéis. A figura 5.4 apresenta uma imagem após as várias fases de filtragem mencionadas.

Após a filtragem da imagem, é calculada a variação de luminância numa região circular centrada na fóvea. A escolha do raio que melhor define a região da fóvea tem como princípio o aumento repentino da luminância, indicando a diferença de intensidade dos pixéis da região da fóvea e do resto do olho. Mais precisamente, para encontrar o raio ideal da cavidade, são calculadas circunferências com raios progressivamente maiores centradas na fóvea. A intensidade dos pixéis de cada circunferência é somada e é criada uma função polinomial que representa a média da intensidade dos pixéis de cada circunferência, representada pela equação 5.1. Foi escolhido um polinómio de grau 6 para ser possível representar as mudanças de luminância mais suaves. Em seguida é calculada a segunda derivada dessa função (eq. 5.2) e o valor do raio escolhido corresponde ao mínimo local apresentado.

$$p(u) = p_1u^6 + p_2u^5 + p_3u^4 + p_4u^3 + p_5u^2 + p_6u + p_7 \quad (5.1)$$

$$\frac{d^2p}{du^2} = x^3(30p_1u + 20p_2) + 12p_3u^2 + 6p_4u + 2p_5 \quad (5.2)$$

Seguidamente, é realizado o mascaramento da imagem. O setor restante é definido como o complemento da união dos setores da fóvea e disco ótico. A imagem original e as áreas

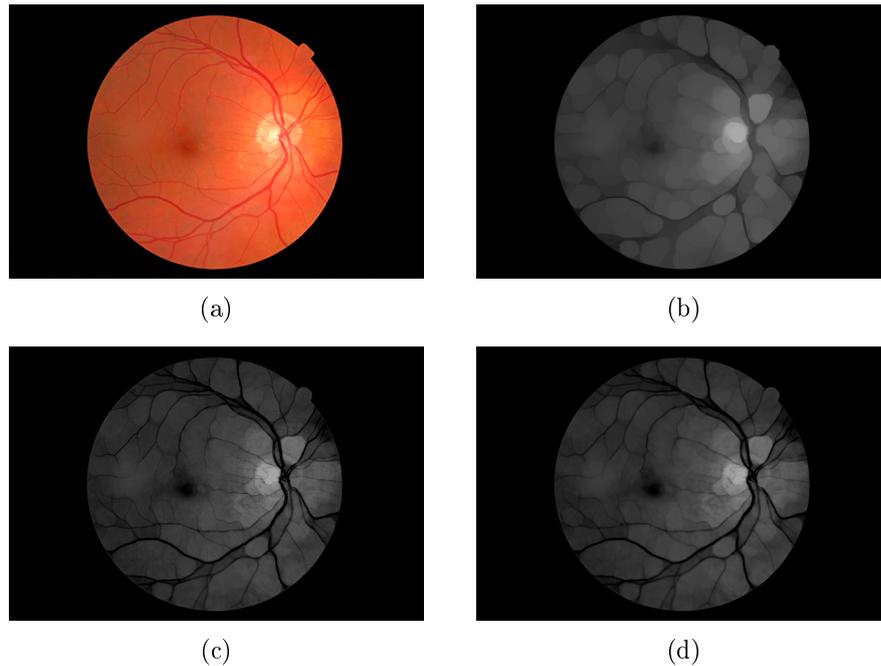


Figura 5.4: Imagem original e as imagens após cada etapa de filtragem: (a) imagem original [45], (b) após a aplicação do filtro de dilatação, (c) após a aplicação do filtro de erosão, (d) após a aplicação do filtro de mediana.

delimitadas em estudo estão representadas na Fig. 5.2.

Subsequentemente, é resumida a classificação de qualidade da imagem global e dos setores associados utilizando o método de classificação de Dias *et al.*. Todas as imagens e setores são avaliados e classificados de acordo com a sua cor, foco, contraste e iluminação. A informação é reunida e submetida a uma decisão final de classificável ou não classificável. As medidas provenientes dos algoritmos dos quatro atributos da imagem também são sujeitas a avaliação para obter a classificação de cor, foco, contraste e iluminação da imagem. A figura 5.5 descreve os passos deste algoritmo de setorização.

Para possibilitar a comparação entre os resultados obtidos, tanto os setores como a imagem original, foram etiquetados manualmente consoante os indicadores de cor, luminosidade, foco e contraste. Estes resultados, informação sobre a presença de vários tipos de artefactos em cada setor e nas imagens originais, e os valores adquiridos do algoritmo de classificação foram documentados para facilitar trabalho futuro.

A fim de garantir resultados favoráveis, o algoritmo de classificação setorial sofreu algumas modificações. A próxima partição descreve as alterações efetuadas.

### 5.1.3 Optimização

Os setores de imagem propostos representam componentes do olho com características muito próprias e distintas do resto da fisionomia da retina. Desta forma, o processo de classificação de qualidade do algoritmo original deve ser alterado para possibilitar o processamento

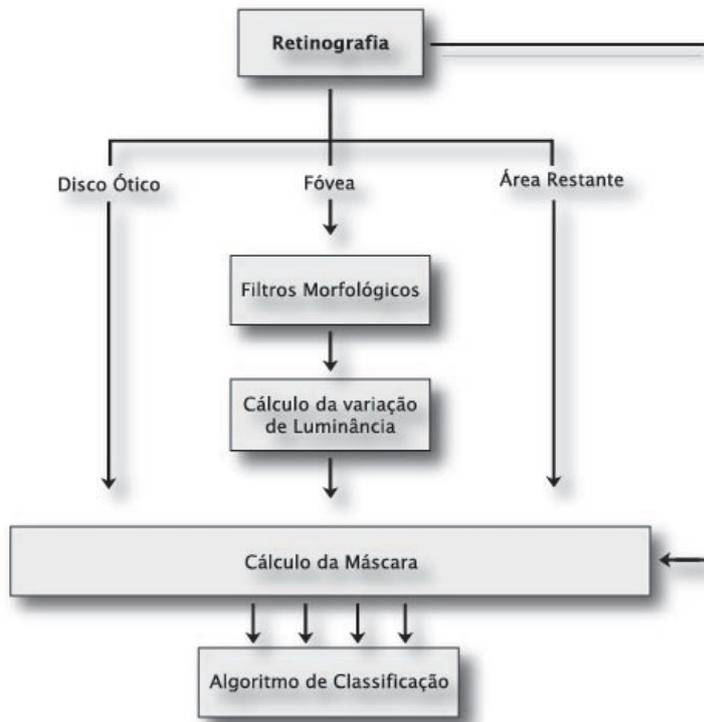


Figura 5.5: Diagrama que descreve o algoritmo de setorização proposto.

fiável dos setores. Por conseguinte, as soluções seguintes foram desenvolvidas.

### 5.1.3.1 Avaliação dos Classificadores

Na medida em que os classificadores do algoritmo de Dias *et al.* foram treinados com retinografias inteiras, é necessário treinar classificadores que estejam adaptados à classificação destas sub-regiões retinianas. Para o efeito, foram utilizadas as 2228 imagens referenciadas anteriormente, o programa WEKA e a aplicação Classification Learner do MATLAB<sup>®</sup>, ferramentas para explorar os dados e treinar os classificadores.

Também foi considerado fazer seleção de descritores utilizando métodos de filtragem. Estes métodos estudam a utilidade dos descritores independentemente do classificador escolhido e ordenam os descritores pela sua importância, sendo relativamente fácil fazer a seleção dos descritores pretendidos utilizando um valor limiar. Foram utilizadas três medidas de filtragem diferentes para cada indicador relativo a cada setor: a correlação, o quociente do ganho de informação e o ganho de informação. No entanto, devido ao número reduzido de descritores por indicador de qualidade genérico (alguns indicadores apenas eram avaliados com 3 descritores), esta seleção não foi efetuada.

### 5.1.3.2 Implementação dos Descritores de Textura

De forma a melhorar o desempenho dos classificadores propostos, principalmente a performance na avaliação das regiões do disco ótico e da fóvea, foram incorporados descritores

de textura. Este tipo de descritores é muito utilizado em processamento de imagem, nomeadamente na identificação de objetos ou regiões, pois contém informação sobre a distribuição espacial de tonalidades da imagem.

Em 1973, Haralick *et al.* [33] introduziu uma matriz de coocorrência de nível cinza (GLCM) e desenvolveu um conjunto de 14 medidas de textura. O tamanho desta matriz quadrada equivale ao número de níveis de cinza diferentes existentes na imagem. O elemento  $(i, j)$  da matriz é obtido através da soma de todos os casos em que um pixel de valor  $i$  é vizinho de um pixel com valor  $j$  e dividindo a matriz por este somatório. As medidas de textura desenvolvidas pelos autores estão representadas na tabela 5.2, assumindo que o tamanho da GLCM é  $N_g$  e  $p(i, j)$  representa a probabilidade de um pixel com valor  $i$  seja adjacente a um pixel de valor  $j$ , ou seja o elemento  $(i, j)$  da matriz. Os descritores de Haralick são calculados a partir da matriz de co-ocorrência gerada, utilizando quatro direções de vizinhança diferentes. As direções possíveis estão representadas na figura 5.6.



Figura 5.6: As quatro direções de vizinhança possíveis definidas no cálculo de descritores de Haralick [53].

A extração de descritores é dividida em duas etapas: primeiro é calculada a GLCM e seguidamente os descritores de textura baseados nesta matriz. Desde a sua criação que este método tem sido utilizado nas mais variadas aplicações de processamento de imagem, nomeadamente na análise de fotografias médicas.

Mais tarde, em 1999, Soh *et al.* [51] utilizou 10 medidas adquiridas a partir da GLCM para o estudo de padrões de mapeamento do gelo marítimo. Os autores, para além de terem usado cinco medidas apresentadas por Haralick *et al.* (Energia, Contraste, Correlação, Homogeneidade e Entropia representadas na tabela 5.2), aplicaram outras cinco medidas de textura, nomeadamente as medidas descritas na tabela 5.3.

Auto-correlação	$\sum_i \sum_j (ij)p(i, j)$
Dissimilaridade	$\sum_i \sum_j  i - j  \cdot p(i, j)$
Tom do Aglomerado	$\sum_i \sum_j (i + j - \mu_x - \mu_y)^3 p(i, j)$
Proeminência do Aglomerado	$\sum_i \sum_j (i + j - \mu_x - \mu_y)^4 p(i, j)$
Probabilidade Máxima	$\max_{i,j} p(i, j)$

Tabela 5.3: As medidas de textura utilizadas no projecto de Soh *et al.* [51] calculadas a partir da GLCM.

Mais recentemente, em 2002, Clasi *et al.* [52] estudaram o efeito da quantização do nível de cinza tendo em conta a capacidade das estatísticas de coocorrência classificarem texturas naturais. Para o efeito, utilizaram as medidas de uniformidade, entropia, dissimilaridade,

Segundo Momento Angular / Energia / Uniformidade:	$\sum_i \sum_j p(i, j)^2$
Contraste:	$\sum_{n=0}^{N_g-1} n^2 \{ \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i, j) \},  i - j  = n$
Correlação:	$\frac{\sum_i \sum_j (ij) p(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y}$ em que $\mu_x, \mu_y, \sigma_x, \sigma_y$ correspondem à média e variância de $p_x$ e $p_y$ , as funções de densidade de probabilidade parcial
Soma dos Quadrados:	$\sum_i \sum_j (i - \mu)^2 p(i, j)$
Momento de Diferença Inversa / Homogeneidade:	$\sum_i \sum_j \frac{1}{1+(i-j)^2} p(i, j)$
Média da Soma:	$\sum_{i=2}^{2N_g} i p_{x+y}(i)$ onde $x$ e $y$ são as coordenadas de um elemento da GLCM e $p_{x+y}(i)$ é a probabilidade da soma das coordenadas da GLCM ser igual a $x + y$
Variância da Soma:	$\sum_{i=2}^{2N_g} (i - f_8)^2 p_{x+y}(i)$
Entropia da Soma:	$-\sum_{i=2}^{2N_g} p_{x+y}(i) \log\{p_{x+y}(i)\} = f_8$
Entropia:	$-\sum_i \sum_j p(i, j) \log(p(i, j))$
Variância da Diferença:	$\sum_{i=0}^{N_g-1} i^2 p_{x-y}(i)$
Entropia da Diferença:	$-\sum_{i=0}^{N_g-1} p_{x-y}(i) \log\{p_{x-y}(i)\}$
Medida de Informação de Correlação 1:	$\frac{HXY - HXY1}{\max\{HX, HY\}}$
Medida de Informação de Correlação 2:	$(1 - \exp[-2(HXY2 - HXY)])^{\frac{1}{2}}$ em que $HXY = -\sum_i \sum_j p(i, j) \log(p(i, j))$ , $HX, HY$ são as entropias de $p_x$ e $p_y$ $HXY1 = -\sum_i \sum_j p(i, j) \log\{p_x(i)p_y(j)\}$ e $HXY2 = -\sum_i \sum_j p_x(i)p_y(j) \log\{p_x(i)p_y(j)\}$
Coefficiente de Correlação Máximo:	Raiz quadrada do segundo maior valor próprio $\mathbf{Q}$ em que $\mathbf{Q}(i, j) = \sum_k \frac{p(i, k)p(j, k)}{p_x(i)p_y(k)}$

Tabela 5.2: As medidas de Haralick *et al.* [33] calculadas a partir da GLCM.

contraste, momento de diferença inversa (apresentadas na tabela 5.2) e a medida de diferença inversa, representada pela equação 5.3.

$$\sum_i \sum_j \frac{1}{1 + |i - j|} p(i, j) \quad (5.3)$$

No trabalho presente foram consideradas todas as medidas expostas na tabela 5.2, na tabela 5.3 e a equação 5.3 no cálculo dos descritores de foco, contraste e na avaliação final de classificável ou não classificável das regiões da fóvea e do disco ótico. Neste trabalho foi utilizada a direção vertical, com um intervalo de uma unidade (vizinho mais próximo). Operações de seleção de descritores utilizando métodos de filtragem também foram realizadas de forma a obter os melhores resultados utilizando este novo conjunto de descritores e os descritores originais. Os resultados obtidos encontram-se descritos na secção seguinte.

## 5.2 Resultados e Discussão

Esta secção é destinada à apresentação e análise do desempenho na classificação de cada setor face à classificação manual desse mesmo setor mediante as modificações relatadas na secção anterior. Tanto o setor como a imagem inteira são avaliados consoante os indicadores de cor, foco, contraste e iluminação e a sua classificação global de qualidade. A performance do trabalho apresentado é analisada utilizando três medidas: a sensibilidade, especificidade e a precisão representadas pelas equações 5.4, 5.5 e 5.6 respetivamente.

$$\text{sensibilidade} = \frac{\text{número de verdadeiros positivos}}{\text{número de verdadeiros positivos} + \text{número de falsos negativos}} \quad (5.4)$$

$$\text{especificidade} = \frac{\text{número de verdadeiros negativos}}{\text{número de verdadeiros negativos} + \text{número de falsos positivos}} \quad (5.5)$$

$$\text{precisão} = \frac{\text{número de verdadeiros positivos}}{\text{número de verdadeiros positivos} + \text{número de falsos positivos}} \quad (5.6)$$

Estas medidas normalmente são utilizadas em avaliações de classificações binárias, mas os classificadores de cor e foco possuem três classes. Desta forma é considerada uma classe “correta” e as outras duas consideradas “incorretas”. Tendo como exemplo a avaliação da classificação de imagens “Claras”, verdadeiros positivos (TP) correspondem ao número de imagens “Claras” que foram corretamente classificadas, falsos negativos (FN) correspondem ao número de imagens “Claras” que foram classificadas como “Normais” ou “Escuras”, verdadeiros negativos (TN) correspondem ao número de imagens “Escuras” e “Normais” que foram corretamente classificadas e falsos positivos (FP) correspondem ao número de imagens “Escuras” ou “Normais” que foram classificadas como “Claras”. Este princípio também foi exercido na avaliação das classes “Normais” e “Escuras” referente ao algoritmo de classificação de cor e nas classes constituintes do algoritmo de classificação de foco.

Uma boa forma de analisar métodos de classificação multi-classe é através do uso de matrizes de confusão. Cada linha da matriz representa o número de casos previstos e cada coluna representa o número de casos reais. Assim, estas tabelas expõem o número de TP, TN, FP e FN documentados em cada classe de forma a facilitar a comparação entre os classificadores. Este tipo de representação de dados também é utilizado.

Para além das modificações expostas na secção anterior, foi efetuado um estudo para avaliar o desempenho do algoritmo de classificação tendo em conta a variação do raio da região em estudo. Nesta pesquisa foi considerado um intervalo de valores que variava desde o equivalente ao raio original obtido inicialmente até ao seu dobro. Mediante os resultados obtidos, os raios foram determinados e os valores escolhidos foram utilizados no algoritmo de setorização.

Todos os resultados obtidos nesta secção foram resultantes do processamento de 2228 imagens. Estas retinografias são divididas por setor e por classe como está exposto na tabela 5.4.

	Cor			Foco			Contraste		Iluminação		Global	
	Claras	Escuras	Normais	Desfocadas	Limite	Focadas	Baixo	Alto	Irregular	Regular	Não Classificável	Classificável
D.O.	265	43	1871	451	1383	345	1284	895	280	1899	348	1831
Fov.	15	3	586	384	207	12	567	37	54	550	175	429
A. R.	972	86	1170	747	1169	312	904	1324	1440	788	818	1410
Total	996	93	1139	333	1162	733	753	1475	1452	776	446	1782

Tabela 5.4: Número de imagens por setor (D.O. significa disco ótico, Fov. fóvea, A.R área restante e total representa a imagem completa) e por classe.

Por conseguinte, os resultados finais são derivados dos três estudos efetuados: inicialmente foi realizado o estudo da dimensão dos raios das regiões “Disco ótico” e “Fóvea”, seguidamente os classificadores foram avaliados e finalmente foram adicionados os descritores de textura. Os resultados obtidos nas três fases são analisados nesta secção.

