



Filipe Alexandre Joaquim Francisco

Licenciatura em Ciências da Engenharia

RetQuality – Validador de qualidade de retinografias

Dissertação para obtenção do Grau de Mestre em
Engenharia Eletrotécnica e de Computadores

Orientador: André Damas Mora, Professor Auxiliar, FCT-UNL
Co-orientador: José Manuel Fonseca, Professor Auxiliar, FCT-UNL

Júri:

Presidente: Prof. Doutora Anabela Monteiro Gonçalves Pronto
Arguente: Prof. Doutor Pedro Manuel Cardoso Vieira
Vogais: Prof. Doutor José Manuel Matos Ribeiro da Fonseca
Prof. Doutor André Teixeira Bento Damas Mora



FACULDADE DE
CIÊNCIAS E TECNOLOGIA
UNIVERSIDADE NOVA DE LISBOA

Junho 2013

Copyright

Copyright©2013 - Todos os direitos reservados. Filipe Alexandre Joaquim Francisco.
Faculdade de Ciências e Tecnologia. Universidade Nova de Lisboa.

A Faculdade de Ciências e Tecnologia e a Universidade Nova de Lisboa têm o direito, perpétuo e sem limites geográficos, de arquivar e publicar esta dissertação através de exemplares impressos reproduzidos em papel ou de forma digital, ou por qualquer outro meio conhecido ou que venha a ser inventado, e de a divulgar através de repositórios científicos e de admitir a sua cópia e distribuição com objetivos educacionais ou de investigação, não comerciais, desde que seja dado crédito ao autor e editor.

Agradecimentos

No fim de esta importante etapa da minha vida gostaria de fazer alguns agradecimentos pelo todo o apoio que me foi dado.

Gostaria de agradecer ao meu Orientador Professor Doutor André Damas Mora por todo apoio dado nesta última etapa do meu percurso. Demonstrou sempre uma total disponibilidade e boa disposição que tornaram todas as barreiras encontradas mais facilmente ultrapassáveis. Um muito obrigado para o meu Co-orientador Professor José Manuel Fonseca pelo seu apoio neste projeto.

Gostaria também de agradecer aos meus colegas de curso e amigos, particularmente a David Rodrigues e Rui Taborda pela vossa amizade e apoio ao longo de todo o percurso.

O completar desta etapa só se tornou possível, em grande parte, porque apareceu alguém na minha vida que me tornou um estudante e essencialmente um ser humano melhor. Essa pessoa é Carla Santos, minha namorada há seis anos. Gostaria, nesta altura, de lhe agradecer o apoio indispensável e o seu encorajamento permanente para que conseguisse atingir este objetivo.

Um muito obrigado à minha família, em especial à minha Mãe, Avós e Irmã. Tornaram tudo mais fácil, apoiando-me sempre, acreditando e fazendo-me acreditar de que era capaz...e fui!

Por fim, gostaria de fazer um agradecimento muito especial ao meu Pai. Infelizmente já não me vê acabar esta etapa da minha vida e como ele iria gostar de ma ver acabar. Mas infelizmente demorei demasiado tempo, por isso faço-lhe também um pedido de desculpa. Nunca o esquecerei...

Resumo

A avaliação da qualidade de imagem da retina é um contributo importante na obtenção de métodos automáticos de deteção de patologias retinianas fiáveis. Imagens de fraca qualidade dificultam uma análise correta da retina e poderão levar a falsos diagnósticos. Vários artigos publicados indicam que entre 10% a 15% das imagens são rejeitadas devido à sua fraca qualidade.

Esta dissertação visou desenvolver um método de classificação automática da qualidade de imagens retinianas capturadas através de uma câmara de *fundus* e que permitisse, em tempo real, fornecer *feedback* ao operador sobre a qualidade das imagens adquiridas. Por intermédio desse *feedback*, ações corretivas poderiam ser tomadas e perdas de informação ou inconvenientes para o paciente poderiam ser evitados.

A classificação da qualidade das imagens baseou-se numa avaliação genérica da qualidade da imagem em termos de contraste, focagem e iluminação. Foram extraídas doze características do domínio espacial e duas características do domínio da frequência. Através destas características foi gerada uma árvore de decisão que permitiu efetuar a classificação da qualidade das imagens. De um conjunto de 161 imagens, 67% foram utilizadas como conjunto de treino na geração da árvore de decisão e 33% como conjunto de teste. O método desenvolvido obteve uma sensibilidade de 90.91% e uma especificidade de 92%, o que demonstrou a aplicabilidade do método desenvolvido.

Palavras-chave: Retina; Qualidade de Imagem; Processamento de Imagem, Classificação Automática.

Abstract

Assessing retinal image quality is an important contribution to achieve reliable automated retinal pathologies detection. Images of poor quality hinder a correct analysis of the patient's retina and may lead to incorrect diagnosis. Various published articles indicate that between 10% and 15% of images are rejected due to poor quality.

This work aimed to develop a method for automatic quality classification, in real time, of retinal images captured through a fundus camera, providing feedback to the operator. Through this real-time feedback, corrective actions could be taken and information loss or inconvenience to the patient could be avoided.

Image quality classification was based on contrast, focus and illumination evaluation on the overall image. Were extracted twelve features from space domain and two features from frequency domain. Through these features was generated a decision tree that allowed images quality classification. From a dataset containing 161 images, 67% were used in the decision tree generation and 33% in its test. The method developed obtained 90.91% sensitivity and 92% specificity.

Keywords: Retina; Image Quality; Image Processing; Automatic Classification.