## 5.2.1 Estudo do Efeito da Variação do Raio sobre o Desempenho

Como mencionado, foi efetuado um estudo empírico que analisa a variação do desempenho do algoritmo de classificação com a variação do raio da região do disco ótico e da fóvea. Este estudo foi elaborado com 2179 imagens em que o disco ótico é detetado e 604 imagens em que a fóvea é detetada. Estas imagens foram classificadas de acordo com a sua cor, foco, contraste, iluminação e qualidade global, resultando no número de imagens exposto na tabela 5.4.

As medidas utilizadas para avaliar a performance dos classificadores foram a sensibilidade, a especificidade e a precisão. No entanto, devido à extensão dos resultados, em seguida apenas serão expostos os valores da precisão da classe que representa a qualidade global dos setores, sendo que esta classe é considerada a mais importante de todo o processo, decidindo se a região pode ou não ser avaliada. As representações da sensibilidade, especificidade e precisão dos indicadores genéricos de imagem e a sua respetiva avaliação foram movidas para o apêndice C.

### 5.2.1.1 Raio da Região do Disco Ótico

Como é possível verificar através da análise da figura 5.7, de uma maneira geral, quanto maior o raio da região do disco ótico a ser avaliada, melhores são os resultados. Esta conclusão deve-se ao facto de o disco ótico ser mais claro que o resto do olho, sendo confundido por contaminação de luz. Por vezes não são avistados vasos nesta zona, provocando classificações incorretas quando é avaliado o foco e contraste, pois ambos são influenciados pela capacidade de visualização dos vasos. Assim, quanto maior for a área do olho abrangida para além do

disco ótico, melhor será a classificação. Desta forma, para esta região foi usado um raio igual ao dobro do raio do disco ótico devolvido pelo algoritmo de segmentação.

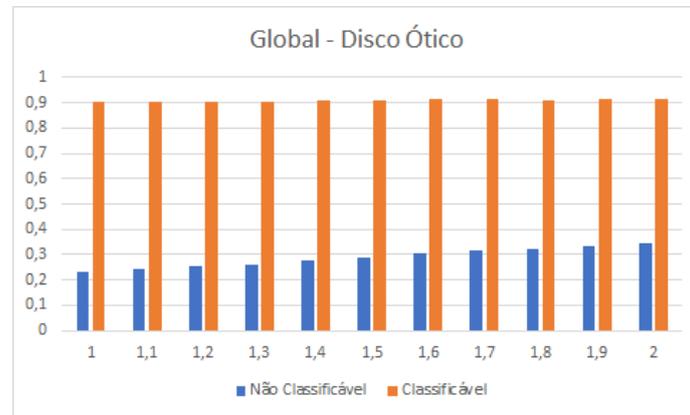


Figura 5.7: Gráfico obtido variando o raio do disco ótico. O eixo das abcissas representa o rácio entre o raio da região e o raio do disco ótico (intervalos de uma décima) e o eixo das ordenadas representa os valores de precisão. O gráfico refere-se à classificação da qualidade global da imagem.

### 5.2.1.2 Raio da Região da Fóvea

Através da avaliação da figura de 5.8 é possível observar, de uma maneira geral, os resultados não diferem muito entre si, possivelmente devido ao número reduzido de imagens em certas classes. Contudo, analisando o gráfico de classificação global de qualidade, é possível verificar que os melhores resultados são obtidos quando é considerado o raio original devolvido pelo algoritmo de setorização proposto. Desta forma, como esta classificação acaba por ser a mais importante neste procedimento, foi escolhido este valor de raio para representar a zona da fóvea.

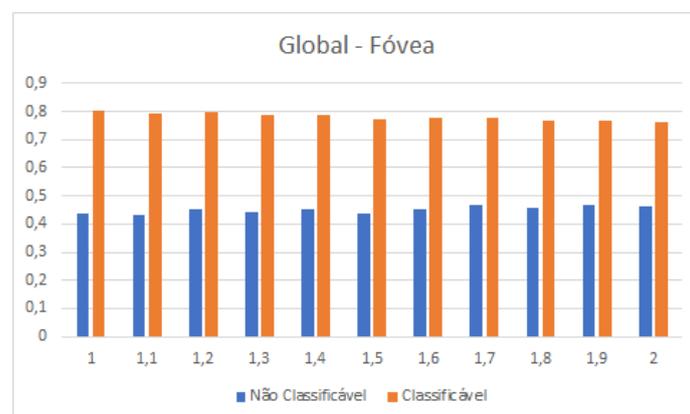


Figura 5.8: Gráfico obtido variando o raio da fóvea. O eixo das abcissas representa o rácio entre o raio da região e o raio da fóvea (intervalos de uma décima) e o eixo das ordenadas representa os valores de precisão. O gráfico refere-se à classificação da qualidade global da imagem.

## 5.2.2 Análise de Desempenho para Diferentes Classificadores

Como referido, foram treinados outros classificadores de modo a serem obtidos melhores resultados. Este estudo foi elaborado com as 2228 imagens já referidas e com a distribuição exposta na tabela 5.4. As medidas utilizadas para avaliar a performance dos classificadores foram a sensibilidade, a especificidade e a precisão. No entanto, devido à extensão dos resultados, em seguida apenas serão expostos os resultados provenientes da classificação global de qualidade. Os resultados adquiridos da avaliação dos classificadores dos restantes indicadores genéricos de imagem e a sua respetiva análise foram movidos para o apêndice C. Para além de serem expostos os melhores resultados utilizando um classificador novo, também são descritos os resultados provenientes dos classificadores criados por Dias *et al.*. Os classificadores propostos foram projetados usando o programa WEKA e a aplicação Classification Learner do MATLAB®.

### 5.2.2.1 Classificador da Região do Disco Ótico

O mecanismo sugerido que assegura melhores resultados corresponde no classificador *Bagged Trees*. Foram utilizadas 348 imagens etiquetadas como "Não Classificável" e 1831 como "Classificável". A tabela 5.5 apresenta os valores das medidas de avaliação do classificador proposto e do classificador criado por Dias *et al.*.

	Classificadores			
	Dias et al.		Proposto	
	"Não Classificável"	"Classificável"	"Não Classificável"	"Classificável"
Sensibilidade	0.6121	0.7766	0.4856	0.965
Especificidade	0.7766	0.6121	0.965	0.4856
Precisão	0.3424	0.9133	0.725	0.908

Tabela 5.5: Valores das medidas de análise dos classificadores de avaliação de qualidade global do disco ótico.

Mediante os resultados obtidos, o melhor classificador para efetuar a avaliação global de qualidade da região do disco ótico é o classificador concebido por Dias *et al.*, pois ambas as classes têm os valores de sensibilidade e especificidade superiores a 0,5, indicando que cada classe teve mais de metade das imagens corretamente classificadas, apesar do classificador proposto apresentar melhores valores de precisão. Os resultados de ambos os classificadores não são os ideais, pois a zona do disco ótico é mais clara que o resto da retina, sendo facilmente confundida com contaminação de luz e falsamente avaliada como não classificável.

### 5.2.2.2 Classificador da Região da Fóvea

A metodologia sugerida que assegura melhores resultados corresponde no classificador quadrático SVM. Foram utilizadas 175 imagens etiquetadas como "Não Classificável" e 429

como "Classificável". A tabela 5.6 apresenta os valores das medidas de avaliação do classificador proposto e do classificador criado por Dias *et al.*.

	Classificadores			
	Dias et al.		Proposto	
	"Não Classificável"	"Classificável"	"Não Classificável"	"Classificável"
Sensibilidade	0.5711	0.6993	0.354	0.9114
Especificidade	0.6993	0.5711	0.9114	0.354
Precisão	0.4391	0.8021	0.62	0.7758

Tabela 5.6: Valores das medidas de análise dos classificadores de avaliação de qualidade global da fóvea.

É possível observar que o melhor classificador para efetuar a avaliação global de qualidade da região da fóvea é o classificador concebido por Dias *et al.*, pois ambas as classes têm os valores de sensibilidade e especificidade superiores a 0,5, indicando que cada classe teve mais de metade das imagens corretamente classificadas. Os resultados de ambos os métodos não são os ideais para um classificador, devendo-se ao facto de a zona da fóvea ser mais escura que o resto do olho e ser uma região caracterizada por não existirem vasos sanguíneos. Também se deve considerar o facto de ser uma área bastante pequena e normalmente sem variações de cor, sendo facilmente confundida com uma sombra.

### 5.2.2.3 Classificador da Área Restante

O classificador sugerido que assegura melhores resultados corresponde ao classificador gaussiano médio SVM. Foram utilizadas 818 imagens etiquetadas como "Não Classificável" e 1410 como "Classificável". A tabela 5.7 apresenta os valores das medidas de avaliação dos dois classificadores.

	Classificadores			
	Dias et al.		Proposto	
	"Não Classificável"	"Classificável"	"Não Classificável"	"Classificável"
Sensibilidade	0.9046	0.3894	0.549	0.91
Especificidade	0.3894	0.9046	0.91	0.549
Precisão	0.4622	0.8756	0.7768	0.7764

Tabela 5.7: Valores das medidas de análise dos classificadores de avaliação de qualidade global da área restante.

Efetuada uma análise dos resultados obtidos, é de constatar que o melhor classificador para efetuar a avaliação global de qualidade da área restante é o classificador proposto neste trabalho, pois na sua totalidade, existe um menor número de imagens classificadas incorretamente e ambas as classes têm os valores de precisão, sensibilidade e especificidade superiores a 0,5. Os resultados de ambos os métodos não são os ideais para um classificador, devendo-se ao facto da dimensão desta área depender do tamanho das zonas do disco ótico e/ou da

fóvea consideradas. Inclusive, com certos componentes ausentes, torna-se difícil de classificar o foco e o contraste das retinografias.

#### 5.2.2.4 Classificador da Imagem Completa

O mecanismo sugerido que assegura melhores resultados corresponde no classificador de rede bayesiana. Foram utilizadas 446 imagens etiquetadas como "Não Classificável" e 1782 como "Classificável". A tabela 5.8 apresenta os valores das medidas de avaliação dos dois classificadores.

	Classificadores			
	Dias et al.		Proposto	
	"Não Classificável"	"Classificável"	"Não Classificável"	"Classificável"
Sensibilidade	0.9103	0.4080	0.5928	0.8611
Especificidade	0.4080	0.9103	0.8611	0.5928
Precisão	0.2779	0.9478	0.5137	0.8952

Tabela 5.8: Valores das medidas de análise dos classificadores de avaliação de qualidade global da retinografia completa.

Mediante os resultados obtidos, é de constatar que o melhor classificador para efetuar a avaliação global de qualidade da imagem total é o classificador proposto neste trabalho, pois na sua totalidade, existe um menor número de imagens classificadas incorretamente e ambas as classes têm os valores de precisão, sensibilidade e especificidade superiores a 0,5.

### 5.2.3 Implementação dos Descritores de Textura

Para melhorar as classificações obtidas, foram implementados os descritores de textura enunciados na partição 5.1.3.2. Mais precisamente, foram introduzidos os descritores de textura nas classificações de contraste, de foco e conseqüentemente, na classificação global de qualidade das regiões do disco ótico e da fóvea. Após a junção de todos os descritores (de textura e os originais), foram efetuadas operações de seleção de descritores, utilizando os filtros de correlação, quociente do ganho de informação e o ganho de informação. Os classificadores utilizados para treinar o novo conjunto de descritores foram os propostos na seção 5.2.2. Os resultados estão descritos em baixo.

#### 5.2.3.1 Disco Ótico

Após os descritores de textura terem sido adicionados aos descritores originais, foi observado que a junção melhorava o comportamento dos classificadores de contraste e da classificação global de qualidade da região do disco ótico. Foi realizado o estudo de seleção e todos os descritores tinham alguma influência na melhoria. Desta forma, o classificador de contraste ficou com 24 descritores (20 de textura + 4 originais) e o de global com 34 descritores.

A tabela 5.9 apresenta os resultados obtidos da classificação global de qualidade utilizando 34 descritores. Devido à extensão dos resultados, a matriz confusão restante e a sua análise estão representadas no apêndice C.

		Previsto	
		"Não Classificável"	"Classificável"
Real	"Não Classificável"	239	109
	"Classificável"	330	1501

Tabela 5.9: Matriz de confusão proveniente da classificação global de qualidade do disco ótico após a inclusão dos descritores de textura.

Relativamente à classe "Classificável", estes resultados geraram uma precisão igual a 0.932, uma sensibilidade igual a 0.8197, uma especificidade de 0.687 e uma precisão da classe "Não Classificável" de 0.42. Apesar de não ser muito significativo, deu-se um aumento em ambas as precisões, mais concretamente de 0.019 na classe "Classificável" e de 0.08 na classe "Não Classificável".

### 5.2.3.2 Fóvea

Tendo sido adicionados os descritores de textura aos descritores originais, foi observado que a junção melhorava apenas o comportamento do classificador global de qualidade. Foi realizado o estudo de seleção e todos os descritores tinham alguma influência na melhoria, resultando num total de 34 descritores. A tabela 5.10 apresenta os resultados obtidos da classificação global de qualidade.

		Previsto	
		"Não Classificável"	"Classificável"
Real	"Não Classificável"	108	67
	"Classificável"	111	381

Tabela 5.10: Matriz de confusão proveniente da classificação global de qualidade da fóvea após a inclusão dos descritores de textura.

Relativamente à classe "Classificável", estes resultados geraram uma precisão igual a 0.85, uma sensibilidade igual a 0.6171, uma especificidade de 0.7744 e uma precisão da classe "Não Classificável" de 0.493. Apesar de não ser muito significativo, deu-se um aumento de ambas as precisões, mais concretamente de 0.0479 na classe "Classificável" e de 0.0535 na classe "Não Classificável".

## 5.2.4 Discussão

A avaliação de qualidade de retinografias corresponde numa fase importante na deteção de doenças da retina, pois a qualidade das imagens pode interferir ou impossibilitar o diag-

nóstico. Desta forma é imperativo que métodos mais eficazes sejam criados para avaliar a qualidade destas imagens. O trabalho descrito neste capítulo foi uma tentativa de fornecer uma solução eficiente para a avaliação de qualidade de retinografias em ambientes de rastreio.

Após a observação dos resultados expostos, é de notar que ao longo das alterações realizadas nos algoritmos de setorização e de classificação de Dias *et al.*, os resultados vão progredindo. No entanto, os valores finais não são os ideais, existindo algumas limitações.

A performance inferior dos classificadores pode ser explicada pela etiquetagem feita manualmente. As retinografias utilizadas não foram etiquetadas por um médico ou técnico experiente, podendo existir erros nas classificações empíricas efetuadas. Inclusive, a sensibilidade do algoritmo pode ser diferente da sensibilidade do encarregado pela triagem manual, havendo discordância entre a classificação manual e a classificação automática. De mencionar, que os indicadores em análise (cor, foco, contraste, iluminação) são muito suscetíveis às condições ambiente em que estão a ser analisados (nomeadamente o ecrã do computador a ser utilizado, a luz da sala, entre outros aspetos), podendo alterar a qualificação dos mesmos.

Também tem influência o facto do algoritmo de setorização exigir uma fase de pré-processamento para localizar os componentes do olho em estudo. Caso o algoritmo de deteção receba uma imagem com qualidade muito negativa (imagens muito escuras ou claras, mau enquadramento, entre outras circunstâncias), o algoritmo não consegue detetar e/ou delimitar corretamente as regiões. Consequentemente, as imagens a serem processadas têm de ter qualidade suficiente para o disco ótico e/ou a fóvea serem bem localizados. Também é por este motivo que existe um número de retinografias irregular entre classes do mesmo classificador, particularmente quando as regiões do disco ótico e da fóvea são avaliadas. A dependência noutro algoritmo de pré-processamento também provoca o aumento significativo do tempo de computação.

Apesar dos obstáculos referidos, é possível admitir que o balanço final é positivo: o algoritmo de setorização segmenta corretamente as retinografias e, no geral, recorrendo às imagens de teste os classificadores propostos obtiveram melhor performance que os classificadores concebidos por Dias *et al.*

# Capítulo 6

## Método de Classificação de Artefactos em Retinografias

A classificação da qualidade de retinografias tem recebido um aumento de destaque na comunidade de processamento de imagens médicas. Em particular, a deteção e classificação de artefactos desempenha um papel importante na melhoria da aquisição de imagens da retina em ambientes de rastreio médico.

De igual forma, redes neuronais convolucionais têm alcançado bastante sucesso na área de processamento de imagens, sendo uma técnica de alto desempenho e exatidão em comparação com outros métodos conhecidos. Este tipo de redes é constituído por várias camadas convolucionais ocultas, em que cada camada recebe dados com três dimensões: altura, largura e profundidade (número de canais das imagens de entrada). Cada camada tem um número de neurónios com pesos e polarizações específicos que durante o treino são atualizados. Após o treino da rede e durante a classificação de uma imagem, a última camada devolve os valores de avaliação relativos a cada classe. A vantagem deste tipo de classificadores a todos os outros é que os dados alimentados à rede podem ser imagens, não havendo necessidade de determinar descritores manualmente e reduzindo a quantidade de parâmetros de uma rede.

Neste âmbito, é apresentada uma rede neuronal convolucional projetada para classificar vários tipos de artefactos. Para atingir tal objetivo, foram realizados vários estudos de forma a obter a arquitetura de rede ideal. Este capítulo foca-se na descrição do modelo de aprendizagem profunda concebido.

### 6.1 Método Proposto

A rede implementada recebe uma retinografia e classifica a imagem consoante os artefactos presentes. A fotografia em análise pode ser catalogada de acordo com as seguintes classes: imagem desfocada ("Desf."), contendo sobreposição luminosa ("M. Luz"), iluminação insuficiente ("P. Luz"), possuindo marcas de reflexão da luz ("Artef.") ou imagem com boa qualidade ("Boas"). As imagens disponíveis para testar cada classe mencionada,

estão representadas na tabela 4.1. A estas retinografias foram adicionadas 200 fotografias do banco de imagens Messidor e 216 de um outro banco de imagens proprietário, como referido na secção 5.1.1.

Os testes foram efetuados com um modelo CNN que utilizava o algoritmo de *backpropagation*, que recebia dados de entrada com dimensões 256x256x3, e devolvia os valores que representavam a probabilidade de a imagem pertencer a cada uma das classes mencionadas. Para o efeito, várias configurações e parametrizações da rede foram avaliadas. Esta secção descreve os detalhes da metodologia aplicada.