Índice

CAPÍTULO 1 - INTRODUÇÃO.....	1
CAPÍTULO 2 - ESTADO DA ARTE	7
2.1. CLASSIFICADORES DE QUALIDADE DE IMAGEM DA RETINA.....	7
2.2. A TRANSFORMADA DE FOURIER NA AVALIAÇÃO DA QUALIDADE DE IMAGEM	9
2.3. LOCALIZAÇÃO DO DISCO ÓPTICO	11
2.4. SUMÁRIO	12
CAPÍTULO 3 - METODOLOGIA.....	13
3.1. ESTRUTURAÇÃO DO TRABALHO DESENVOLVIDO.....	13
3.2. PRÉ-PROCESSAMENTO	14
3.3. EXTRAÇÃO DE CARACTERÍSTICAS.....	21
3.3.1. Domínio espacial	21
3.3.2. Domínio da frequência	23
3.3.3. Localização do Disco Óptico	24
3.4. CLASSIFICAÇÃO DAS IMAGENS	25
3.5. APLICAÇÃO DESENVOLVIDA (RETQUALITY).....	28
CAPÍTULO 4 - ANÁLISE E DISCUSSÃO DOS RESULTADOS	31
4.1. RESULTADOS.....	31
4.2. DISCUSSÃO DOS RESULTADOS.....	33
CAPÍTULO 5 - CONCLUSÕES E TRABALHO FUTURO.....	35
5.1. CONCLUSÕES	35
5.2. TRABALHO FUTURO.....	36
BIBLIOGRAFIA.....	37

Índice de Figuras

Figura 1.1 – Câmara de fundus.....	1
Figura 1.2 – Imagem do fundo ocular.	2
Figura 1.3 – Imagem do fundo ocular com Retinopatia Diabética	3
Figura 1.4 – Imagem do fundo ocular com Degeneração Macular Relacionada à Idade.4	
Figura 1.5 – Exemplos de imagens inválidas.....	4
Figura 2.1 – Definição das sete regiões.....	8
Figura 2.2 – Exemplo de impressões digitais: (a) Impressão digital de baixa qualidade; (b) Imagem digital de alta qualidade.	10
Figura 2.3 – Espectro de energia: (a) Impressão digital de baixa qualidade; (b) Impressão digital de alta qualidade.....	10
Figura 2.4 – Energia normalizada.	11
Figura 3.1 – Exemplo de imagens: (a) Imagem válida; (b) Imagem inválida.....	13
Figura 3.2 – Exemplo de uma imagem do banco de imagens.....	14
Figura 3.3 – Definição da ROI.....	15
Figura 3.4 – Algoritmo da operação de localização de cada região.	15
Figura 3.5 – Exemplo de um histograma.	16
Figura 3.6 – Binarização da imagem.....	17
Figura 3.7 – Dois tipos de imagem suportados.....	17
Figura 3.8 – Localização dos pontos em imagens do tipo A.....	18
Figura 3.9 – Localização dos pontos em imagens do tipo B.....	19
Figura 3.10 – Definição da localização das regiões.....	20

Figura 3.11- Decomposição da imagem nos canais Red,Green,Blue (RGB):a) imagem RGB; b) Canal Vermelho; c) Canal Verde; d) Canal Azul	21
Figura 3.12- Decomposição da transformada de Fourier na componente amplitude e fase: (a) Imagem original; (b) Amplitude; (c) Fase	23
Figura 3.13 – Exemplo em que não existe troca dos dados das regiões 1 e 2.	24
Figura 3.14 – Exemplo em que existe troca dos dados das regiões 1 e 2.	25
Figura 3.15 – Árvore de decisão gerada pelo CART.	26
Figura 3.16 – Layout da aplicação.	28

Índice de Tabelas

Tabela 3.1 – Definição de cada região.....	20
Tabela 3.2 – Características do domínio espacial.	21
Tabela 3.3 – Características do domínio da frequência.....	23
Tabela 3.4 – Importância de cada variável na construção do classificador.....	26
Tabela 3.5 – Importância de cada variável na construção do classificador (apenas nós principais).	27
Tabela 4.1 – Distribuição da classificação das imagens obtida pelo conjunto de treino	32
Tabela 4.2 – Desempenho do classificador com o conjunto de treino.	32
Tabela 4.3 – Distribuição da classificação das imagens obtida pelo conjunto de teste. 33	
Tabela 4.4 – Desempenho do classificador com o conjunto de teste.....	33
Tabela 4.5 – Comparação de resultados com outros métodos.	34

Lista de Abreviaturas

- DFT** - Discrete Fourier Transform
- DM** - Diabetes *Mellitus*
- DMRI** - Degeneração Macular Relacionada à Idade
- DO** - Disco Óptico
- JPEG** - *Joint Photographic Experts Group*
- RD** - Retinopatia Diabética
- RGB** - *Red, Green, Blue*
- ROI** - Região de Interesse (*Region of Interest*)

Capítulo 1 - Introdução

A obtenção de imagens da retina de alta qualidade é de grande importância, pois providenciam informação crítica que permite diagnosticar patologias oculares tais como, a Retinopatia Diabética (RD) e a Degeneração Macular Relacionada à Idade (DMRI). São patologias que afetam cada vez um número maior de pessoas nos dias de hoje, estimando-se que no ano 2050 o número de pessoas afetadas com RD triplique nos Estados Unidos (Saaddine et al. 2008).

Um dos métodos mais comuns de aquisição de imagens da retina é através de uma câmara de *fundus*. A câmara de *fundus* (Figura 1.1) proporciona uma vista ampliada do fundo da superfície da retina: nervo óptico, mácula e do pólo posterior (Giancardo 2008). É um equipamento que é utilizado por optometristas, oftalmologistas e outro tipo de especialistas para diagnosticar e monitorar doenças da retina. Comparado com outro tipo de equipamento, como o oftalmoscópio, é relativamente maior, mas tem a vantagem de a imagem poder ser examinada por um especialista noutro local e/ou tempo, assim como permitir o seu armazenamento para futura comparação com outros exames. Nesta tese são analisadas imagens recolhidas por este tipo de equipamento.




Figura 1.1 – Câmara de *fundus*.

Um exame médico à retina é usualmente dividido em dois passos: aquisição da imagem e posterior diagnóstico. A qualidade da imagem é subjetivamente avaliada pela pessoa que efetua a captura da imagem e um inexperiente fotógrafo pode aceitar imagens de baixa qualidade. Em telemedicina, a transmissão de uma imagem de baixa qualidade poderia significar, no pior caso um diagnóstico errado, e na melhor das hipóteses, a repetição do exame por parte do paciente.

Num estudo realizado a 2771 pacientes, 11% das imagens foram consideradas inválidas. Destas imagens inválidas aproximadamente 25% deviam-se a fraca fixação do paciente, 25% devido a deficiente focagem, 25% devido ao tamanho demasiado pequeno da pupila e as restantes razões foram indeterminadas (Zimmer-Galler & Zeimer et al. 2006).

A retina é a porção do olho onde se formam as imagens que vemos. É composta por células que são sensíveis à luz, os cones e bastonetes, que quando excitados, transformam a energia luminosa em sinais nervosos que são transmitidos ao córtex cerebral através do nervo óptico (Guyton & Hall 2002).

O nervo óptico situa-se na parte posterior do globo ocular. Dentro do olho este ponto é visto como o disco óptico (DO), onde não existem células sensíveis à luz, sendo, por essa razão, o ponto cego do campo de visão (Galloway et al. 2006).

A mácula é uma zona de forma oval que se situa perto do centro da retina tendo um comprimento de 4.55 mm encontrando-se a uma distância de 3 mm do DO. Perto do seu centro encontra-se a fóvea, que é uma região rica em cones e é responsável pela visão central, a cores e detalhada que é essencial para o ser humano ler, escrever e fazer outras atividades onde uma visão com acuidade seja necessária. A parte restante da retina é composta essencialmente por bastonetes que são menos sensíveis às cores mas, por outro lado, são mais sensíveis à baixa intensidade da luz. Em ambientes mais escuros são os bastonetes que se encarregam da nossa visão (Ferris & Easty 1998).




Figura 1.2 – Imagem do fundo ocular.

Uma das patologias mais recorrentes da retina é a RD (Figura 1.3), que é uma manifestação ocular de diabetes *Mellitus* (DM). DM é uma doença metabólica caracterizada por um aumento anormal de glicose no sangue. Não sendo tratada pode provocar diversas complicações, sendo a RD a desordem microvascular mais comum causada pela DM e a principal causadora de perda visual (Soares 2013).

Estudos revelaram que é uma doença que afeta até 80% das pessoas que tenham diabetes há mais de 10 anos (Kertes et. al. 2007). Apesar destas estatísticas, no máximo 90% dos novos casos poderiam ser evitados caso existisse um apropriado e vigilante tratamento e monitorização da retina (Tapp 2003).



Figura 1.3 – Imagem do fundo ocular com Retinopatia Diabética (Departamento dos Assuntos dos Veteranos dos Estados Unidos da América)

Outra das patologias que afeta uma considerável parte da população é a DMRI. É uma doença degenerativa da retina que afeta essencialmente pessoas acima dos 50 anos, sendo uma das maiores causas de cegueira de pessoas dessa faixa etária, estimando-se que existam 25 a 30 milhões de pessoas afetadas pela doença (Bupa 2010). Provoca uma perda da visão central devido ao dano na retina, mais precisamente na mácula e, uma vez que a esperança média de vida nos países desenvolvidos se encontra a aumentar, é crível que o número de pessoas afetadas pela doença venha no futuro a aumentar.



Figura 1.4 – Imagem do fundo ocular com Degeneração Macular Relacionada à Idade (*Retina Specialists*).

O uso de métodos de detecção automática de patologias oculares poderia contribuir para um diagnóstico precoce de patologias, como a RD e DMRI, tornando dessa forma o tratamento mais eficaz, podendo nalguns casos curar o paciente e noutros atrasar ou reduzir a severidade das patologias.

No entanto existem ainda alguns problemas a ultrapassar de maneira a desenvolver um método de detecção totalmente automático e fiável e que não proporcione um falso diagnóstico. Um dos problemas é a necessidade de garantir uma qualidade mínima das imagens da retina de forma que, o método de detecção automática de patologias seja fidedigno.

Na Figura 1.3 encontram-se três exemplos de imagens inválidas que ilustram a falta de visibilidade das estruturas anatómicas da retina e que impossibilitam um correto diagnóstico.



Figura 1.5 – Exemplos de imagens inválidas.

O trabalho desenvolvido nesta tese visou elaborar um algoritmo que, de forma automática e em tempo real, pudesse classificar uma imagem da retina como válida ou inválida. Poucos trabalhos foram desenvolvidos até hoje nesta área de classificação da qualidade de imagens da retina, mas nos últimos tempos tem sido alvo de um maior interesse por grupos de investigação, em parte devido ao uso, de cada vez mais, de métodos de detecção automáticos de patologias.

A tese encontra-se estruturada da seguinte forma: no capítulo 2 é feita uma revisão de alguns algoritmos e soluções propostas por outros autores para a avaliação da qualidade de imagens da retina, assim como um levantamento de métodos utilizados para a deteção do DO. No mesmo capítulo é realizada uma revisão da utilização da transformada de Fourier na avaliação da qualidade de imagem; o capítulo 3 apresenta o algoritmo proposto para a classificação da qualidade de imagem da retina; no capítulo 4 são apresentados e discutidos os resultados obtidos e por fim no capítulo 5 efetua-se um resumo dos pontos mais importantes da tese e projeta-se o trabalho a desenvolver no futuro.

2.1. Classificadores de qualidade de imagem da retina

Num contexto de uma crescente utilização de métodos de deteção automática de patologias como a RD, DMRI e outras patologias oftalmológicas, o papel desempenhado pelo classificador de qualidade de imagens da retina ganha uma importância fundamental, pois permite rejeitar imagens de baixa qualidade e por consequência fazer com que os métodos de deteção automática de patologias sejam mais fiáveis.

Na pesquisa realizada verificou-se que existem, essencialmente, dois tipos de classificadores de qualidade de imagens da retina: os que se focam na qualidade genérica da imagem e os que avaliam a qualidade da imagem tendo como critério a identificação das estruturas anatómicas da retina.

Classificadores que se baseiam na qualidade genérica da imagem têm como vantagem o facto de que, dessa forma evitam o processamento de segmentação das estruturas anatómicas da retina que, por norma, é complexo e por essa razão consome mais tempo de processamento.

Lee e Wang (Lee & Wang 1999) propuseram um método que se enquadra neste tipo de classificadores. Os autores propuseram um método onde inicialmente é definido um histograma de intensidade padrão a partir de 20 imagens de retina de excelente qualidade. A largura do histograma pode ser interpretada como medida de avaliação do contraste da imagem, sendo uma característica chave neste método. A qualidade da imagem é avaliada através da convulsão do seu histograma de intensidade com o histograma padrão e pelo cálculo de um índice de qualidade Q. O índice de qualidade Q tem um valor entre 0 e 1, em que 0 significa uma imagem de muito fraca qualidade e 1 uma imagem de excelente qualidade.