### 6.1.1 Preparação do Conjunto de Imagens de Treino e Teste

O tratamento das imagens antes do treino a realizar pela rede é crucial. O conjunto de imagens de treino deve consistir num grupo abundante e suficientemente distinto de retinografias, de forma a que o algoritmo de aprendizagem esteja apto para identificar as diferentes características específicas de cada classe.

Com objetivo de proporcionar os melhores resultados, foram realizadas várias etapas de pré-processamento. A primeira etapa realizada foi efetuar o corte das imagens de forma a diminuir o número de pixéis irrelevantes. A partir da máscara calculada, foi criada uma caixa quadrada delimitadora à volta da FOV da retinografia. O corte foi executado utilizando uma margem de 10 pixéis.

Seguidamente, as imagens foram dimensionadas com resolução 256x256x3 utilizando interpolação bicúbica, de maneira a corresponder à dimensão de entrada da primeira camada.

Para aumentar o número de retinografias em cada categoria, foram implementadas operações de aumento de dados. Estas operações geram imagens artificiais recorrendo a operações de transformação de imagem, i.e. rotações e reflexões. Foram aplicadas operações de reflexão horizontal e vertical, rotações de 45° e -45° e foram determinadas 5 matrizes transformação diferentes para serem multiplicadas à imagem. No total, o conjunto de imagens disponível foi aumentado 9 vezes. Foram selecionadas 4000 imagens por categoria de forma a que o número de dados por classe fosse equivalente.

De maneira a facilitar a aprendizagem, os dados foram normalizados para que os mesmos fossem centrados em zero. Este procedimento normaliza as dimensões dos dados de modo a que estejam todos na mesma escala. A interpretação geométrica desta alteração corresponde na concentração da nuvem de dados na origem ao longo de todas as dimensões.

No contexto das redes neuronais, é aconselhada a divisão em três conjuntos de imagens, nomeadamente em conjunto de treino, validação e teste. Com este propósito, todas as imagens foram baralhadas para evitar amostras excessivamente correlacionadas e foram agrupadas: 60% em conjunto de treino, 20% em conjunto de validação e 20% em conjunto de teste. A imagem 6.1 representa todas as etapas de pré-processamento.

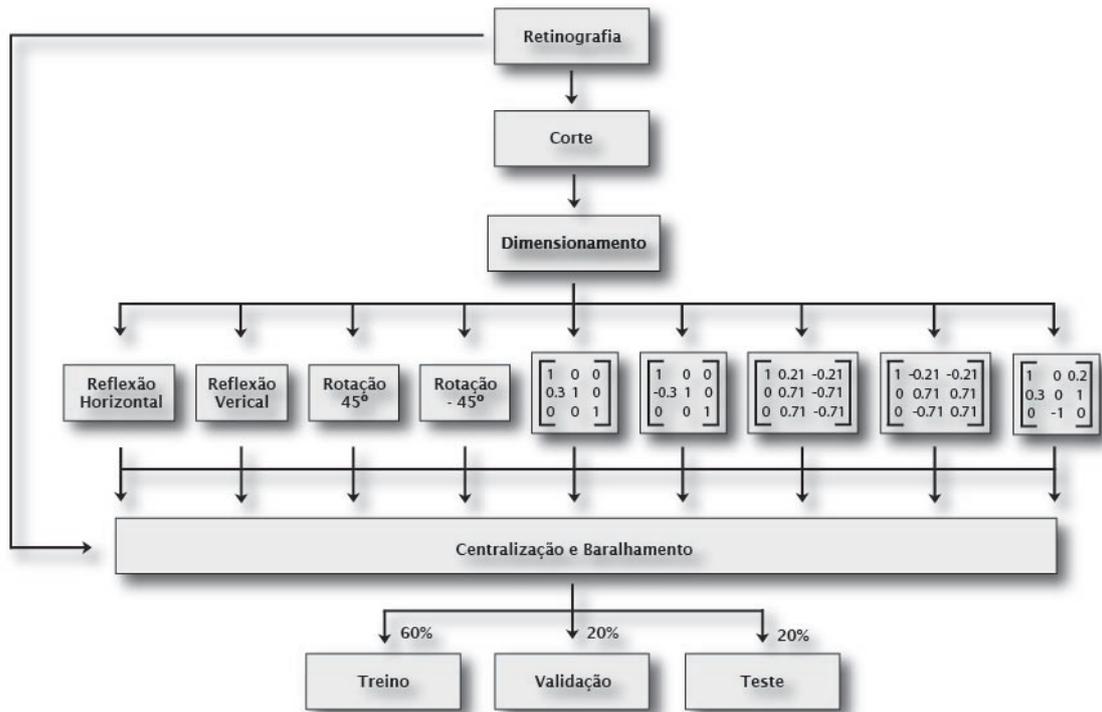


Figura 6.1: Diagrama que descreve as fases de pré-processamento executadas.

### 6.1.2 Modelo

Uma das finalidades deste projeto foi planejar uma rede neuronal convolucional e ajustar os parâmetros associados, de forma a classificar automaticamente artefactos em retinografias. Por conseguinte, a seleção adequada da arquitetura e dos parâmetros é fundamental para atingir o objetivo proposto.

A arquitetura, o número, tipo e disposição das camadas foi alvo de pesquisa intensa. Nomeadamente, o arranjo das camadas convolucionais, de *pooling* e camadas completamente conectadas foi objeto de estudo de forma a garantir os melhores resultados.

O modelo final é constituído por quatro camadas convolucionais e quatro camadas completamente conectadas, incluindo a camada de classificação. Imediatamente a seguir a todas as camadas convolucionais, é introduzida uma camada de normalização de amostra. Esta camada impõe que todas as ativações dos neurónios tenham uma média próxima de zero e o desvio padrão próximo de um. Esta operação permite acelerar a aprendizagem e estabilizar o modelo.

É aplicada uma unidade de retificação linear, exceto na última camada de classificação. Esta função de ativação define a saída de cada nó consoante a sua entrada, alterando todos os valores negativos para zero e os restantes são mantidos constantes.

Imediatamente a seguir, é colocada uma camada de *pooling* máximo nos conjuntos convolucionais. Esta camada calcula o máximo em regiões não sobrepostas dos valores da camada com o intuito de diminuir o número de parâmetros da rede e consequentemente o custo computacional. Também permite que não ocorra o sobre-ajuste dos parâmetros do modelo.

Para esta operação foi definido um filtro com dimensões 2x2 e um passo de 2 pixéis.

Em cada camada completamente conectada, foi utilizado *dropout*, com probabilidade de 0.5. Esta técnica de regularização é realizada durante o treino, colocando neurónios a zero aleatoriamente. A probabilidade mencionada representa a percentagem de neurónios da camada que se mantêm ativos.

A última camada de classificação usa uma função de ativação *softmax*, que divide todas as saídas de forma a que o seu somatório equivalha uma unidade. A saída desta função representa uma distribuição de probabilidade multi-classe, indicando a probabilidade de cada classe ser verdadeira. Na medida em que a avaliação é feita tendo em conta cinco categorias, esta função vai devolver cinco probabilidades.

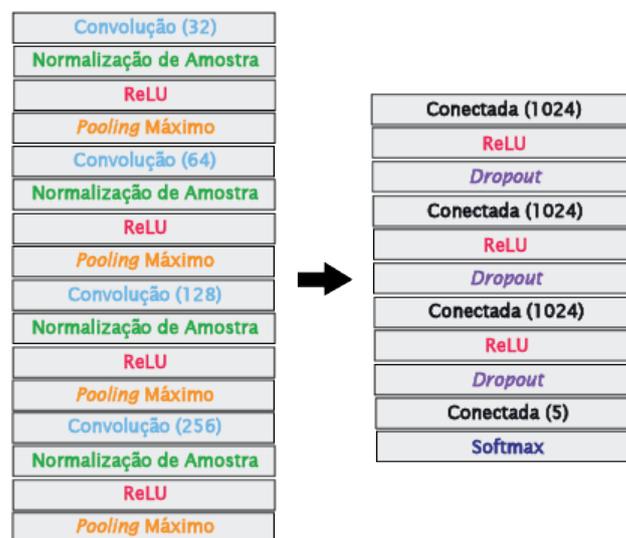


Figura 6.2: Modelo da Rede Neuronal Convolucional proposto.

Definida a arquitetura da rede, foram estipulados os valores dos parâmetros restantes. No âmbito deste projeto, foram atribuídas diferentes especificações para cada camada convolucional. A primeira camada possui 32 filtros com dimensões 3x3 cada um, a segunda possui 64 filtros com dimensões 5x5, a terceira 128 filtros com dimensões 7x7 e a última contendo 256 filtros com dimensões 3x3. Esta configuração foi conseguida recorrendo a vários testes. A descrição dos testes efetuados encontra-se exposta na tabela apresentada no capítulo D. Todas as camadas têm preenchimento de 1 e passo 1, à exceção da terceira que tem passo igual a 2.

A função de inicialização dos pesos consiste numa distribuição gaussiana com média igual a zero e desvio padrão de 0.01, ao passo que as polarizações são iniciadas a zero.

A seleção do valor da taxa de aprendizagem foi alvo de bastante estudo. Este parâmetro é extremamente importante, pois este valor influencia o comportamento da rede neuronal em vários aspetos. Essencialmente, este indicador representa a rapidez com que uma rede ajusta os seus parâmetros e, conseqüentemente, a rapidez da aprendizagem. Caso o valor seja muito baixo, o progresso vai ser lento, mas se for demasiado elevado, irá provocar o comportamento

indesejado da função de perda. Desta forma, após vários testes, foi atribuído o valor de 0.001 inicial e na trigésima época o valor reduz para 0.0001.

Relativamente ao número de épocas, foram definidas 40. Esta medida representa um ciclo completo de treino, ou seja, uma época consiste no treino de todas as amostras uma única vez.

O número de imagens que propaga na rede influencia o tempo de computação, na medida em que se este número for muito elevado o algoritmo é mais rápido. No entanto, um valor maior requer mais exemplos para lidar com o mesmo erro, pois são feitas menos atualizações por época. Logo, a dimensão do conjunto de amostras corresponde a 64 unidades.

Neste modelo foi utilizado um valor de 0.0005 para o termo de regularização L2. Esta medida é utilizada para prevenir que o modelo esteja ajustado demasiado bem ao conjunto de treino, sendo ineficaz na avaliação do conjunto de teste.

O otimizador escolhido foi o Adam. Efetivamente, foram realizados testes utilizando este tipo de otimizador e o método *Momentum*, tendo o primeiro atingido melhor performance. Basicamente este tipo de operações minimiza a função de perda. No entanto, o otimizador Adam mantém a taxa de aprendizagem para cada parâmetro, adaptando-a separadamente ao longo da aprendizagem.

Por último, a função de perda escolhida foi a função de perda de entropia cruzada (*cross entropy loss*). Normalmente utilizada em conjunto com a função *Softmax*, quantifica a diferença entre duas distribuições probabilísticas, nomeadamente a diferença entre os valores pressupostos e os valores reais da distribuição de saída.

A tabela 6.1 sumariza os valores dos parâmetros configurados para o modelo apresentado na figura 6.2.

Parâmetro	Valor
<i>Dropout</i>	0.5
Taxa de Aprendizagem	0.001 até à 30 época
Épocas	40
Dimensão do Conjunto das amostras	64
Regularização L2	0.0005
Otimizador	Adam

Tabela 6.1: Parâmetros utilizados e os valores correspondentes.

## 6.2 Resultados e Discussão

Esta secção é dedicada à exposição dos resultados mediante o modelo da rede neuronal convolucional proposto na secção anterior. A performance do método apresentado é avaliada

de acordo com a medida de exatidão representada pela equação 6.1, as medidas de sensibilidade 5.4, especificidade 5.5, precisão 5.6 e a matriz confusão multi-classe mencionada na secção 5.2. O conjunto de treino contém 2400 imagens para cada classe, o de validação e o de teste contêm 800, totalizando em 20000 imagens disponíveis. Os resultados adquiridos são distribuídos pelas secções seguintes consoante o parâmetro em estudo. Uma descrição mais detalhada das especificações dos testes efetuados encontra-se exposta na tabela apresentada no capítulo D.

$$exatidão = \frac{TP + TN}{TP + TN + FP + FN} \quad (6.1)$$

### 6.2.1 Taxa de Aprendizagem

A tabela 6.2 expõe os resultados adquiridos dos 6 testes realizados para definir o melhor valor de taxa de aprendizagem. Para testar esta medida foi utilizado o modelo projetado na secção 6.1.2. Todos os ensaios realizados recorreram às mesmas imagens e aos mesmos valores de parâmetros, tal como estão expostos na tabela 6.1, à exceção da taxa de aprendizagem. Esta experiência foi uma das primeiras a realizar devido à importância desta medida no bom desempenho da rede. Observando a tabela em baixo apresentada, é possível constatar que o melhor valor obtido foi de 0.001 com redução para 0.0001 na trigésima época.

Número	Taxa de Aprendizagem	Exatidão do conjunto de Validação	Tempo
1	0.01	0.4993	1h 49 min
2	0.001	0.7593	1h 48 min
3	0.0001	0.7432	1h 49 min
4	0.001 até à 10 época	0.7670	1h 49 min
5	0.001 até à 20 época	0.7660	1h 49 min
6	0.001 até à 30 época	0.7745	1h 50 min

Tabela 6.2: Valores de taxa de aprendizagem testados e os respetivos valores de exatidão, utilizando o modelo de CNN apresentado na figura 6.2.

### 6.2.2 Épocas

O número de épocas também foi sujeito a análise. Para tal, foi utilizado o modelo mencionado na secção 6.1.2. Todas as experiências realizadas recorreram às mesmas imagens e aos mesmos valores dos parâmetros, tal como estão expostos na tabela 6.1, à exceção do número de épocas. A tabela 6.3 expõe os resultados adquiridos sendo visível que a diferença entre os valores de exatidão consoante o número de épocas não é muito significativo. No entanto, o tempo de processamento aumenta excessivamente como esperado. Na escolha do valor ideal deve ser tomado em consideração o facto de que o incremento do número épocas pode causar o sobre-ajuste do modelo, sendo necessário analisar os gráficos de exatidão

e de perda para detetar quando a aprendizagem deixa de ser realizada. Desta forma, e consultando os valores obtidos, foram consideradas 40 épocas.

Número	Época	Exatidão do conjunto de Validação	Tempo
1	20	0.76	56 min
2	40	0.769	1h 48 min
3	60	0.7585	2h 43 min

Tabela 6.3: Números de épocas testados e os respetivos valores de exatidão, utilizando o modelo de CNN apresentado na figura 6.2.

### 6.2.3 Dimensão dos Conjuntos

Como mencionado na secção anterior, o número elevado da dimensão do conjunto de amostras influencia a performance do treino da rede. Inclusive, valores relativamente baixos do parâmetro em estudo, combinados com uma taxa de aprendizagem em decaimento, garante convergência de longo prazo enquanto mantem a possibilidade de sair de mínimos locais encontrados inicialmente. Desta forma, este parâmetro requer alguma atenção. Para testar esta medida foi utilizado o modelo projetado na secção 6.1.2. Todos os ensaios realizados recorreram às mesmas imagens e aos mesmos valores dos parâmetros, tal como estão expostos na tabela 6.1, à exceção da dimensão de conjunto de amostras. A tabela 6.4 apresenta os resultados adquiridos. O número que garante o melhor desempenho é 64 amostras por ciclo de treino.

Número	Dimensão dos Conjuntos	Exatidão do conjunto de Validação	Tempo
1	32	0.7638	1h 46 min
2	64	0.7715	1h 44 min
3	128	0.7710	1h 45 min

Tabela 6.4: Valores da dimensão dos conjuntos de amostras testados e os respetivos valores de exatidão, utilizando o modelo de CNN apresentado na figura 6.2.

### 6.2.4 Regularização L2

Este termo tende a forçar o valor reduzido dos pesos da rede. Mais concretamente, a regularização efetuada tenta encontrar um compromisso entre pesos pequenos e uma função de perda minimizada de forma a que não ocorra o sobre-ajuste do modelo. Logo, alguns testes foram realizados utilizando o modelo projetado na secção 6.1.2. Todos os ensaios realizados recorreram às mesmas imagens e aos mesmos valores dos parâmetros, tal como

estão expostos na tabela 6.1, à exceção do valor do termo de regularização L2. A tabela 6.5 expõe os resultados adquiridos e foi alcançada a melhor performance utilizando um valor de 0.0005.

Número	Regularização L2	Exatidão do conjunto de Validação	Tempo
1	0.0001	0.758	1h 51 min
2	0.0005	0.7745	1h 51 min
3	0.001	0.7635	1h 51 min

Tabela 6.5: Valores de Taxa de Aprendizagem testados e os respetivos valores de exatidão, utilizando o modelo de CNN apresentado na figura 6.2.

### 6.2.5 Teste do Modelo

O modelo foi treinado utilizando os valores dos parâmetros obtidos do estudo desenvolvido na secção anterior.

Os passos de pré-processamento foram aplicados a todas as imagens, permitindo que a rede treinasse com 12000 imagens, categorizadas como mencionado previamente. Tanto o conjunto de validação como o de teste dispuseram de 800 imagens por classe.

Por conseguinte o modelo proposto alcançou 80.4% de exatidão no conjunto de validação e o tempo de treino foi de 1 hora e 49 minutos. Para o conjunto de validação foi obtida a matriz confusão representada na tabela 6.6. Em relação ao conjunto de teste, a exatidão foi de 77.32%, resultando na matriz confusão 6.7.

		Previsto				
		Artef.	Boas	Desf.	M. Luz	P. Luz
Real	Artef.	584	2	103	68	43
	Boas	0	799	0	0	1
	Desf.	26	1	693	52	28
	M. Luz	14	0	24	643	119
	P. Luz	22	2	27	252	497

Tabela 6.6: Matriz confusão relativa ao conjunto de validação.

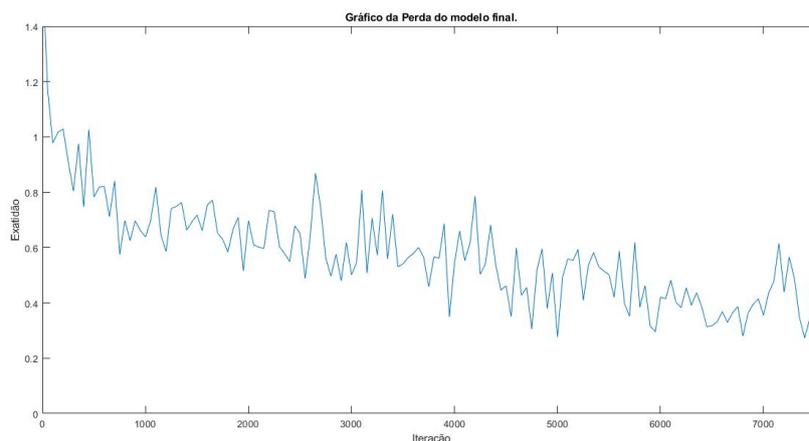
Como é possível observar na tabela 6.9, utilizando o grupo de imagens de teste, foi obtida uma precisão para a classe "Boas" de 0.9913, uma sensibilidade de 0.99375 e uma especificidade de 0.9981. Considerando que os outros valores não foram ideais, é possível dividir estes resultados em duas classes globais que avaliam apenas a presença de artefactos. Nesta situação, a performance deste modelo é considerada excelente. A figura 6.3 relata o desempenho durante o treino da rede em estudo.

		Previsto				
		Artef.	Boas	Desf.	M. Luz	P. Luz
Real	Artef.	553	0	133	70	44
	Boas	1	795	0	0	4
	Desf.	39	0	664	52	45
	M. Luz	25	0	23	621	131
	P. Luz	25	7	56	252	460

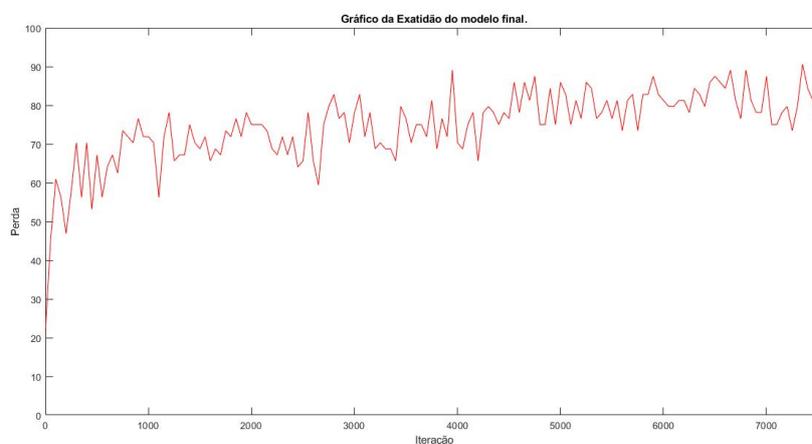
Tabela 6.7: Matriz confusão relativa ao conjunto de teste.

	"Art."	"Boas"	"Desf"	"M. Luz"	"P. Luz"
Sensibilidade	0.73	0.9988	0.8662	0.8037	0.5959
Especificidade	0.9868	0.9984	0.9534	0.8838	0.9403
Precisão	0.8985	0.9938	0.8182	0.6335	0.7224

Tabela 6.8: Valores das medidas resultantes da matriz confusão 6.6.



(a)



(b)

Figura 6.3: Gráficos da perda(a) e da exatidão(b) obtidos no treino da rede em estudo.

	"Art."	"Boas"	"Desf"	"M. Luz"	"P. Luz"
<b>Sensibilidade</b>	0.6913	0.9938	0.83	0.7763	0.575
<b>Especificidade</b>	0.9654	0.9981	0.9337	0.8824	0.9296
<b>Precisão</b>	0.86	0.9913	0.758	0.6241	0.6725

Tabela 6.9: Valores das medidas resultantes da matriz confusão 6.7.

## 6.2.6 Discussão

Neste tipo de algoritmos existe a possibilidade de encontrar vários obstáculos, no entanto o mais crítico é a restrição de memória. Existindo limitação de memória o número e disposição das camadas da rede são afetados, tal como a escolha de certos parâmetros, como o número de épocas. Inclusive, as imagens de treino são dos componentes mais importantes para a conceção deste tipo de métodos, e existindo estes problemas, não é possível recorrer a um grupo de dados suficientemente abundante e variado para melhorar a performance do modelo. No caso em estudo, as imagens tiveram de ser reduzidas para o tamanho 256x256x3 para existirem mais opções de arquiteturas a testar. Ainda foi ponderado apenas utilizar um dos canais da imagem, mas na medida em que estão a ser classificados artefactos que facilmente são confundidos com componentes morfológicos da retina e estes são distinguidos pela sua cor e intensidade, esta premissa não foi abordada.

O erro observado nas classificações pode ser justificado pelo facto de as imagens que contêm artefactos normalmente possuem mais que um presente. Caso não existam diferentes casos do artefacto isolado, pode ser introduzido erro na classificação pois torna-se difícil aprender as características que definem cada irregularidade.

De lembrar o mencionado na seção 5.2.4, pois também se aplica neste caso. A etiquetagem de todas as imagens foi feita manualmente e não foram categorizadas por um médico ou especialista. Esta circunstância também pode prejudicar o desempenho deste algoritmo.

Contudo, é possível admitir que foram obtidos resultados razoáveis. Inclusive, em ambiente de teste, foi obtida uma precisão para a classe "Boas" de 0.9913, uma sensibilidade de 0.99375 e uma especificidade de 0.9981, valores muito próximos de 1. Desta forma, na medida em que as outras classes que indicam a presença de artefactos não possuem valores tão favoráveis, é possível admitir duas classes globais: uma que assinala a presença de artefactos e outra que indica a sua ausência e assim obter resultados próximos do máximo admissível. Além do mais, a rede proposta veio a contribuir no âmbito da classificação multi-classe de artefactos, pois não existem muitos trabalhos científicos dedicados a este tema.

# Capítulo 7

## Conclusão e Trabalho Futuro

Esta dissertação apresenta dois métodos associados à avaliação de qualidade de imagens do fundo do olho. O primeiro algoritmo mencionado corresponde na alteração do método proposto por Dias *et al.* de forma a serem analisados setores morfológicos da retina individualmente. Para além de ter sido introduzido o procedimento de segmentação da retina, foi elaborado um estudo da seleção dos raios para delimitar as secções e certos aspetos referentes aos classificadores originais foram alterados. Nomeadamente, foram treinados novos classificadores e foram adicionados descritores de textura, de forma a adaptar o algoritmo inicial às diferentes características dos componentes oculares em estudo.

Feita a análise dos resultados obtidos executando o método acima referido, é possível observar que estes não são os valores ideais. No entanto, comparando os mesmos com os resultados adquiridos a partir da técnica desenvolvida por Dias *et al.*, utilizando as mesmas imagens de teste, o algoritmo proposto nesta tese atinge uma melhor performance. Contudo, o método apresentado acaba por ter custos computacionais, visto que depende de um outro algoritmo para efetuar a setorização. Inclusive, este procedimento requer a verificação manual, e conseqüente catalogação, das imagens devolvidas.

De facto, toda a categorização das imagens da retina utilizadas nesta tese, não foi efetuada por um médico ou técnico oftalmólogo. Desta forma, foi introduzido erro associado a esta triagem, principalmente quando avaliada a seleção de retinografias relativamente à sua cor, foco, contraste, iluminação e qualidade global, na medida em que estes indicadores genéricos de imagem são muito sensíveis às condições do ambiente de classificação.

Caso seja pretendido utilizar o algoritmo de setorização concebido para avaliar imagens do fundo do olho, devem ser realizadas alterações mais profundas neste projeto. Nomeadamente, o modo como os descritores são calculados. Os setores em estudo (disco ótico e fóvea), são zonas do olho com aspetos visuais característicos, e os descritores utilizados para avaliar estas zonas têm de ter esses aspetos em consideração. Possivelmente será necessário alterar os indicadores utilizados na avaliação destas secções, i. e. repensar na utilização do foco para avaliar a seção da fóvea, pois esta trata-se de uma região pequena, escura e sem vasos, confundida muito facilmente por uma zona desfocada, ou a forma como a cor é medida

quando é avaliado o disco ótico, sendo que esta região é mais clara que o resto da retina.

A segunda técnica exposta neste trabalho, corresponde no projeto de uma rede neuronal convolucional para classificar artefactos presentes em retinografias. Com este intuito, foram consideradas as seguintes classes distintas: imagens contendo artefactos de reflexão de luz, imagens desfocadas, contendo sobreposição luminosa, iluminação insuficiente ou imagens com boa qualidade. Após várias tentativas, o modelo foi definido e foi efetuado o estudo de alguns parâmetros da rede. Finalmente, foi testado o modelo considerando os parâmetros finais resultantes dos estudos realizados.

Dos obstáculos encontrados na projeção deste método, o que causou mais impacto foi a restrição de memória. Esta limitação influenciou o número, disposição das camadas e os valores dos parâmetros associados. Inclusive, o tamanho das imagens alimentadas ao algoritmo foi diminuído de forma a permitir o seu processamento, e o número de retinografias propagadas na rede em cada ciclo era relativamente baixo. Contudo, o uso de uma GPU permitiu aumentar o número de imagens processadas e diminuir em grande parte o tempo de treino. Para além das dificuldades mencionadas anteriormente, também convém referir que o projeto de uma rede neuronal passa por inúmeras tentativas e erros até produzir os resultados desejados.

Porém, é razoável afirmar que foram obtidos resultados positivos e que o projeto contribuiu para o desenvolvimento de redes neuronais convolucionais no contexto de classificação de artefactos, na medida em que estudos abordando este tema são escassos. Todavia, alterações podem vir a ser feitas para melhorar a sua performance. Nomeadamente, aumentar o número de imagens de treino e a sua variedade. Para o efeito, também deve ser considerado recorrer a múltiplos GPUs para diminuir o tempo de treino e ser possível aumentar em número e dimensões as imagens utilizadas. Relativamente a melhorias futuras para o método de aprendizagem profunda proposto, poderá passar pelo aumento do número de classes de artefactos ou a deteção e segmentação das irregularidades consideradas, de forma a melhorar a experiência de aquisição de retinografias em ambiente de rastreio médico.

Concluindo, o objetivo principal deste trabalho foi a pesquisa e criação de dois métodos associados ao estudo de qualidade de imagens do fundo do olho. Apesar de avaliarem aspetos distintos, ambos os métodos enunciados melhoram o ato de aquisição de retinografias em rastreios oftalmológicos, facilitando o processo de diagnóstico. Inclusive, os dois contribuíram para a pesquisa de soluções relacionadas com a classificação de qualidade de imagem e de artefactos, respetivamente. Todo o projeto de pesquisa desta dissertação contém informações relevantes sobre o estudo da qualidade de retinografias e das patologias encontradas na retina, sendo útil para a realização de estudos futuros.

# Apêndice A

## Avaliação da qualidade de retinografias usando indicadores genéricos de qualidade de imagem

Conforme já referido, este documento tem como base o trabalho de Dias *et al.* [9] apresentado em 2014. O trabalho referido consiste num algoritmo de avaliação de qualidade de imagens da retina usando indicadores genéricos com excelente desempenho e computacionalmente eficiente. Por conseguinte, este é considerado o método de aprendizagem automatizada tradicional com melhor performance registada. Este apêndice descreve minuciosamente este estudo e os seus resultados.

### Materiais

Na totalidade, foram utilizadas 2032 imagens provenientes de quatro bancos de imagens públicos distintos e de outros dois bancos de imagens privados. As imagens provenientes dos bancos de imagens privados resultaram de exames médicos feitos em Portugal e na Índia. Consequentemente, estas imagens diferem entre si em termos de resolução e de campo de visão.

### Algoritmo

O algoritmo em estudo divide-se nas seguintes fases sequenciais: uma fase inicial de pré-processamento das imagens, em seguida a avaliação dos quatro indicadores genéricos, a fusão da informação resultante destes indicadores e uma classificação final da retinografia. A classificação final determina se uma imagem é classificável ou não classificável.

## Pré-Processamento

Nesta fase, as imagens são mascaradas e cortadas para eliminar irregularidades indesejadas na imagem e para diminuir o tempo de computação.

Numa primeira etapa a imagem é binarizada utilizando o valor limiar obtido através de um estudo estatístico com 361 imagens. Esta pré-máscara é processada usando duas aberturas morfológicas resultando na máscara final.

Na segunda etapa, é utilizada a máscara para delimitar uma caixa à volta da região de interesse (ROI) na imagem. Em seguida, a retinografia é cortada consoante os limites desta caixa.

## Algoritmo de Avaliação da Cor

Esta avaliação resulta em três classes de cor de imagens: “Claras” (“*Bright*”), “Escuras” (“*Dark*”) ou “Normais” e é iniciada com um procedimento de indexação de cor recorrendo a uma retroprojeção de histograma. Para o efeito, foram criados mapas de cor a partir dos conjuntos de imagens de treino de cada classe. Estes mapas são utilizados para efetuar indexação de cores da imagem de teste, originando três imagens indexadas distintas. Posteriormente, os valores médios destas imagens resultantes são determinados, originando três medidas de cor ( $C_1$ ,  $C_2$ ,  $C_3$ ) relativas a cada classe.

## Algoritmo de Avaliação do Foco

O foco de uma imagem pode ser classificado como “Desfocadas” (“*Blurred*”), “Limite” (“*Borderline*”) e “Focadas” (“*Focused*”), assim este algoritmo tem três fases. Na primeira fase é aplicado o operador de Sobel à imagem cinza e a primeira medida de foco ( $F_1$ ) resulta na média do mapa resultante. Em seguida é aplicado um filtro passa baixo de média móvel 3 por 3 na imagem cinza, seguido pela utilização do operador de Sobel e a primeira medida de informação de foco ( $f_1$ ) é obtida através da média do mapa resultante.

A segunda fase consiste na aquisição da segunda medida de foco ( $F_2$ ) obtida pela subtração entre as duas medidas anteriormente calculadas. É aplicado novamente um filtro passa baixo de média móvel 5 por 5 na imagem cinza, seguido pela utilização de um operador de Sobel e a segunda medida de informação de foco ( $f_2$ ) é obtida através da média do mapa resultante. A última medida ( $F_3$ ) é obtida pela diferença entre as duas medidas de informação de foco ( $f_1 - f_2$ ).

## Algoritmo de Avaliação do Contraste

Relativamente ao contraste, uma imagem retiniana é avaliada possuindo contraste “Baixo” (“*Low*”) ou “Alto” (“*High*”). Este algoritmo começa por uma retroprojeção de histograma para originar uma imagem indexada. O mapa de cor utilizado neste passo foi obtido através

de um estudo estatístico efetuado com 170 imagens. A partir deste mapa é obtido um histograma com 16 barras.

A primeira medida ( $Ct_1$ ) corresponde na soma da diferença absoluta entre a percentagem de pixéis em cada barra do histograma e a percentagem de um histograma com distribuição uniforme ( $100\%/16 = 6.25\%$ ). A segunda medida ( $Ct_2$ ) é o número de barras do histograma com 0% de pixéis. Seguidamente, é aplicado um filtro de média móvel 3 por 3 na imagem indexada. Utilizando a imagem filtrada, as medidas  $Ct_3$  e  $Ct_4$  são calculadas da mesma forma que as medidas  $Ct_1$  e  $Ct_2$  respetivamente.

## Algoritmo de Avaliação da Iluminação

Este algoritmo avalia a iluminação numa imagem como “Irregular” (“*Uneven*”) ou “Regular” (“*Even*”). Esta abordagem utiliza indexação de cor e o mapa de cor utilizado é proveniente do MATLAB<sup>®</sup>, após a cor azul escura ter sido substituída pelo preto.

O algoritmo começa por efetuar uma retroprojeção de histograma utilizando o mapa de cor para produzir uma imagem indexada. Desta imagem resultam quatro medidas de iluminação. A primeira medida ( $I_1$ ) corresponde na média da imagem indexada, a segunda e terceira medida ( $I_2$  e  $I_3$ ) são a variância do conjunto de pixéis cujo o índice seja inferior ou superior que  $I_1$  respetivamente e a quarta medida ( $I_4$ ) é a variância da imagem total indexada.

## Classificação de Qualidade de Imagem

A fusão das catorze medidas obtidas a partir dos quatro algoritmos anteriormente descritos vai dar origem na classificação final de qualidade da imagem, sendo que esta classificação pode qualificar uma imagem como “Não classificável” (“*Ungradable*”) ou “Classificável” (“*Grgradable*”), como é possível verificar na imagem A.1.

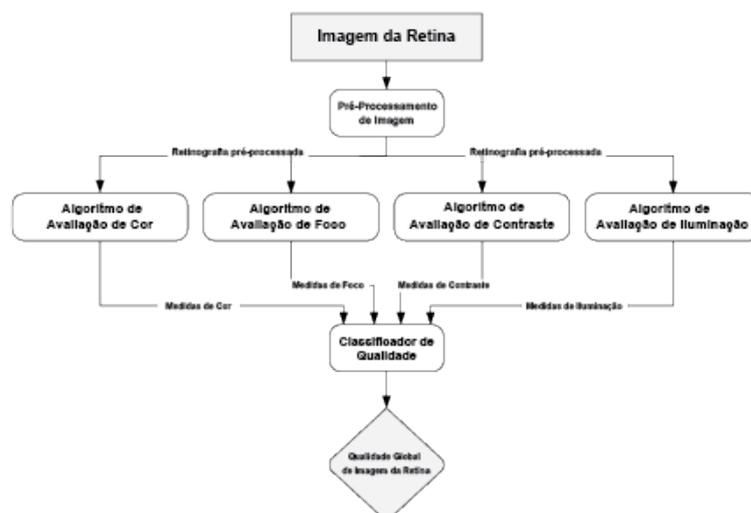


Figura A.1: Fluxograma do algoritmo proposto por Dias *et al.*. Adaptado de [9].

Tanto a classificação final de qualidade como as outras quatro classificações de indicadores genéricos (cor, foco, contraste e iluminação) são adquiridas através da aplicação de técnicas de aprendizagem automatizada. Para o efeito, foram testados quatro classificadores diferentes para cada algoritmo de avaliação de indicadores genéricos: A rede neuronal FFB (Feed-Forward Backpropagation), a rede com função de base radial, o classificador KNN (K-Nearest Neighbours) e o classificador SVM.