Esta abordagem por si só não obteve grandes resultados e como é referido por Lalonde et al. (Lalonde et al. 2001), "A ligação entre semelhanças de histogramas e qualidade

de imagem não é assim tão forte”. Lalonde que no mesmo artigo propôs uma abordagem ligeiramente diferente focando-se na distribuição local da intensidade dos pixels em oposição à distribuição global de Lee e Wang.

Em 2009, Davis et al. (Davis et al. 2009) propôs um método em que a qualidade da imagem é avaliada através de uma avaliação da luminosidade e do contraste. A imagem é dividida em sete regiões das quais extrai 17 características por cada canal de cor no espaço CIELab.




Figura 2.1 – Definição das sete regiões (Davis et al. 2009).

CIELab é um espaço de cores uniformemente distribuídas, de cromaticidade uniforme. Tem uma distribuição perceptualmente uniforme, luminosidade separada da cromaticidade e é a representação dos contrastes cromáticos naturais do ser humano. Esta aproximação à visão do ser humano melhora a descoberta de uma relação entre as características extraídas e a avaliação que um especialista faz da qualidade da imagem.

As características escolhidas para efetuar a avaliação da luminosidade da imagem foram:

- Intensidade média – Permite avaliar a intensidade de cada cor na imagem;
- Assimetria – Avalia a simetria da imagem, ou mais precisamente, a falta dela;
- Kurtosis – É uma característica que avalia se o histograma da imagem tem altos ou se é plano relativo a uma distribuição normal.

As características que permitiram avaliar o contraste da imagem foram:

- Variância – Um valor baixo reflete fraco contraste, independentemente do brilho da imagem;
- 8 Características de Haralick (Haralick et al. 1973) – Explora a relação de um pixel com os outros pixels na sua vizinhança. A distribuição de diferentes intensidades numa escala de cinzentos entre estes pixels é utilizada para calcular um valor de contraste;

Entropia – É uma característica que representa os níveis de cinzentos quantizados;

Frequência espacial – É uma característica que é afetada tanto por contraste como por ruído e por si só não produz um indicador de qualidade.

Os resultados obtidos na classificação das imagens por este método foram uma sensibilidade de 100% e uma especificidade de 96%.

Noutro tipo de classificadores pesquisados, a presença de vasos sanguíneos e de outras estruturas anatómicas são usados como critério avaliador da qualidade das imagens. Em 2006, Fleming et al. (Fleming et al. 2006) propôs um método baseado na nitidez e definição de campo. Uma imagem é considerada com adequada nitidez desde que exista detalhe suficiente que se consiga efetuar automaticamente a detecção de RD. A visibilidade dos vasos macular foi utilizada como indicador da nitidez da imagem, uma vez que estes vasos são conhecidos por serem estreitos e tornam-se menos visíveis com a degradação da imagem. Uma imagem é considerada com adequada definição de campo desde que seja visível, entre outras estruturas anatómicas, o DO e pelo menos dois discos ópticos de diâmetro de visível retina em redor da fóvea. Os resultados obtidos por este método foram uma sensibilidade de 99.1% e uma especificidade de 89.4%.

2.2.A Transformada de Fourier na avaliação da qualidade de imagem

O processamento de imagens no domínio da frequência é realizado através de uma transformação do domínio espacial, que é o domínio no qual uma imagem se encontra inicialmente, para o domínio da frequência, utilizando para o efeito, a transformada de Fourier. É uma ferramenta matemática muito útil pois permite que a informação visual seja representada de uma outra forma, sem que para isso exista perda de informação durante a transformação espacial → frequência e vice-versa.

Na pesquisa realizada não foram encontrados artigos em que a qualidade de imagem da retina fosse avaliada por intermédio da transformada de Fourier, no entanto foram encontrados artigos noutras áreas do processamento de imagem, em que a mesma é utilizada para efetuar a avaliação da qualidade de imagem.

Uma das áreas onde foi encontrada a utilização da transformada de Fourier, mais concretamente a transformada discreta de Fourier (*Discrete Fourier Transform - DFT*), foi na análise de impressões digitais.

Y. Chen et al. em 2005, desenvolveu um método de avaliação da qualidade de imagem de uma impressão digital através do cálculo da DFT. Numa impressão digital as cristas papilares residem numa determinada gama de frequências. A região de interesse do espectro de frequência é uma região circular compreendida entre o valor mínimo e máximo de frequência nas quais se encontram tipicamente os valores de frequência das cristas papilares. À medida que a qualidade da impressão digital aumenta, assim também aumenta a concentração de energia na região de interesse. Para efetuar a avaliação da qualidade da

imagem, um índice de qualidade Q_F é calculado em função da concentração de energia em regiões de forma anelar que se encontram dentro da região de interesse. Com base neste conceito, um conjunto de filtros passa-banda é aplicado de forma a extrair a energia de cada gama de frequências. Imagens de alta qualidade terão a energia concentrada em poucas gamas de frequência enquanto imagens de baixa qualidade terão a energia distribuída por várias gamas de frequência. Na Figura 2.2 encontram-se duas impressões digitais de diferentes qualidades que foram submetidas ao método proposto por Y. Chen et al. e cujos resultados podem ser visualizados na Figura 2.3.




Figura 2.2 – Exemplo de impressões digitais: (a) Impressão digital de baixa qualidade; (b) Imagem digital de alta qualidade. (Alonso-Fernandez et al. 2005)

Através da Figura 2.3 é possível ver os diferentes espectros de energia que cada imagem possui. Verifica-se que na Figura 2.3 (b), que corresponde à impressão digital de alta qualidade, a energia encontra-se concentrada numa gama de frequências menor comparativamente à Figura 2.2 (a) referente à impressão digital de baixa qualidade em que a energia se encontra mais dispersa.




Figura 2.3 – Espectro de energia: (a) Impressão digital de baixa qualidade; (b) Impressão digital de alta qualidade. (Alonso-Fernandez et al. 2005)

O mesmo se pode concluir através da Figura 2.4 que é uma representação da energia normalizada em função da gama de filtros passa-banda aplicados.