No entanto este último classificador não foi testado para produzir a classificação global. Para cada uma das abordagens, foram utilizadas arquiteturas com diferentes parâmetros internos. No treino foi aplicada validação cruzada *4-fold* e foram utilizadas 75% das imagens no treino e 25% das imagens no teste.

## Resultados

Para avaliar a performance destes classificadores, foram utilizadas duas medidas: a sensibilidade e a especificidade. Dado que dois dos algoritmos de avaliação de indicadores genéricos (Cor e foco) produzem três classes em vez de duas, estas medidas não podem ser aplicadas diretamente nestes casos. Assim, nas decisões não binárias foi utilizada uma abordagem em que uma das classes era considerada a classe correta e as outras duas eram agregadas e consideradas incorretas. No caso da cor a classe correta é “Normal” enquanto as outras duas (“Clara” e “Escura”) são consideradas incorretas. Da mesma forma, no foco, a classe correta corresponde na classe “Focada”.

Um dos requisitos para um método de classificação de qualidade de imagens robusto, é que a sua performance não deve ser influenciada pela diferença entre as resoluções de imagem. Logo, é essencial estudar o efeito das diferentes resoluções nos desempenhos dos classificadores e nos valores das catorze medidas referentes aos algoritmos de avaliação de indicadores genéricos. Consequentemente, Dias *et al.* realizou um estudo estatístico que, utilizando um conjunto de 20 imagens respetivo a cada uma das 14 classes, conduziu a 3 tipos experiências com medidas distintas: uma utilizando as imagens originais, outra usando metade da área das imagens originais e uma terceira com o dobro da área das imagens originais. Para o propósito deste trabalho, estes resultados não são relevantes, logo não vão ser discutidos.

Além disso também foram analisados os requisitos computacionais do algoritmo de forma a que o mesmo não compromettesse a capacidade de ser utilizado em sistemas de tempo real e em ambientes em que as fontes de energia são fracas ou instáveis. Os resultados destas duas avaliações serão discutidos de seguida.

### Algoritmo de Avaliação da Cor

Utilizando 100 imagens classificadas com cor “Claras”, 100 com cor “Escuras” e 300 com cor “Normais”, os melhores resultados foram obtidos por uma rede neuronal FFB com 10

neurônios na camada escondida. Considerando as classes “Claras” e “Escuras” como as classes incorretas e a classe “Normais” como sendo correta, foi obtida uma área ROC de 0.9993 e foram obtidos os valores de sensibilidade e especificidade relatados na tabela A.1.

<b>Cor</b>	"Claras" (%)	"Escuras" (%)	"Normais" (%)
Sensibilidade	99.00 ± 0.00	98.80 ± 0.42	100.00 ± 0.00
Especificidade	100.00 ± 0.00	100.00 ± 0.00	98.90 ± 0.21

Tabela A.1: Desempenho do classificador de cor proposto por Dias et al. [9].

## Algoritmo de Avaliação do Foco

Na avaliação do classificador de foco, foram utilizadas 120 imagens classificadas com o foco “Desfocadas”, 120 com o foco “Limite” e 200 com o foco “Focadas”. A melhor performance foi alcançada utilizando uma rede neuronal FFB com 50 neurônios na camada oculta. Considerando as classes “Desfocadas” e “Limite” como as classes incorretas e a classe “Focadas” como sendo correta, foi obtida uma área ROC de 0.9867 e foram obtidos os valores de sensibilidade e especificidade relatados na tabela A.2.

<b>Foco</b>	"Desfocadas" (%)	"Limite" (%)	"Focadas" (%)
Sensibilidade	97.25 ± 0.79	98.58 ± 1.11	99.60 ± 0.32
Especificidade	98.78 ± 0.26	98.72 ± 0.45	99.58 ± 0.44

Tabela A.2: Desempenho do classificador de foco proposto por Dias et al. [9].

## Algoritmo de Avaliação do Contraste

Relativamente ao contraste, foram utilizadas 85 imagens classificadas com o contraste “Baixo” e 170 com o contraste “Alto”. A melhor performance foi alcançada utilizando uma rede neuronal FFB com 3 neurônios na camada oculta. Considerando a classe “Baixo” como a classe incorreta e a classe “Alto” como sendo correta, foi obtida uma área ROC de 0.9783 e foram obtidos os valores de sensibilidade e especificidade relatados na tabela A.3.

<b>Contraste</b>	"Baixo" (%)	"Alto" (%)
Sensibilidade	94.94 ± 0.79	97.71 ± 0.19
Especificidade	97.71 ± 0.19	94.94 ± 0.79

Tabela A.3: Desempenho do classificador de contraste proposto por Dias et al. [9].

## Algoritmo de Avaliação da Iluminação

Possuindo 200 imagens classificadas com a iluminação “Irregular” e 200 com a iluminação “Regular”, a melhor performance foi alcançada utilizando uma rede neuronal FFB com 4

neurónios na camada oculta. Considerando a classe “Irregular” como a classe incorreta e a classe “Regular” como sendo correta, foi obtida uma área ROC de 0.9984 e foram obtidos os valores de sensibilidade e especificidade relatados na tabela A.4.

<b>Iluminação</b>	"Irregular"(%)	"Regular"(%)
Sensibilidade	99.25 ± 0.54	99.5 ± 0.33
Especificidade	99.5 ± 0.33	99.25 ± 0.54

Tabela A.4: Desempenho do classificador de iluminação proposto por Dias et al. [9].

## Classificação de Qualidade de Imagem

A avaliação do classificador global de qualidade de imagem foi conseguida utilizando 848 imagens classificadas como “Não Classificável” e 1184 imagens com qualidade “Classificável”. Como descrito anteriormente, foram testados vários tipos de classificadores, tendo sendo obtidos os resultados expostos na tabela A.5. Como é possível verificar, os resultados não são muito distintos, no entanto, os melhores valores foram obtidos utilizando uma rede neuronal FFB com 14 neurónios na camada oculta. Por conseguinte, este classificador foi adotado. De igual modo, considerando a classe “Não classificável” como a classe incorreta e a classe “Classificável” como sendo correta, foi obtida uma área ROC de 0.9987.

Classificador	Performance	"Não classificável" (%)	"Classificável" (%)
Rede Neuronal FFB	Sensibilidade	99.76	99.49
	Especificidade	99.49	99.76
Rede com Função de base Radial	Sensibilidade	97.17	99.92
	Especificidade	99.92	97.17
Classificador KNN	Sensibilidade	91.39	95.69
	Especificidade	95.69	91.39

Tabela A.5: Desempenho do classificador global de qualidade proposto por Dias et al. [9].

Como é possível verificar a partir dos resultados expostos, todos os classificadores são quase perfeitos, tendo obtido áreas ROC próximas do valor máximo de 1. Estes valores são muito importantes pois as imagens utilizadas são bastante variadas, consistindo numa amostra proveniente de uma população com diferentes tipos de etnias, grau de patologia presente e equipamento utilizado, consequentemente validando a robustez do algoritmo.

## Tempo de computação

Com fim de quantificar os custos de computação do algoritmo, foi feita uma análise do pior caso possível em termos de custo de computação. Para o efeito, foram utilizadas 456

imagens em que possuíam uma menor percentagem de pixéis de fundo pretos com resoluções diferentes. Foi utilizada uma implementação não otimizada feita no MATLAB<sup>®</sup>, num computador com CPU Intel<sup>®</sup> Core<sup>™</sup> 2 Duo 2.00 GHz e com 3 GB de RAM e foi observado que o tempo de computação varia linearmente com o tempo. No melhor dos casos, uma imagem com 52,080 pixéis demora em média 0.31 segundos a ser processada e no pior dos casos, uma imagem com 6 665,472 pixéis demora em média 23.05 segundos a ser processada. Normalmente o processamento de uma imagem demora 6 segundos. De notar que este algoritmo não foi otimizado, e caso estivesse numa linguagem compilada estes custos computacionais diminuiriam

Este trabalho demonstrou que é possível obter excelentes resultados de classificação optando por utilizar indicadores genéricos de qualidade de imagem nos algoritmos de classificação de qualidade. Inclusive, esta proposta aplicada em sistemas de exames e diagnóstico, facilita o trabalho do técnico pois, não só como devolve uma medida de qualidade global, como apresenta valores sobre 4 indicadores genéricos de qualidade de imagem, permitindo o fácil ajuste durante o processo de capturas de imagem.



# Apêndice B

## Exemplos de Imagens de Treino

### Messidor

Como mencionado anteriormente, foram utilizadas 200 imagens do banco de imagens público Messidor. Em seguida são apresentados alguns exemplos desse conjunto de imagens.

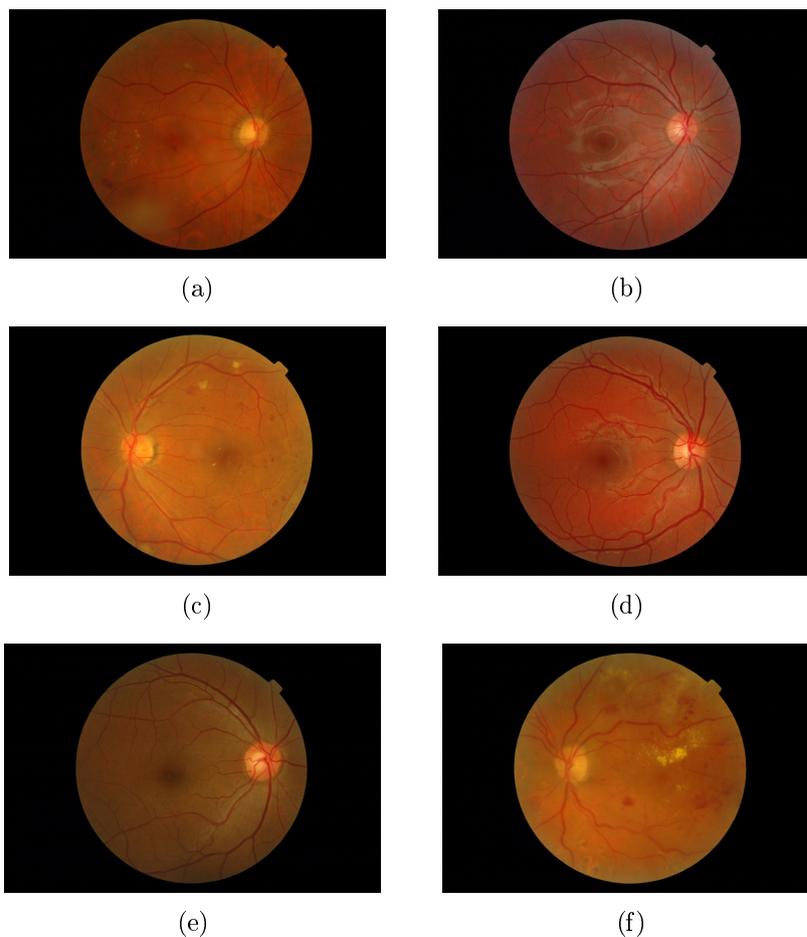


Figura B.1: Exemplos de retinografias do banco de imagens Messidor [50].



# Apêndice C

## Resultados Adicionais - Avaliação Setorial de Qualidade de Retinografias

Este capítulo descreve os resultados obtidos em falta no capítulo 5. De igual forma, esta partição está dividida consoante método, setor e indicador em análise. Os testes realizados nestes estudos, utilizaram a distribuição de imagens exposta na tabela 5.4.

### Estudo da Variação do Raio

#### Raio da Região do Disco Ótico

Cor

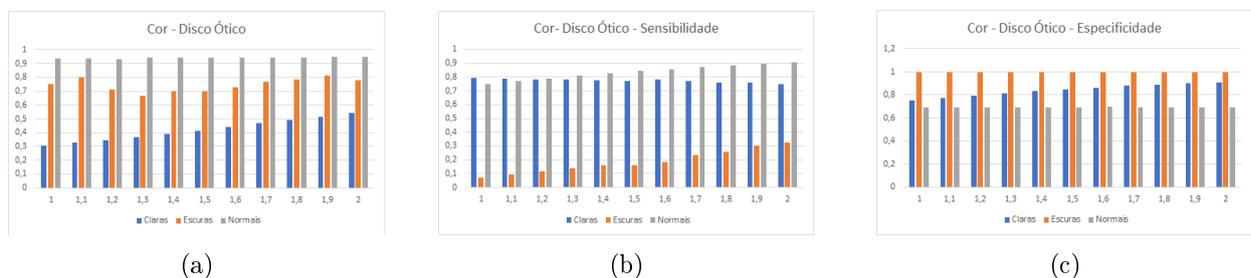


Figura C.1: Gráfico obtido variando o raio do disco ótico. O eixo das abcissas representa os valores multiplicados pelo raio original da zona considerada e o eixo das ordenadas representa os valores de: (a) precisão, (b) sensibilidade, (c) especificidade. O gráfico refere-se à classificação da cor da imagem. Como é possível verificar, no geral, considerando as 3 medidas, os valores aumentam com o crescimento do raio.

## Foco

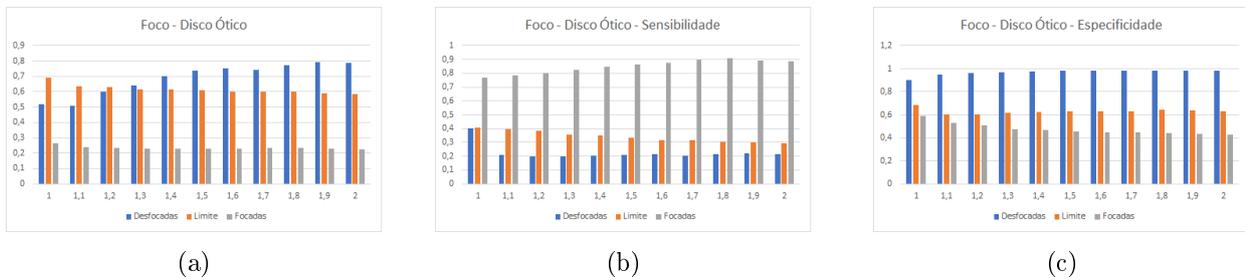


Figura C.2: Gráfico obtido variando o raio do disco ótico. O eixo das abcissas representa os valores multiplicados pelo raio original da zona considerada e o eixo das ordenadas representa os valores de: (a) precisão, (b) sensibilidade, (c) especificidade. O gráfico refere-se à classificação do foco da imagem. Como é possível verificar, através da análise da precisão, é alcançada melhor performance quando considerado o raio original.

## Contraste

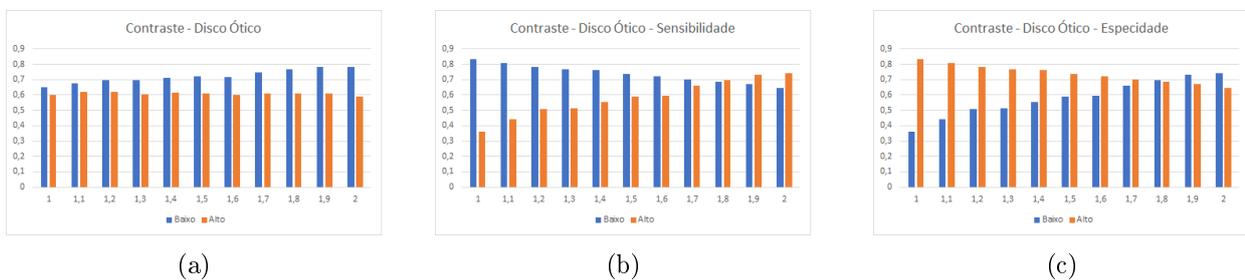


Figura C.3: Gráfico obtido variando o raio do disco ótico. O eixo das abcissas representa os valores multiplicados pelo raio original da zona considerada e o eixo das ordenadas representa os valores de: (a) precisão, (b) sensibilidade, (c) especificidade. O gráfico refere-se à classificação do contraste da imagem. O gráfico refere-se à classificação do foco da imagem. Como é possível verificar, através da análise da precisão, é alcançada melhor performance quando considerado o dobro do raio.

## Iluminação

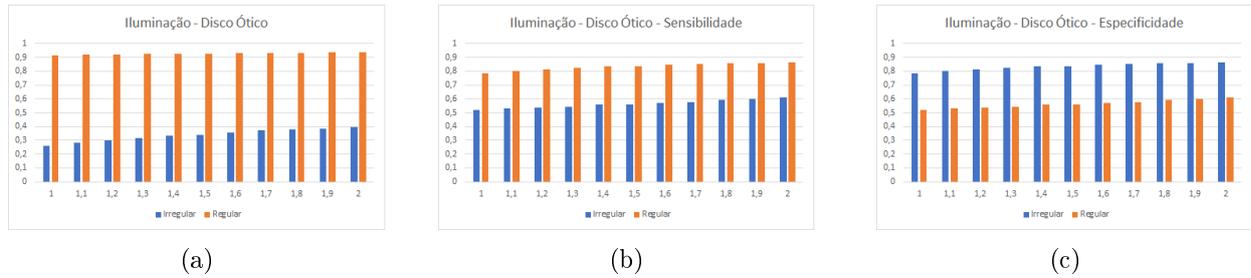


Figura C.4: Gráfico obtido variando o raio do disco ótico. O eixo das abcissas representa os valores multiplicados pelo raio original da zona considerada e o eixo das ordenadas representa os valores de: (a) precisão, (b) sensibilidade, (c) especificidade. O gráfico refere-se à classificação da iluminação da imagem. Como é possível verificar, considerando as 3 medidas, os valores aumentam com o crescimento do raio.