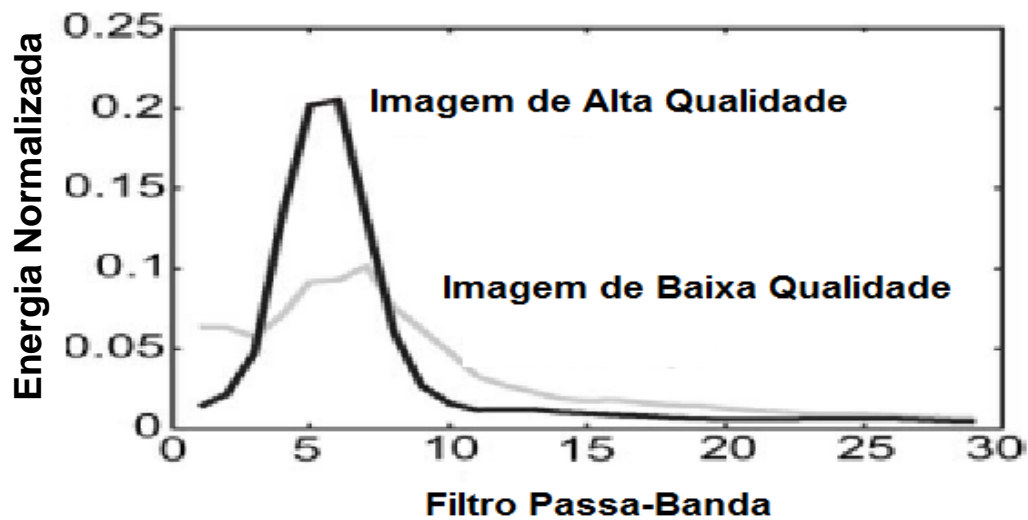


Figura 2.4 – Energia normalizada.(Adaptado de Alonso-Fernandez et al. 2005)

2.3. Localização do Disco Óptico

A deteção do DO desempenha um papel muito importante em métodos de deteção automática de patologias, uma vez que a sua localização é muitas vezes usada como ponto de referência devido ao facto de a distância do DO ao centro da fóvea ser constante e de esta ser o centro da mácula.

Em 1989, Chaudhuri et al. baseou-se no facto de geralmente o DO ser a zona mais brilhante da imagem da retina para dessa forma identificar a localização do DO. Este método por si só, poderá não ser muito fidedigno uma vez que por vezes poderão existir outras zonas mais brilhantes presentes na imagem da retina provocado por outros fatores como exsudados.

Walter e Klein em 2001, propuseram um método que partiu do pressuposto de que as zonas brilhantes, como exsudados, se encontram longe do tamanho do DO. Para localizar o DO é feita uma seleção das zonas mais brilhantes da imagem da retina através da binarização da imagem, a partir da qual se seleciona o maior e mais brilhante objeto ligado da imagem da retina. No conjunto de imagens testado pelos autores foi obtida uma percentagem de sucesso de 100%.

Para além dos métodos que se baseiam no estudo da intensidade do DO para o localizarem, existe um outro tipo de método que consiste numa deteção preliminar dos principais vasos sanguíneos. Todos os vasos sanguíneos têm origem no DO e os seus caminhos seguem um padrão semelhante a uma parábola em todas as imagens, por essa razão, ao se efetuar a deteção dos vasos sanguíneos e percorrendo o seu caminho é possível localizar o DO (Foracchia et al. 2004). Foi um método que obteve uma percentagem de sucesso de 97.5% utilizando a base de dados de imagens da retina STARE. Em 2008 Youssif

et al. apresentou um método que consistia num *matching* da direção expectável do padrão dos vasos sanguíneos, o qual também obteve bons resultados com 98.77% de taxa de sucesso na identificação do DO.

2.4. Sumário

Dos trabalhos pesquisados, foram encontrados métodos de classificação automática de imagens com bons desempenhos, particularmente os apresentados por Davis et al. (Davis et al. 2009) e Fleming et al. (Fleming et al. 2006) que tendo desempenhos semelhantes baseiam-se em conceitos de avaliação da qualidade de imagem diferentes.

Embora não tenha sido encontrado nenhum trabalho na área da avaliação da qualidade de imagem da retina em que a transformada de Fourier fosse utilizada, foi possível encontrar a sua utilização em outras áreas, tais como a impressão digital, onde se observou a obtenção de bons resultados.

O trabalho desenvolvido visou um classificador que se baseasse na qualidade genérica da imagem. Um dos objetivos era a sua utilização em cenários que requisitassem uma avaliação em tempo real e em termos de tempo de processamento, este tipo de classificadores é melhor, pois, como referido anteriormente, não existe necessidade de segmentar as estruturas anatómicas da retina para avaliar a qualidade da imagem. Teve como ponto de partida o método apresentado por Davis et al. (Davis et al. 2009) a partir do qual se decidiu efetuar algumas modificações que se julgaram necessárias no sentido de diminuir o número de características a extrair. Devido aos bons resultados obtidos em outras áreas do processamento de imagem pela transformada de Fourier na avaliação da qualidade de imagem, decidiu-se inclui-la no conjunto de características a extrair da imagem. No próximo capítulo irá ser descrito em detalhe a metodologia desenvolvida.

3.1. Estruturação do trabalho desenvolvido

A classificação da qualidade das imagens da retina baseou-se numa avaliação da qualidade genérica da imagem em termos de contraste, focagem e luminosidade.

O algoritmo desenvolvido é composto por 3 fases:

- Pré-processamento;
- Extração de características;
- Classificação das imagens.

Numa primeira fase estabeleceu-se a Região de Interesse (ROI – *Region of Interest*) da qual, foram extraídas características numa segunda fase. Por fim, com base nessas características, foi gerada uma árvore de decisão que permitiu classificar a qualidade das imagens.




Figura 3.1 – Exemplo de imagens: (a) Imagem válida; (b) Imagem inválida.