## Global

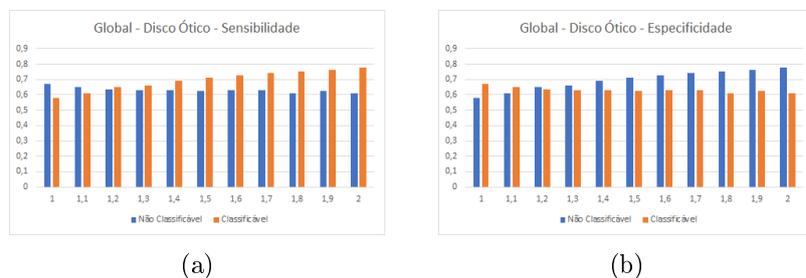


Figura C.5: Gráfico obtido variando o raio do disco ótico. O eixo das abcissas representa os valores multiplicados pelo raio original da zona considerada e o eixo das ordenadas representa os valores de: (a) sensibilidade, (b) especificidade. O gráfico refere-se à classificação de qualidade global da imagem. Como é possível verificar, considerando as 2 medidas, os valores aumentam com o crescimento do raio.

## Raio da Região da Fóvea

### Cor

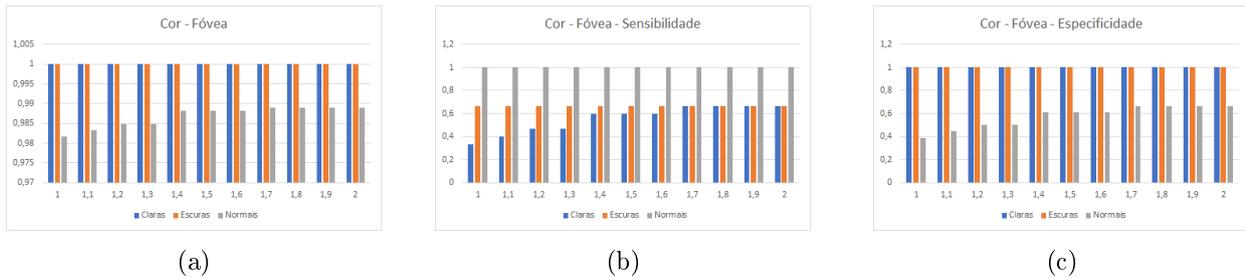


Figura C.6: Gráfico obtido variando o raio da fóvea. O eixo das abcissas representa os valores multiplicados pelo raio original da zona considerada e o eixo das ordenadas representa os valores de: (a) precisão, (b) sensibilidade, (c) especificidade. O gráfico refere-se à classificação da cor da imagem. Como é possível verificar, considerando as 3 medidas, os valores aumentam com o crescimento do raio.

### Foco

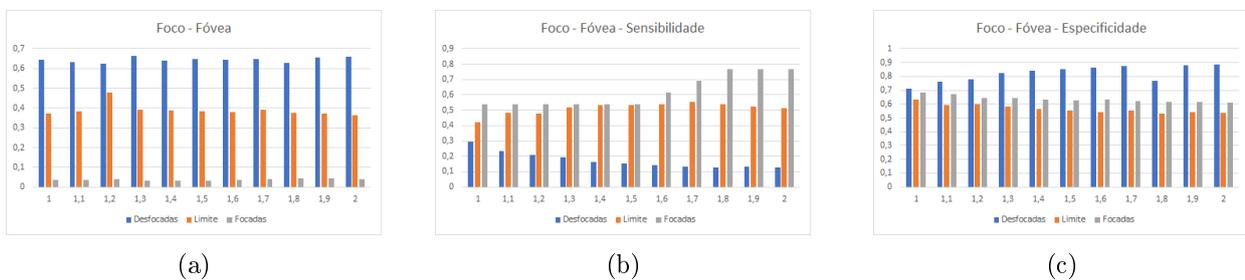


Figura C.7: Gráfico obtido variando o raio da fóvea. O eixo das abcissas representa os valores multiplicados pelo raio original da zona considerada e o eixo das ordenadas representa os valores de: (a) precisão, (b) sensibilidade, (c) especificidade. O gráfico refere-se à classificação do foco da imagem. Como é possível verificar, no geral, considerando as 3 medidas, os valores aumentam com o crescimento do raio.

## Contraste

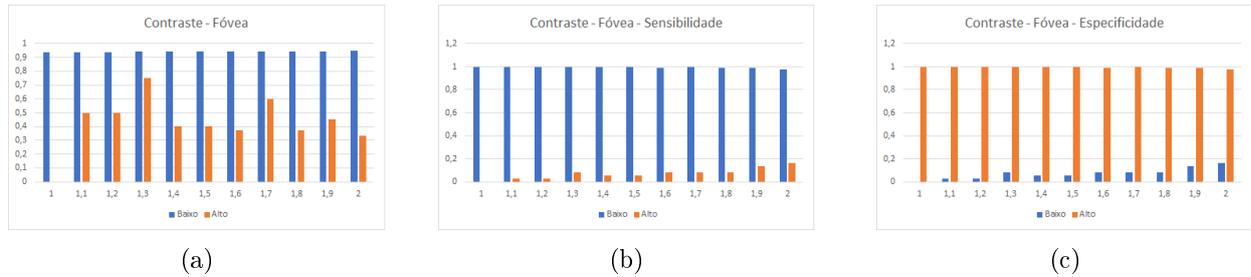


Figura C.8: Gráfico obtido variando o raio da fóvea. O eixo das abcissas representa os valores multiplicados pelo raio original da zona considerada e o eixo das ordenadas representa os valores de: (a) precisão, (b) sensibilidade, (c) especificidade. O gráfico refere-se à classificação do contraste da imagem. Como é possível verificar, no geral, considerando as 3 medidas, os valores aumentam com o crescimento do raio.

## Iluminação

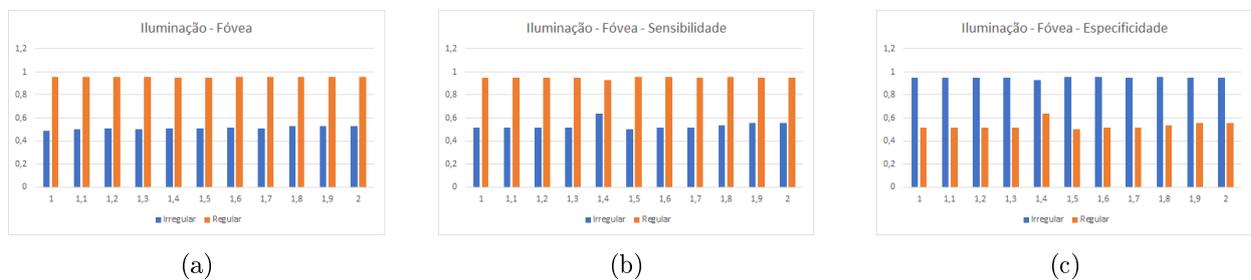


Figura C.9: Gráfico obtido variando o raio da fóvea. O eixo das abcissas representa os valores multiplicados pelo raio original da zona considerada e o eixo das ordenadas representa os valores de: (a) precisão, (b) sensibilidade, (c) especificidade. O gráfico refere-se à classificação da iluminação da imagem. Como é possível verificar, considerando as 3 medidas, os valores mantêm-se semelhantes ao longo do aumento do raio.

## Global

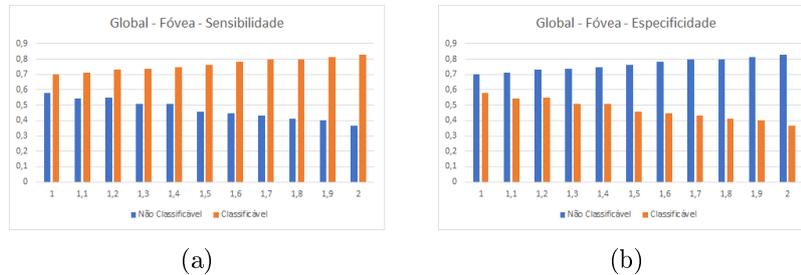


Figura C.10: Gráfico obtido variando o raio da fóvea. O eixo das abcissas representa os valores multiplicados pelo raio original da zona considerada e o eixo das ordenadas representa os valores de: (a) sensibilidade, (b) especificidade. O gráfico refere-se à classificação de qualidade global da imagem. Como é possível verificar, enquanto o raio aumenta, a performance piora.

## Alteração dos Classificadores

### Classificadores da Região do Disco Ótico

#### Cor

	Classificadores					
	Dias <i>et al.</i>			Proposto		
	"Claras"	"Escuras"	"Normais"	"Claras"	"Escuras"	"Normais"
Sensibilidade	0.7509	0.3256	0.9075	0.6075	0.395	0.9113
Especificidade	0.9117	0.9981	0.6916	0.924	0.99	0.578
Precisão	0.5408	0.7778	0.9470	0.52	0.46	0.9291

Tabela C.1: Valores das medidas de análise dos classificadores de avaliação da cor da região do disco ótico. O classificador retreinado proposto que garantiu melhores resultados foi o classificador de rede bayesiana. Comparando os valores desta tabela, é possível verificar que o classificador com melhor performance foi o classificador concebido por Dias *et al.*

## Foco

	Classificadores					
	Dias et al.			Proposto		
	"Desfocadas"	"Limite"	"Focadas"	"Desfocadas"	"Limite"	"Focadas"
Sensibilidade	0.2173	0.2957	0.887	0.39	0.9147	0.296
Especificidade	0.985	0.6332	0.4286	0.9618	0.358	0.9678
Precisão	0.7903	0.5835	0.226	0.727	0.7123	0.63

Tabela C.2: Valores das medidas de análise dos classificadores de avaliação do foco da região do disco ótico. O classificador retreinado proposto que garantiu melhores resultados foi o classificador fino gaussiano SVM. Comparando os valores desta tabela, é possível verificar que o classificador com melhor performance foi o classificador proposto neste trabalho.

## Contraste

	Classificadores			
	Dias et al.		Proposto	
	"Baixo"	"Alto"	"Baixo"	"Alto"
Sensibilidade	0.643	0.743	0.7321	0.658
Especificidade	0.743	0.643	0.658	0.7321
Precisão	0.7822	0.5922	0.7544	0.631

Tabela C.3: Valores das medidas de análise dos classificadores de avaliação do contraste da região do disco ótico. O classificador retreinado proposto que garantiu melhores resultados foi o classificador baseado em instâncias. Comparando os valores desta tabela, é possível verificar que ambos garantem uma performance semelhante. Neste caso a escolha do classificador depende das características do projeto.

## Iluminação

	Classificadores			
	Dias et al.		Proposto	
	"Irregular"	"Regular"	"Irregular"	"Regular"
Sensibilidade	0.6107	0.862	0.514	0.8737
Especificidade	0.862	0.6107	0.8737	0.514
Precisão	0.3949	0.9376	0.379	0.923

Tabela C.4: Valores das medidas de análise dos classificadores de avaliação da iluminação da região do disco ótico. O classificador retreinado proposto que garantiu melhores resultados foi o classificador de rede bayesiana. Comparando os valores desta tabela, é possível verificar que o classificador com melhor performance foi o classificador concebido por Dias *et al.*

## Classificador da Região da Fóvea

### Cor

	Classificadores					
	Dias et al.			Proposto		
	"Claras"	"Escuras"	"Normais"	"Claras"	"Escuras"	"Normais"
Sensibilidade	0.3333	0.6667	1	0.6	0.67	1
Especificidade	1	1	0.3889	1	1	0.61
Precisão	1	1	0.9816	1	1	0.988

Tabela C.5: Valores das medidas de análise dos classificadores de avaliação da cor da região da fóvea. O classificador retreinado proposto que garantiu melhores resultados foi o classificador linear SVM. Comparando os valores desta tabela, é possível verificar que o classificador com melhor performance foi o classificador proposto.

### Foco

	Classificadores					
	Dias et al.			Proposto		
	"Desfocadas"	"Limite"	"Focadas"	"Desfocadas"	"Limite"	"Focadas"
Sensibilidade	0.2969	0.4203	0.5385	0.724	0.28	0.1538
Especificidade	0.7136	0.6322	0.6836	0.295	0.7279	0.995
Precisão	0.6441	0.3734	0.0361	0.642	0.349	0.4

Tabela C.6: Valores das medidas de análise dos classificadores de avaliação do foco da região da fóvea. O classificador retreinado proposto que garantiu melhores resultados foi o classificador *Bagged Trees*. Comparando os valores desta tabela, é possível verificar que o classificador com melhor performance foi o classificador proposto.

### Contraste

	Classificadores			
	Dias et al.		Proposto	
	"Baixo"	"Alto"	"Baixo"	"Alto"
Sensibilidade	0.9982	0	0.9577	0.216
Especificidade	0	0.9982	0.216	0.9577
Precisão	0.9386	0	0.949	0.25

Tabela C.7: Valores das medidas de análise dos classificadores de avaliação do contraste da região da fóvea. O classificador retreinado proposto que garantiu melhores resultados foi o classificador de rede bayesiano. Comparando os valores desta tabela, é possível verificar que o classificador com melhor performance foi o classificador proposto.

## Iluminação

	Classificadores			
	Dias et al.		Proposto	
	"Irregular"	"Regular"	"Irregular"	"Regular"
Sensibilidade	0.5185	0.9473	0.47	0.983
Especificidade	0.9473	0.5185	0.983	0.47
Precisão	0.4912	0.9525	0.7097	0.9441

Tabela C.8: Valores das medidas de análise dos classificadores de avaliação da iluminação da região da fóvea. O classificador retreinado proposto que garantiu melhores resultados foi o classificador de árvore simples. Comparando os valores desta tabela, é possível verificar que o classificador com melhor performance foi o classificador proposto.

## Classificador da Área Restante

### Cor

	Classificadores					
	Dias et al.			Proposto		
	"Claras"	"Escuras"	"Normais"	"Claras"	"Escuras"	"Normais"
Sensibilidade	0.9825	0.7326	0.9504	0.9753	0.7385	0.948
Especificidade	0.953	0.9995	0.9641	0.952	0.999	0.9575
Precisão	0.9418	0.9844	0.967	0.94	0.9545	0.961

Tabela C.9: Valores das medidas de análise dos classificadores de avaliação da cor da região restante. O classificador retreinado proposto que garantiu melhores resultados foi o classificador cubico SVM. Comparando os valores desta tabela, é possível verificar que o classificador com melhor performance foi o classificador Dias *et al.*.

### Foco

	Classificadores					
	Dias et al.			Proposto		
	"Desfocadas"	"Limite"	"Focadas"	"Desfocadas"	"Limite"	"Focadas"
Sensibilidade	0.8594	0.4423	0.9755	0.541	0.7673	0.5929
Especificidade	0.5503	0.8376	0.9755	0.8427	0.5826	0.965
Precisão	0.4908	0.7504	0.7985	0.634	0.6699	0.7341

Tabela C.10: Valores das medidas de análise dos classificadores de avaliação do foco da região restante. O classificador retreinado proposto que garantiu melhores resultados foi o classificador fino gaussiano SVM. Comparando os valores desta tabela, é possível verificar que o classificador com melhor performance foi o classificador Dias *et al.*.

## Contraste

	Classificadores			
	Dias et al.		Proposto	
	"Baixo"	"Alto"	"Baixo"	"Alto"
Sensibilidade	0.8186	0.6798	0.6847	0.7832
Especificidade	0.6798	0.8186	0.7832	0.6847
Precisão	0.6357	0.8459	0.6832	0.7844

Tabela C.11: Valores das medidas de análise dos classificadores de avaliação do contraste da região restante. O classificador retreinado proposto que garantiu melhores resultados foi o classificador perceptrão de camada múltipla. Comparando os valores desta tabela, é possível verificar que o classificador com melhor performance foi o classificador proposto.

## Iluminação

	Classificadores			
	Dias et al.		Proposto	
	"Irregular"	"Regular"	"Irregular"	"Regular"
Sensibilidade	0.7424	0.8909	0.8542	0.5165
Especificidade	0.8909	0.7424	0.5165	0.8542
Precisão	0.9255	0.6542	0.7635	0.6596

Tabela C.12: Valores das medidas de análise dos classificadores de avaliação da iluminação da região restante. O classificador retreinado proposto que garantiu melhores resultados foi o classificador de perceptrão de camada múltipla. Comparando os valores desta tabela, é possível verificar que o classificador com melhor performance foi o classificador concebido por Dias *et al.*.

## Classificador da Imagem Completa

### Cor

	Classificadores					
	Dias et al.			Proposto		
	"Claras"	"Escuras"	"Normais"	"Claras"	"Escuras"	"Normais"
Sensibilidade	0.994	0.6596	0.958	0.9538	0.6774	0.9403
Especificidade	0.9596	0.9995	0.9679	0.9594	0.9897	0.9341
Precisão	0.9519	0.9841	0.969	0.95	0.7411	0.937

Tabela C.13: Valores das medidas de análise dos classificadores de avaliação da cor da imagem completa. O classificador retreinado proposto que garantiu melhores resultados foi o classificador de regressão logística aditiva. Comparando os valores desta tabela, é possível verificar que o classificador com melhor performance foi o classificador concebido por Dias *et al.*.

### Foco

	Classificadores					
	Dias et al.			Proposto		
	"Desfocadas"	"Limite"	"Focadas"	"Desfocadas"	"Limite"	"Focadas"
Sensibilidade	0.6426	0.8279	0.9743	0.541	0.7673	0.5929
Especificidade	0.9226	0.8824	0.9565	0.662	0.5826	0.88
Precisão	0.5928	0.8842	0.9171	0.6342	0.6699	0.7341

Tabela C.14: Valores das medidas de análise dos classificadores de avaliação de foco da imagem completa. O classificador retreinado proposto que garantiu melhores resultados foi o classificador de *weighted KNN*. Comparando os valores desta tabela, é possível verificar que o classificador com melhor performance foi o classificador concebido por Dias *et al.*.

### Contraste

	Classificadores			
	Dias et al.		Proposto	
	"Baixo"	"Alto"	"Baixo"	"Alto"
Sensibilidade	0.8783	0.9174	0.8613	0.9258
Especificidade	0.9174	0.8783	0.9258	0.8613
Precisão	0.8448	0.9364	0.8545	0.9595

Tabela C.15: Valores das medidas de análise dos classificadores de avaliação do contraste da imagem completa. O classificador retreinado proposto que garantiu melhores resultados foi o classificador de percepção de camada múltipla. Comparando os valores desta tabela, é possível verificar que o classificador com melhor performance foi o classificador proposto.

## Iluminação

	Classificadores			
	Dias et al.		Proposto	
	"Irregular"	"Regular"	"Irregular"	"Regular"
Sensibilidade	0.7756	0.8769	0.8685	0.691
Especificidade	0.8769	0.7756	0.691	0.8685
Precisão	0.9215	0.6772	0.8395	0.7384

Tabela C.16: Valores das medidas de análise dos classificadores de avaliação de iluminação da imagem completa. O classificador retreinado proposto que garantiu melhores resultados foi o classificador de percepção de camada múltipla. Comparando os valores desta tabela, é possível verificar que o classificador com melhor performance foi o classificador proposto.

## Implementação dos Descritores de Textura

Como mencionado na secção 5.2.3.1, a incorporação dos descritores de textura melhorou os resultados referentes aos indicadores de qualidade global, contraste do disco ótico, sendo os resultados dos dois últimos algoritmos expostos em seguida.

		Proposto	
		"Baixo"	"Alto"
Real	"Baixo"	996	287
	"Alto"	315	585

Tabela C.17: Matriz de confusão proveniente da classificação do contraste da região do disco ótico após a inclusão dos descritores de textura.

Analisando a tabela C.17, a precisão da classe "Alto" foi de 0.7597, a sensibilidade 0.65 e a especificidade 0.7763, enquanto a precisão da classe "Baixo" foi de 0.671. Em comparação com os valores das medidas obtidas utilizando o classificador de Dias *et al.*, existiu um aumento da precisão (0.5922) e da especificidade (0.643) da classe "Alto". No entanto, a sensibilidade da classe "Alto" diminuiu 0.093 unidades e a precisão da classe "Baixo" diminuiu 0.0225. No entanto, dada a magnitude do aumento dos outros parâmetros, foi o classificador em estudo foi considerado preferível.

## Apêndice D

# Resultados Adicionais - Método de Classificação de Artefactos em Retinografias

A tabela exposta em seguida expõe a descrição dos resultados obtidos nos testes mencionados no capítulo 6. Esta tabela apresenta o tamanho das imagens de entrada, o número de filtros, tamanho, número e preenchimento das camadas, número de épocas, o tamanho do conjunto de amostra, caso foi efetuada a normalização do conjunto de amostra, os valores do termo de regularização L2, da taxa de aprendizagem e de *Dropout*, as funções de perda, o tipo de otimizador, o resultado da exatidão e o tempo de processamento.

Num	Tamanho c	Densidade	Número de Filtros	Tamanho	Numero de Camadas	Numero de épocas	Tamanho do conjunto	Normalização de do conjunto de amostra	Regularização	Preenchimento	Taxa de Aprendizagem	Dropout	Função de perda	Otimizador	Exatidão	Tempo
1	512x512	3	32,64,128,256,512	7x7, 5x5, 3x3, 3x3, 3x3	(conv+BatchNom+relu+maxpooling)*5+(1 dense+relu+dropout)*2	60	64 sim	L2=0.001	0.2,1,1.1	0.001, drop 30 de 0.1	0.5	Softmax	Adam	0.6214	12:37:22	
2	512x512	3	32,64,128,256,512	3x3, 3x3, 7x7, 5x5, 3x3	(conv+BatchNom+relu+maxpooling)*5+(1 dense+relu+dropout)*2	20	32 sim	L2=0.001	1,1,0,2,1	0.001 drop 30 de 0.1	0.5	Softmax	Adam	0.6439	01:53:14	
3	256x256	3	32,64,128,256	3x3	(conv+BatchNom+relu+maxpooling)*4+(1 dense+relu+dropout)*2	30	32 sim	L2=0.0001		1 0.001 drop 30 de 0.1	0.5	Softmax	Adam	0.6422	00:50:07	
4	256x256	3	32,64,128	3x3	(conv+BatchNom+relu+maxpooling)*3+(1 dense+relu+dropout)*2	30	32 sim	L2=0.0001		1 0.0001 drop 30 de 0.1	0.5	Softmax	Adam	0.6247	00:59:14	
5	256x256	3	32,64,128	3x3	(conv+BatchNom+relu+maxpooling)*3+(1 dense+relu+dropout)*2	40	32 sim	L2=0.0001		1 0.0001 drop 30 de 0.1	0.5	Softmax	Adam	0.6131	01:19:29	
6	256x256	3	32,64,128	3x3	(conv+BatchNom+relu+maxpooling)*3+(1 dense+relu+dropout)*2	40	32 sim	L2=0.0005		1 0.001 drop 20 de 0.1	0.5	Softmax	Adam	0.6467	01:19:29	
7	256x256	3	32,64,128	3x3	(conv+BatchNom+relu+maxpooling)*3+(1 dense+relu+dropout)*3	40	32 sim	L2=0.001		1 0.001 drop 20 de 0.1	0.5	Softmax	Adam	0.6494	01:28:31	
8	512x512	3	10,30,50,100,50	7x7, 3x3, 3x3, 3x3, 3x3	(conv+BatchNom+relu+maxpooling)*5+(1 dense+relu+dropout)*3	20	32 sim	L2=0.001		1, maxpool=0 0.001 drop 30 de 0.1	0.5	Softmax	Adam	0.6142	10:28:33	
9	512x512	3	10,30,50,100,50	7x7, 3x3, 3x3, 3x3, 3x3	(conv+BatchNom+relu+maxpooling)*5+(1 dense+relu+dropout)*3	30	64 sim	0.0005		1, maxpool=0 0.001 drop 30 de 0.1	0.5	Softmax	SGDM	0.5750	08:55:26	
10	256x256	3	32,64,128	3x3	(conv+BatchNom+relu+maxpooling)*3+(1 dense+relu+dropout)*3	30	64 sim	L2=0.001		1 0.001 drop 30 de 0.1	0.5	Softmax	Adam	0.6525	05:16:28	
11	256x256	3	128,32,64	3x3	(conv+BatchNom+relu+maxpooling)*3+(1 dense+relu+dropout)*3	30	64 sim	L2=0.001		0 0.001 drop 30 de 0.1	0.25	Softmax	Adam	0.65	00:31:53	
12	256x256	3	128,32,64	3x3	(conv+BatchNom+relu+maxpooling)*3+(1 dense+relu+dropout)*3	30	64 sim	L2=0.001		0 0.001 drop 30 de 0.1	0.25	Softmax	Adam	0.6308	00:42:40	
13	256x256	3	128,32,64	3x3	(conv+BatchNom+relu+maxpooling)*3+(1 dense+relu+dropout)*3	30	64 sim	L2=0.001		0 0.001 drop 20 de 0.1	0.25	Softmax	Adam	0.6256	00:42:59	
14	256x256	3	128,32,64	3x3	(conv+BatchNom+relu+maxpooling)*3+(1 dense+relu+dropout)*3	30	32 sim	L2=0.001		0 0.001 drop 10 de 0.1	0.25	Softmax	Adam	0.6492	00:35:51	
15	256x256	3	128,32,64	3x3	(conv+BatchNom+relu+maxpooling)*3+(1 dense+relu+dropout)*3	40	32 sim	L2=0.0001		0 0.001 drop 10 de 0.1	0.25	Softmax	Adam	0.6433	00:48:02	
16	256x256	3	50,100,256,400,400,256	7x7, 5x5, 3x3, 3x3, 3x3	(conv+relu+maxpooling+crossChannel)*3+(conv+relu)*3+maxpooling+(1 dense+relu+dropout)*3	64	64 sim	L2=0.0005	0.2,2,1,1.1	0.001 drop 30	0.5	Softmax	Adam	0.6189	00:31:56	
17	256x256	3	50,100,256,400,400,256	7x7, 5x5, 3x3, 3x3, 3x3	(conv+relu+maxpooling+crossChannel)*3+(conv+relu)*3+maxpooling+(1 dense+relu+dropout)*3	10	25 sim	L2=0.0005	0.2,2,1,1.1	0.001 drop 30	0.5	Softmax	SGDM	0.6242	00:10:46	
18	256x256	3	50,100,256,400,400,256	7x7, 5x5, 3x3, 3x3, 3x3	(conv+relu+maxpooling+crossChannel)*3+(conv+relu)*3+maxpooling+(1 dense+relu+dropout)*3	20	25 sim	L2=0.0005	0.2,2,1,1.1	0.001 drop 30	0.5	Softmax	Adam	0.6067	00:28:33	
19	256x256	3	50,100,256,400,400,256	7x7, 5x5, 3x3, 3x3, 3x3	(conv+relu+maxpooling+crossChannel)*3+(conv+relu)*3+maxpooling+(1 dense+relu+dropout)*3	30	25 sim	L2=0.0005	0.2,2,1,1.1	0.001 drop 10	0.5	Softmax	Adam	0.6214	00:42:36	
<b>Foi tirada a classe de imagens "Carteira" devido à sua semelhança com a classe "Desfile"</b>																
20	256x256	3	32,64,128	3x3	(conv+BatchNom+relu+maxpooling)*3+(1 dense+relu+dropout)*3	40	64 sim	L2=0.001		1 0.001 drop 30 de 0.1	0.5	Softmax	Adam	0.7527	00:29:35	
21	256x256	3	32,64,128	3x3	(conv+BatchNom+relu+maxpooling)*3+(1 dense+relu+dropout)*3	40	64 sim	L2=0.001		1 0.001 drop 30 de 0.1	0.5	Softmax	Adam	0.7580	00:57:20	
22	256x256	3	32,64,128	3x3	(conv+BatchNom+relu+maxpooling)*3+(1 dense+relu+dropout)*3	40	64 sim	L2=0.001		1 0.001 drop 20 de 0.1	0.5	Softmax	Adam	0.7557	00:57:20	
23	256x256	3	50,100,256,400,400,256	7x7, 5x5, 3x3, 3x3, 3x3	(conv+relu+maxpooling+crossChannel)*3+(conv+relu)*3+maxpooling+(1 dense+relu+dropout)*3	30	25 sim	L2=0.0005	0.2,2,1,1.1	0.001 drop 30	0.5	Softmax	SGDM	0.742	00:30:31	
24	256x256	3	50,100,256,400,400,256	7x7, 5x5, 3x3, 3x3, 3x3	(conv+relu+maxpooling+crossChannel)*3+(conv+relu)*3+maxpooling+(1 dense+relu+dropout)*3	30	25 sim	L2=0.0005	0.2,2,1,1.1	0.001 drop 10	0.5	Softmax	Adam	0.7307	00:37:09	
25	256x256	3	50,100,256,400,400,256	7x7, 5x5, 3x3, 3x3, 3x3	(conv+relu+maxpooling+crossChannel)*3+(conv+relu)*3+maxpooling+(1 dense+relu+dropout)*3	30	25 sim	L2=0.0001	0.2,2,1,1.1	0.001 drop 20	0.5	Softmax	Adam	0.7353	00:58:38	
26	512x512	3	32,64,128,256	7x7, 5x5, 3x3, 3x3	(conv+BatchNom+relu+maxpooling)*4+(1 dense+relu+dropout)*3	40	32 sim	L2=0.001		0 0.001 drop 20	0.5	Softmax	Adam	0.7443	01:10:39	
27	512x512	3	32,64,128,256	3x3,5x5,7x7, 3x3	(conv+BatchNom+relu+maxpooling)*4+(1 dense+relu+dropout)*3	40	32 sim	L2=0.001		0 0.001 drop 30	0.5	Softmax	Adam	0.7593	02:50:03	
28	512x512	3	32,64,128,256	3x3,5x5,7x7, 3x3	(conv+BatchNom+relu+maxpooling)*4+(1 dense+relu+dropout)*3	50	32 sim	L2=0.001		0 0.001 drop 30	0.5	Softmax	Adam	0.7500	03:32:10	
29	512x512	3	32,64,128,256	3x3,5x5,7x7, 3x3	(conv+BatchNom+relu+maxpooling)*4+(1 dense+relu+dropout)*3	50	32 sim	L2=0.001		0 0.001 drop 20	0.5	Softmax	Adam	0.7463	03:32:38	
<b>Aumentei dataset - Data Augmentation - 4000 por classe</b>																
30	512x512	3	32,64,128,256	3x3,5x5,7x7, 3x3	(conv+BatchNom+relu+maxpooling)*4+(1 dense+relu+dropout)*3	40	32 sim	L2=0.001		0 0.001 drop 20	0.5	Softmax	Adam	0.7507	07:17:19	
31	512x512	3	50,100,256,400,400,256	7x7, 5x5, 3x3, 3x3, 3x3	(conv+relu+maxpooling+crossChannel)*3+(conv+relu)*3+maxpooling+(1 dense+relu+dropout)*3	40	64 sim	L2=0.0001		0 0.001 drop 20	0.001	0.5	Softmax	SGDM	0.6980	14:53:14
32	256x256	3	50,100,256,400,400,256	7x7, 5x5, 3x3, 3x3, 3x3	(conv+relu+maxpooling+crossChannel)*3+(conv+relu)*3+maxpooling+(1 dense+relu+dropout)*3	30	25 sim	L2=0.0001		0 0.001 drop 20	0.5	Softmax	Adam	0.7395	01:54:49	
33	256x256	3	32,64,128,256	3x3,5x5,7x7, 3x3	(conv+BatchNom+relu+maxpooling)*4+(1 dense+relu+dropout)*3	40	32 sim	L2=0.001		0.2,2,1,1.1 0.001 drop 20	0.5	Softmax	Adam	0.7328	02:39:34	
34	512x512	3	32,64,128,256	3x3,5x5,7x7, 3x3	(conv+BatchNom+relu+maxpooling)*4+(1 dense+relu+dropout)*3	40	32 sim	L2=0.001		1 0.001 drop 20	0.5	Softmax	Adam	0.7405	07:23:37	
35	512x512	3	32,64,128,256	3x3,5x5,7x7, 3x3	(conv+BatchNom+relu+maxpooling)*4+(1 dense+relu+dropout)*3	40	32 sim	L2=0.001		0 0.001 drop 20	0.5	Softmax	Adam	0.7775	05:43:39	
36	256x256	3	50,100,256,400,400,256	7x7, 5x5, 3x3, 3x3, 3x3	(conv+relu+maxpooling+crossChannel)*3+(conv+relu)*3+maxpooling+(1 dense+relu+dropout)*3	30	25 sim	L2=0.0001	0.2,2,1,1.1	0.001 drop 20	0.5	Softmax	Adam	0.7593	00:33:50	
37	256x256	3	32,64,128	3x3	(conv+BatchNom+relu+maxpooling)*3+(1 dense+relu+dropout)*3	40	64 sim	L2=0.001		0 0.001 drop 20	0.5	Softmax	Adam	0.7648	02:19:20	
38	256x256	3	32,64,128,256	3x3,5x5,7x7, 3x3	(conv+BatchNom+relu+maxpooling)*4+(1 dense+relu+dropout)*3	40	128 sim	L2=0.001		1 0.001 drop 20	0.5	Softmax	Adam	0.7795	01:44:30	
39	256x256	3	32,64,128,256	3x3,3x3,3x3, 3x3	(conv+BatchNom+relu+maxpooling)*4+(1 dense+relu+dropout)*3	40	128 sim	L2=0.001		1 0.001 drop 20	0.5	Softmax	Adam	0.7712	01:41:03	
40	256x256	3	32,64,128,256	3x3,3x3,3x3, 3x3	(conv+BatchNom+relu+maxpooling)*4+(1 dense+relu+dropout)*3	60	128 sim	L2=0.001		1 0.001 drop 20	0.5	Softmax	Adam	0.7643	14:50:52	
41	256x256	3	32,64,128,256	3x3,5x5,7x7, 3x3	(conv+BatchNom+relu+maxpooling)*4+(1 dense+relu+dropout)*3	40	32 sim	L2=0.001		1 0.001 drop 20	0.5	Softmax	Adam	0.4993	01:49:10	
42	256x256	3	32,64,128,256	3x3,5x5,7x7, 3x3	(conv+BatchNom+relu+maxpooling)*4+(1 dense+relu+dropout)*3	40	32 sim	L2=0.001		1 0.001 drop 20	0.001	0.5	Softmax	Adam	0.7593	01:48:49
43	256x256	3	32,64,128,256	3x3,5x5,7x7, 3x3	(conv+BatchNom+relu+maxpooling)*4+(1 dense+relu+dropout)*3	40	32 sim	L2=0.001		1 0.0001 drop 20	0.0001	0.5	Softmax	Adam	0.7432	01:49:25
44	256x256	3	32,64,128,256	3x3,5x5,7x7, 3x3	(conv+BatchNom+relu+maxpooling)*4+(1 dense+relu+dropout)*3	40	32 sim	L2=0.001		1 0.001 drop 10	0.5	Softmax	Adam	0.7670	01:49:44	
45	256x256	3	32,64,128,256	3x3,5x5,7x7, 3x3	(conv+BatchNom+relu+maxpooling)*4+(1 dense+relu+dropout)*3	40	32 sim	L2=0.001		1 0.001 drop 20	0.5	Softmax	Adam	0.7660	01:49:50	
46	256x256	3	32,64,128,256	3x3,5x5,7x7, 3x3	(conv+BatchNom+relu+maxpooling)*4+(1 dense+relu+dropout)*3	40	32 sim	L2=0.001		1 0.001 drop 30	0.5	Softmax	Adam	0.7745	01:50:19	
47	256x256	3	32,64,128,256	3x3,5x5,7x7, 3x3	(conv+BatchNom+relu+maxpooling)*4+(1 dense+relu+dropout)*3	40	32 sim	L2=0.001		1 0.001 drop 20	0.5	Softmax	Adam	0.7638	01:46:23	
48	256x256	3	32,64,128,256	3x3,5x5,7x7, 3x3	(conv+BatchNom+relu+maxpooling)*4+(1 dense+relu+dropout)*3	40	64 sim	L2=0.001		1 0.001 drop 20	0.5	Softmax	Adam	0.7715	01:44:44	
49	256x256	3	32,64,128,256	3x3,5x5,7x7, 3x3	(conv+BatchNom+relu+maxpooling)*4+(1 dense+relu+dropout)*3	40	128 sim	L2=0.001		1 0.001 drop 20	0.5	Softmax	Adam	0.7710	01:45:30	
50	256x256	3	32,64,128,256	3x3,5x5,7x7, 3x3	(conv+BatchNom+relu+maxpooling)*4+(1 dense+relu+dropout)*3	20	32 sim	L2=0.001		1 0.001 drop 20	0.5	Softmax	Adam	0.7690	00:53:09	
51	256x256	3	32,64,128,256	3x3,5x5,7x7, 3x3	(conv+BatchNom+relu+maxpooling)*4+(1 dense+relu+dropout)*3	40	32 sim	L2=0.001		1 0.001 drop 20	0.5	Softmax	Adam	0.7690	01:48:08	
52	256x256	3	32,64,128,256	3x3,5x5,7x7, 3x3	(conv+BatchNom+relu+maxpooling)*4+(1 dense+relu+dropout)*3	60	32 sim	L2=0.001		1 0.001 drop 20	0.5	Softmax	Adam	0.7585	02:43:39	
53	256x256	3	32,64,128,256	3x3,5x5,7x7, 3x3	(conv+BatchNom+relu+maxpooling)*4+(1 dense+relu+dropout)*3	40	32 sim	L2=0.0001		0.001 drop 20	0.5	Softmax	Adam	0.7580	01:51:10	
54	256x256	3	32,64,128,256	3x3,5x5,7x7, 3x3	(conv+BatchNom+relu+maxpooling)*4+(1 dense+relu+dropout)*3	40	32 sim	L2=0.0005		1 0.001 drop 20	0.5	Softmax	Adam	0.7745	01:51:02	
55	256x256	3	32,64,128,256	3x3,5x5,7x7, 3x3	(conv+BatchNom+relu+maxpooling)*4+(1 dense+relu+dropout)*3	40	32 sim	L2=0.001		1 0.001 drop 20	0.5	Softmax	Adam	0.7635	01:51:36	
56	256x256	3	32,64,128,256	3x3,5x5,7x7, 3x3	(conv+BatchNom+relu+maxpooling)*4+(1 dense+relu+dropout)*3	40	64 sim	L2=0.0005		1 0.001 drop 20	0.5	Softmax	Adam	0.8040	01:48:50	