Na Figura 3.1 a) é possível visualizar um exemplo de uma imagem válida presente no banco de imagens, onde se constata que nela as estruturas anatômicas da retina se encontram bem definidas. Contrariamente, na Figura 3.1 b), encontra-se um exemplo de uma imagem inválida pois nela não é possível identificar estruturas anatômicas da retina como o DO, que é essencial para um correto diagnóstico.

3.2. Pré-processamento

Uma vez que o objetivo é classificar a qualidade da imagem e não melhorá-la, com o pré-processamento, pretende-se essencialmente, definir a ROI a partir da qual se efetuará a extração de características.

O banco de imagens usado neste trabalho provem de um rastreamento ocular a decorrer a nível nacional e é composto por imagens a cores em formato JPEG (*Joint Photographic Experts Group*). As imagens têm uma dimensão de 2896x1944 pixels com 24 bits de profundidade de cor, ou seja, 8 bits por canal RGB (Figura 3.2).



Figura 3.2 – Exemplo de uma imagem do banco de imagens

Devido à complexidade dos algoritmos usados e uma vez que o tamanho das imagens fornecidas influenciavam proporcionalmente o tempo de processamento, apenas foi processada a ROI. Neste trabalho a ROI é composta por seis regiões centradas na retina como pode ser observado na Figura 3.3.




Figura 3.3 – Definição da ROI.

A decisão de dividir a ROI em várias regiões foi tomada porque desta forma é possível extrair de diferentes regiões da retina as mesmas características, e como ficará demonstrado mais adiante, existem características e/ou regiões que são mais importantes para a classificação da imagem que outras.

O algoritmo de localização das regiões na imagem encontra-se representado na Figura 3.4. Inicialmente efetua-se a binarização da imagem. Com a imagem binarizada é realizada uma deteção do contorno da retina. De seguida, selecionam-se quatro pontos de referência do contorno da retina. Com base nesses quatro pontos selecionados é calculada a localização de cada região.




Figura 3.4 – Algoritmo da operação de localização de cada região.

Pretende-se segmentar a imagem de forma a isolar a zona da retina. A binarização da imagem é uma das formas mais comuns de segmentação da imagem. Esta permite transformar uma imagem em níveis de cinzento ou cores, numa imagem apenas com dois níveis de intensidade, preto e branco. Para tal é necessário definir um valor a partir do qual essa divisão deve ser feita, a esse valor dá-se o nome de *threshold*.

Para se efetuar a binarização começa-se por converter a imagem a cores para uma imagem em níveis de cinzento. Os níveis de cinzento podem variar de 0 a 255. A conversão aproximada consiste em calcular, para cada pixel, a média das intensidades dos canais vermelho, verde e azul (Equação 3.1).

$$\text{Cinzento} \approx \frac{(\text{Vermelho} + \text{Verde} + \text{Azul})}{3} \quad (\text{Equação 3.1})$$

Por fim para se obter a imagem binária, é necessário calcular o valor de *threshold*. O primeiro passo para encontrar esse valor é calcular o histograma da imagem. O histograma calcula a abundância de cada um dos níveis de cinzento. Na Figura 3.5 encontra-se um exemplo de um histograma efetuado a uma imagem da retina em níveis de cinzento, onde é possível constatar, que existe uma clara separação do conjunto de pontos escuros dos pontos claros, e por essa razão o histograma é bimodal.

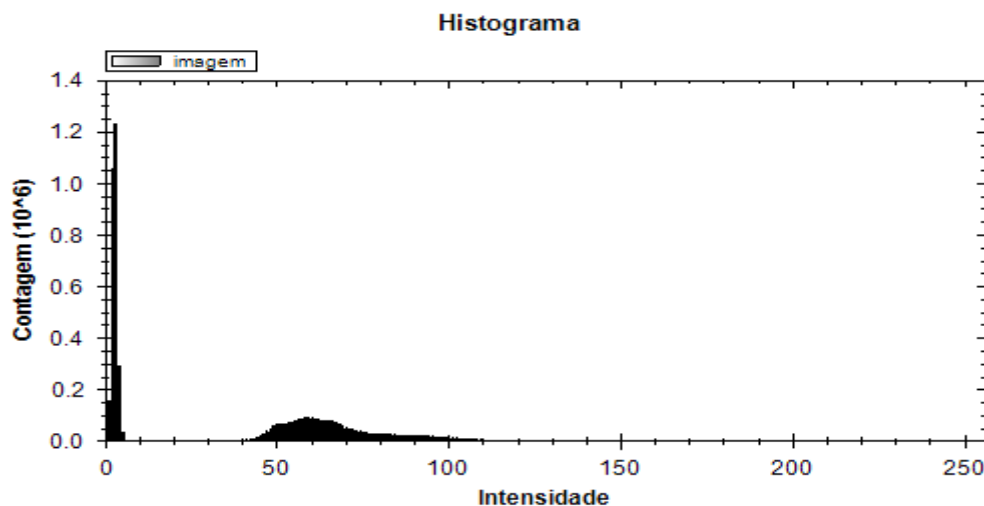


Figura 3.5 – Exemplo de um histograma.

O método utilizado para selecionar o nível de *threshold* é o da minimização da variância intra-grupos (Otsu 1975), que consiste na separação dos níveis de cinzento em dois grupos da forma mais homogênea possível. Os valores de *threshold* calculados para as imagens presentes no banco de imagens variaram entre os valores 10 e 15.




Figura 3.6 – Binarização da imagem.

Após se obter a imagem binarizada, o passo seguinte foi detetar o contorno da retina. Para o conseguirmos recorreu-se à função *FindContours* da biblioteca *OpenCV* que retorna uma lista de contornos detetados, em que cada contorno é uma lista de pontos com coordenadas XY. Para se verificar qual dos contornos é o pretendido, a área do retângulo que delimita o contorno tem de ser superior a 50% do total imagem.




Figura 3.7 – Dois tipos de imagem suportados.