# Bibliografia

- [1] R. R. Bourne, S. R. Flaxman, T. Braithwaite, M. V. Cicinelli, A. Das, Jonas JB, *et al.*, "Magnitude, temporal trends, and projections of the global prevalence of blindness and distance and near vision impairment: a systematic review and meta-analysis", *Lancet Glob Health*, vol. 5, no. 9, pp. 888–897, 2017. (Citado na página 1).
- [2] D. Pascolini e S. P. M. Mariotti, "Global estimates of visual impairment: 2010", *British Journal Ophthalmology Online*, 2011. (2 citações nas páginas 1, e 6).
- [3] C. D. Mathers e D. Loncar, *Projections of global mortality and burden of disease from 2002 to 2030*, chap. 1.5.5. PLoS Med 3, 2006. (Citado na página 1).
- [4] A. Foster e S. Resnikoff, "The impact of vision 2020 on global blindness", *Eye*, vol. 19, no. 10, pp. 1133–1135, 2005. (Citado na página 1).
- [5] N. Patton, T. M. Aslam, T. MacGillivray, I. J. Deary, B. Dhillon, R. H. Eikelboom, K. Yogesan e I. J. Constable, "Retinal image analysis: concepts, applications and potential", *Progress in Retinal and Eye Research*, vol. 25, pp. 99–127, Jan. 2006. (Citado na página 1).
- [6] A. D. Fleming, S. Philip, K. A. Goatman, J. A. Olson, e P. F. Sharp, "Automated assessment of diabetic retinal image quality based on clarity and field definition", *Ophthalmology & Visual Science*, vol. 47, no. 3, pp. 1120–1125, 2006. (3 citações nas páginas 2, 20, e 24).
- [7] M. D. Abramoff e M. S. A. Suttorp-Schulten, "Web-based screening for diabetic retinopathy in a primary care population: the EyeCheck project", *Telemedicine and e-Health*, *Telemedicine and e-Health*, vol. 11, no. 6, pp. 668–674, 2005. (Citado na página 2).
- [8] H. Davis, S. Russell, E. Barriga, M. Abramoff, e P. Soliz, "Visionbased, real-time retinal image quality assessment", *22nd IEEE International Symposium on Computer-Based Medical Systems*. pp. 1–6, 2009. (3 citações nas páginas xiii, 2, e 17).
- [9] J. A. M. P. Dias, C. M. Oliveira e L. A. d. S. Cruz, "Retinal image quality assessment using generic image quality indicators", *Inf. Fusion*, vol. 13 pp. 1-18 2012. (10 citações nas páginas xiv, xviii, 2, 18, 24, 29, 57, 59, 61, e 62).

[10] R. S. Snell, *Clinical anatomy by regions.*, vLippincott Williams & Wilkins, 2007. (2 citações nas páginas 5, e 6).

[11] M. Belleza, URL: <https://nurseslabs.com/special-senses-anatomy-physiology/>, Ultimo acesso: 30 de Julho de 2018. (2 citações nas páginas xiii, e 6).

[12] K. Rogers, *The eye: The physiology of human perception.* The Human Body, Rosen Publishing Group, 2010. (2 citações nas páginas 5, e 6).

[13] G. H. Cassel, M. D. Billig, H. G. Randall, e M. F. Goldberg, *The eye book: A complete guide to eye disorders and health.* Johns Hopkins Press Health Book, Large Print Edition, Johns Hopkins University Press, 2001. (2 citações nas páginas 6, e 30).

[14] N. R. Galloway, W. M. K. Amoaku, P. H. Galloway, e A. C. Browning, *Common eye diseases and their management.* Common Eye Diseases and Their Management, Springer, 2005. (2 citações nas páginas 6, e 30).

[15] N. E. Institute, *Facts about age-related macular degeneration.* URL: [https://nei.nih.gov/health/maculardegen/armd\\_facts](https://nei.nih.gov/health/maculardegen/armd_facts), Ultimo acesso: 30 de Julho de 2018. (2 citações nas páginas 8, e 30).

[16] N. E. Institute, *Facts about diabetic retinopathy.* URL: <https://nei.nih.gov/health/diabetic/retinopathy>, Ultimo acesso: 30 de Julho de 2018. (2 citações nas páginas 9, e 30).

[17] H. Jelinek e M. J. Cree, *Automated image detection of retinal pathology.* CRC Press, 2009. (Citado na página 10).

[18] URL: <https://www.skowroneyecare.com/cataracts.html>, Ultimo acesso: 8 de Agosto de 2018. (2 citações nas páginas xiii, e 7).

[19] F. Lake, "Glaucoma research gives a glimpse of a novel neuroprotection mechanism", 2017 URL: <https://www.neuro-central.com/2017/11/08/glaucoma-research-gives-glimpse-novel-neuroprotection-mechanism/>, Ultimo acesso: 8 de Agosto de 2018. (2 citações nas páginas xiii, e 7).

[20] A. Strohbehn e E. H. Sohn, URL: <http://webeye.ophth.uiowa.edu/eyeforum/tutorials/retinal-detachment-med-students/index.htm>, Ultimo acesso: 8 de Agosto de 2018. (2 citações nas páginas xiii, e 7).

[21] G. Timberlake e M. Kennedy, "The direct ophthalmoscope: How it works and how to use it", 2005. (2 citações nas páginas xiii, e 7).

- [22] T. Kohler, A. Budai, M. F. Kraus, J. Odstreilik, G. Michelson, J. Hornegger, "Automatic no-reference quality assessment for retinal fundus images using vessel segmentation", *IEEE 26th International Symposium on Computer-Based Medical Systems*, pp. 95–100, 2013. (2 citações nas páginas xiii, e 15).
- [23] U. Sevik, "DRIMDB (Diabetic Retinopathy Images Database) Database for Quality Testing of Retinal Images", 2014, URL: [http://https://www.researchgate.net/publication/282641760\\_DRIMDB](http://https://www.researchgate.net/publication/282641760_DRIMDB), Ultimo acesso: 8 de Agosto de 2018. (3 citações nas páginas xiii, 12, e 15).
- [24] K. Eichhorn-Mulligan e I. K. Kim, 2008, URL: <https://www.reviewofophthalmology.com/article/nevus-or-melanoma-how-to-differentiate>, Ultimo acesso: 8 de Agosto de 2018. (2 citações nas páginas xiii, e 15).
- [25] M. D. Abràmoff, M. K. Garvin, M. Sonka, "Retinal imaging and image analysis", *IEEE Rev. Biomed. Eng.*, vol. 3, pp. 169–208, 2010. (Citado na página 11).
- [26] National Health and Nutrition Examination Survey, *Ophthalmology Digital Grading Protocol*. URL: [https://wwwn.cdc.gov/nchs/data/nhanes/2005-2006/manuals/NHANES\\_ophthalmology\\_digital\\_grading\\_protocol.pdf](https://wwwn.cdc.gov/nchs/data/nhanes/2005-2006/manuals/NHANES_ophthalmology_digital_grading_protocol.pdf), Ultimo acesso: 30 de Julho de 2018. (3 citações nas páginas 11, 12, e 28).
- [27] P. J. Saine, "Errors in fundus photography", *Journal of Ophthalmic Photography*, vol. 7, no. 2, pp. 120–122, 1984. (Citado na página 12).
- [28] F. P. R. C. Dept. of Ophthalmology & Visual Sciences of the University of Wisconsin-Madison, *ARIC grading protocol*. URL: [http://www.csc.c.unc.edu/aric/visit/Quality\\_Assurance\\_and\\_Quality\\_Control.3\\_12.pdf](http://www.csc.c.unc.edu/aric/visit/Quality_Assurance_and_Quality_Control.3_12.pdf), Ultimo Acesso: 30 de Julho de 2018. (2 citações nas páginas 12, e 28).
- [29] S. C. Lee e Y. Wang, "Automatic retinal image quality assessment and enhancement", in *Proceedings of SPIE Medical Imaging: Image Processing*, vol. 3661, pp. 1581–1590, May 1999. (2 citações nas páginas 15, e 24).
- [30] M. Lalonde, L. Gagnon, e M.-C. Boucher, "Automatic visual quality assessment in optical fundus images", *Proceedings of Vision Interface*, pp. 259–264, 2001. (4 citações nas páginas xiii, 15, 16, e 24).
- [31] H. Bartling, P. Wanger e L. Martin, "Automated quality evaluation of digital fundus photographs", *Acta Ophthalmologica*, vol. 87, no. 7, pp. 557–568, 2009. (Citado na página 17).
- [32] B. A. Rosner, *Fundamentals of biostatistics 7th edition*. Thomson-Brooks/Cole, 2010. (Citado na página 17).

[33] R. Haralick, Dinstein, e K. Shanmugan, "Textural features for image classification", *IEEE Transactions on Systems, Man, and Cybernetics*, vol. SMC-3, no. 6, pp. 610–621, 1973. (6 citações nas páginas xvii, 18, 23, 25, 35, e 36).

[34] D. Usher, M. Himaga, e M. Dumsy, "Automated assessment of digital fundus image quality using detected vessel area", em *Proceedings of Medical Image Understanding and Analysis*, pp. 81–84, 2003. (Citado na página 19).

[35] J. Lowell, A. Hunter, M. Habib, e D. Steel, "Automated quantification of fundus image quality", em *Proceedings of the 3rd European Medical and Biological Engineering Conference*, 2005. (Citado na página 19).

[36] M. Niemeijer, M. D. Abràmoff, e B. van Ginneken, "Image structure clustering for image quality verification of color retina images in diabetic retinopathy screening", *Medical Image Analysis*, vol. 10, no. 6, pp. 888–898, 2006. (2 citações nas páginas 19, e 24).

[37] R. O. Duda e P. E. Hart "Use of the Hough Transformation to Detect Lines and Curves in Pictures", *Artificial Intelligence Center*, RI International, 1971. (Citado na página 20).

[38] L. Giancardo, M. D. Abràmoff, E. Chaum, T. P. Karnowski, F. Meriaudeau e K. W. Tobin, "Elliptical local vessel density: A fast and robust quality metric for retinal images", *Conference Proceedings of the International Conference of IEEE Engineering in Medicine and Biology Society*, vol. 2008, pp. 3534–3537, 2008. (3 citações nas páginas xvii, 20, e 21).

[39] F. Zana e J. C. Klein, "Segmentation of vessel-like patterns using mathematical morphology and curvature evaluation" *IEEE Transactions on Image Processing*, vol. 10, no. 7, pp. 1010–1019, 2001. (Citado na página 20).

[40] A. Hunter, J. Lowell, M. Habib, B. Ryder, A. Basu, e D. Steel, "An automated retinal image quality grading algorithm", em: *Conference Proceedings of the International Conference of IEEE Engineering in Medicine and Biology Society*, pp. 5955–5958. 2011. (3 citações nas páginas xvii, 20, e 21).

[41] J. Paulus, J. Meier, R. Bock, J. Hornegger, e G. Michelson, "Automated quality assessment of retinal fundus photos" *International Journal of Computer Assisted Radiology and Surgery*, vol. 5, no. 6, pp. 557–564, 2010. (3 citações nas páginas xvii, 22, e 23).

[42] R. Welikala, M. Fraz, P. Foster, P. Whincup, A. Rudnicka, C. Owen, D. Strachan, S. Barman *et al.*, "Automated retinal image quality assessment on the UK Biobank

dataset for epidemiological studies", *Computers in Biology and Medicine*, vol. 71, pp. 67-76, 2016. (3 citações nas páginas xvii, 21, e 22).

[43] M. M. Fraz, R. A. Welikala, A. R. Rudnicka, C. G. Owen, D. P. Strachan e S. A. Barman, "QUARTZ: Quantitative Analysis of Retinal Vessel Topology and size - An automated system for quantification of retinal vessels morphology", *Expert Systems with Applications*, vol. 42, pp. 7221-7234, 2015. (Citado na página 21).

[44] D. Mahapatra, "Retinal Image Quality Classification Using Neurobiological Models of the Human Visual System", *International Workshop on Ophthalmic Medical Image Analysis*, pp. 97-104, 2016. (Citado na página 18).

[45] T. V. Program, *Messidor Dataset*, URL: <http://messidor.crihan.fr/download.php>, Último Acesso: 20 de Agosto de 2018. (6 citações nas páginas xiii, 27, 29, 30, 31, e 33).

[46] G.N. Thomas, S.Y. Ong, Y.C. Tham, W. Hsu, M.L. Lee, Q.P. Lau, W.T. Tay, J. Alessi-Calandro, L.A. Hodgson, R. Kawasaki, T.Y. Wond e C.Y. Cheung, "Measurement of Macular Fractal Dimension Using a Computer-Assisted Program", *Invest. Ophthalmol. Vis. Sci.*, 2014. (Citado na página 30).

[47] L. Gagnon, M. Lalonde, M. Beaulieu, e M.-C. Boucher "Procedure to detect anatomical structures in optical fundus images", em *Proceedings of SPIE Medical Imaging: Image Processing*, (M. Sonka and K. M. Hanson, eds.), vol. 4322 de *Society of Photo-Optical Instrumentation Engineers (SPIE) Conference Series*, pp. 1218-1225, 2001. (Nenhuma citação).

[48] M. Omar, A. Hossain, L. Zhang, e H. Shum, "An intelligent mobile-based automatic diagnostic system to identify retinal diseases using mathematical morphological operations", pp. 1-5, 2014. (Citado na página 32).

[49] S. S. Das e A. Mohan, "Medical image enhancement techniques by bottom hat and median filtering", *International Journal of Electronics Communication and Computer Engineering*, 2014. (Citado na página 32).

[50] I. S. Institute, DRIVE Dataset, URL: <http://www.isi.uu.nl/Research/Databases/DRIVE/>, Último Acesso: 30 de Agosto de 2018. (2 citações nas páginas xiv, e 65).

[51] L. Soh e C. Tsatsoulis, "Texture Analysis of SAR Sea Ice Imagery Using Gray Level Co-Occurrence Matrices", *IEEE Transactions on Geoscience and Remote Sensing*, vol. 37, no. 2, 1999. (2 citações nas páginas xvii, e 35).

[52] D A. Clausi, "An analysis of co-occurrence texture statistics as a function of grey level quantization", *Can. J. Remote Sensing*, vol. 28, no. 1, pp. 45-62, 2002. (Citado na página 35).

[53] M. V. Boland, URL: [http://murphylab.web.cmu.edu/publications/boland/boland\\_node26.html](http://murphylab.web.cmu.edu/publications/boland/boland_node26.html)  
Ultimo Acesso: 30 de Agosto de 2018. (2 citações nas páginas xiv, e 35).

[54] D. Zhang, D. M. Monro e S. Rakshit, "Eyelash removal method for human iris recognition", *IEEE International Conference on image processing*, pp. 285–288, 2006. (Citado na página 24).

[55] T.H. Min e R.H. Park, "Eyelid and eyelash detection method in the normalized iris image using the parabolic Hough model and Otsus thresholding method", *Pattern Recognition Letters*, vol. 30, pp. 1138—1143, 2009. (3 citações nas páginas xiii, 24, e 25).

[56] N. Otsu, "A threshold selection method from gray-level histogram", *IEEE Transactions on Systems, Man, and Cybernetics*, pp. 62–66, 1979. (Citado na página 24).

[57] M. S. Haleem, M. Salman, L. Han, J. van Hemert, B. Li e A. Fleming, "Automated feature extraction for early detection of diabetic retinopathy in fundus images", *IEEE Journal of Biomedical and Health Informatics*, 2015. (Citado na página 25).

[58] S. Ravishankar, A. Jain e A. Mittal, "Retinal Area Detector From Scanning Laser Ophthalmoscope (SLO) Images for Diagnosing Retinal Diseases", *Proceedings of the IEEE conference on computer vision and pattern Recognition*, pp. 210–217, 2009. (Citado na página 25).

[59] X. Zhang, G. Thibault, E. Decenciere, B. Marcotegui, B. Laÿ, R. Danno, G. Cazuguel, G. Quellec, M. Lamard, P. Massin, *et al*, "Exudate detection in color retinal images for mass screening of diabetic retinopathy", *Medical Image Analysis*, pp. 1026–1043, 2014. (Citado na página 26).

[60] Prasanna Porwal e Manesh Kokare, "A Novel Method to Remove Bright Artifacts for Enhancing Lesion Detection in Retinal Images", *Signal and Information Processing (IconSIP)*, pp. 1–5, 2016. (Citado na página 26).