De seguida, efetuou-se uma seleção de quatro pontos que se encontram no contorno da retina e que têm as seguintes particularidades:

P1 – X máximo

P2 – X mínimo

P3 – Y máximo

P4 – Y mínimo

O banco de imagens tem dois tipos diferentes de imagens, tipo A (Figura 3.7 (a)) e do tipo B (Figura 3.7 (b)). Por existirem dois tipos de imagens o método consistiu em percorrer a lista de pontos do contorno em dois sentidos como indicado na Figura 3.8 e na Figura 3.9. Para cada sentido foram encontrados os quatro pontos. Os assinalados a azul são os pontos encontrados no sentido azul, os assinalados a verde são os pontos encontrados no sentido verde e os assinalados a amarelo são o resultado da média dos pontos encontrados nos dois sentidos e estes serão os seleccionados para definir a dimensão e localização das seis regiões.

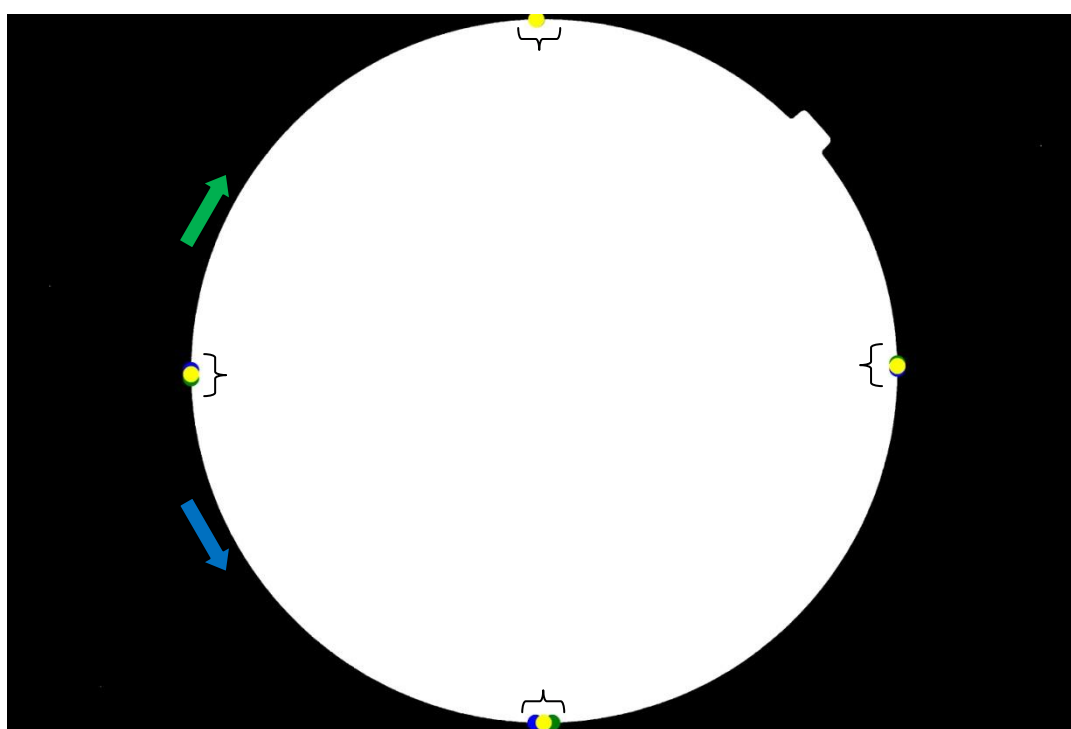


Figura 3.8 – Localização dos pontos em imagens do tipo A.

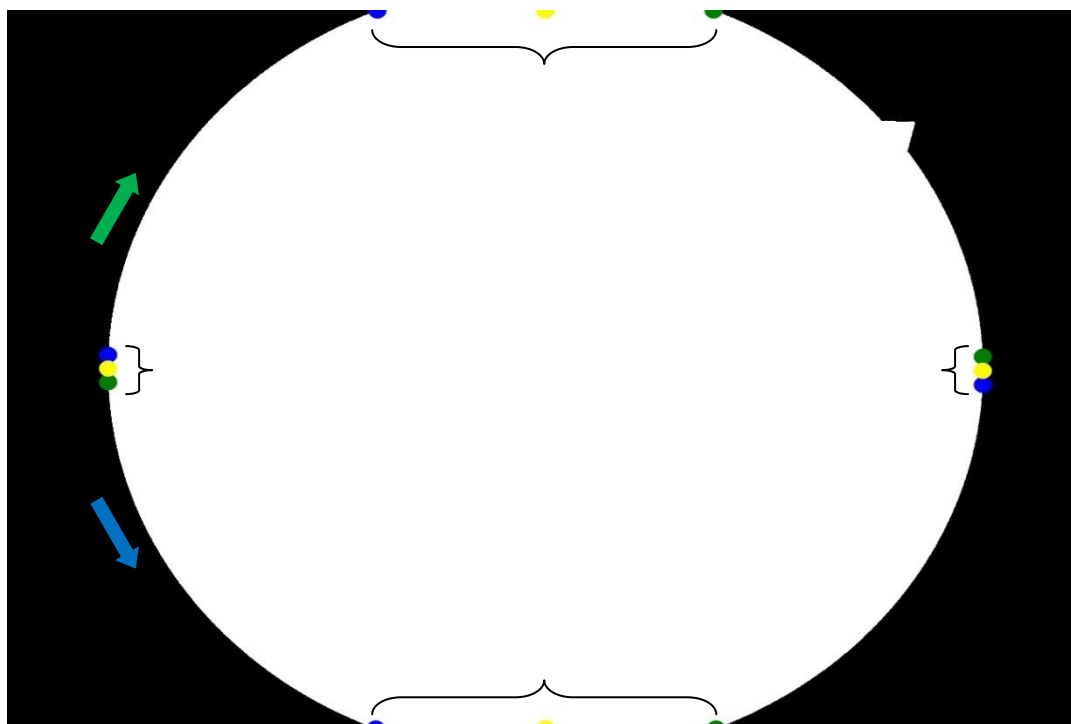


Figura 3.9 – Localização dos pontos em imagens do tipo B.

Para se definir a localização de cada região é necessário efetuar cálculos auxiliares que são apresentados a seguir e cuja representação é possível visualizar na Figura 3.10:

$$Q_L = \frac{(X_{\text{máximo}} - X_{\text{mínimo}})}{3} \times 0.8 \quad (\text{Equação 3.2})$$

$$R_L = \frac{(X_{\text{máximo}} - X_{\text{mínimo}})}{2} \times 0.8 \quad (\text{Equação 3.3})$$

$$K = \frac{(X_{\text{máximo}} - X_{\text{mínimo}} - Q_L) \times 3}{2} \quad (\text{Equação 3.4})$$

$$Y_{\text{médio}} = \frac{(Y_{\text{máximo}} - Y_{\text{mínimo}})}{2} \quad (\text{Equação 3.5})$$

Por fim a localização de cada região é apresentada na Tabela 3.1.

Após se definir a localização de cada região, a fase de pré-processamento encontra-se finalizada.

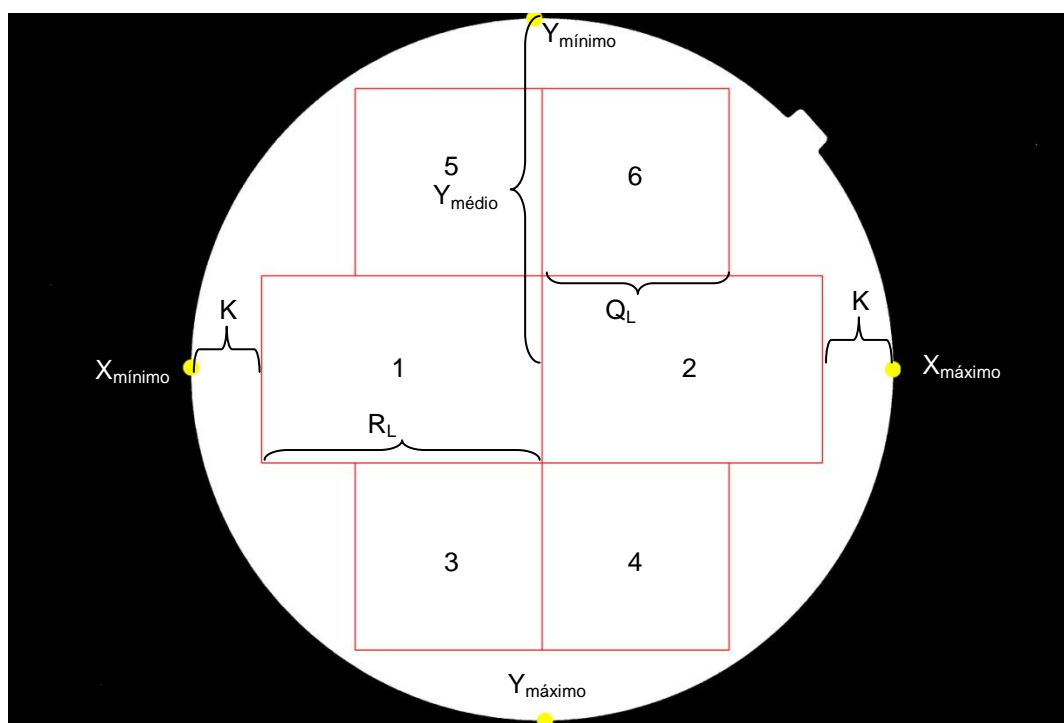


Figura 3.10 – Definição da localização das regiões.

Tabela 3.1 – Definição de cada região.

Região	$x_{inicial}$	$y_{inicial}$	Largura	Altura
1	$X_{mínimo} + K$	$Y_{médio} - \frac{Q_L}{2}$	R_L	Q_L
2	$X_{mínimo} + K + R_L$	$Y_{médio} - \frac{Q_L}{2}$	R_L	Q_L
3	$X_{mínimo} + K + \frac{Q_L}{2}$	$Y_{médio} + \frac{Q_L}{2}$	Q_L	Q_L
4	$X_{mínimo} + K + \frac{3 \times Q_L}{2}$	$Y_{médio} + \frac{Q_L}{2}$	Q_L	Q_L
5	$X_{mínimo} + K + \frac{Q_L}{2}$	$Y_{médio} + \frac{3 \times Q_L}{2}$	Q_L	Q_L
6	$X_{mínimo} + K + \frac{3 \times Q_L}{2}$	$Y_{médio} + \frac{3 \times Q_L}{2}$	Q_L	Q_L

3.3. Extração de características

As características a extrair da imagem foram escolhidas de forma a poder aferir a qualidade da imagem. Na Figura 3.11 (a) é possível verificar que a imagem da retina é na sua maior parte constituída por tons avermelhados, mas como se pode verificar pela Figura 3.11 (c) o canal verde é o que apresenta o melhor contraste das estruturas anatómicas da retina (Hipwell et al. 2000). Pela Figura 3.11 pode-se concluir ainda, que cada canal apresenta características diferentes. Por esse motivo algumas das características escolhidas foram extraídas para cada canal de cor.

As características escolhidas encontram-se divididas no domínio espacial e no domínio da frequência.




Figura 3.11- Decomposição da imagem nos canais *Red, Green, Blue* (RGB): a) imagem RGB; b) Canal Vermelho; c) Canal Verde; d) Canal Azul

3.3.1. Domínio espacial

Domínio espacial é o domínio no qual a imagem se encontra inicialmente e refere-se ao agregado de pixéis que compõem a imagem e cujos métodos são procedimentos que operam diretamente sobre esses pixéis no espaço (x,y) . Na tabela seguinte é possível visualizar as características do domínio espacial escolhidas retiradas do histograma da imagem:

Tabela 3.2 – Características do domínio espacial.

Assimetria canal vermelho	Assimetria canal verde	Assimetria canal azul
Relação da média do canal vermelho com a média do canal verde	Relação da média do canal vermelho com a média do canal azul	Relação da média do canal verde com a média do canal azul

Com a extração das relações das médias de cada canal da imagem efetua-se uma análise da luminosidade da imagem, pois são características que são calculadas em função da intensidade média de cada canal.

Através da extração da assimetria de cada canal é possível efetuar uma análise da uniformidade luminosidade da imagem, ou neste caso, da falta dela. Imagens de retina de melhor qualidade possuem, possuem por norma, uma luminosidade que não é uniforme.

De seguida, são apresentadas as equações que foram utilizadas para efetuar os cálculos das características indicadas na Tabela 3.2:

- **Assimetria para cada canal (Karl Pearson 1895)**

$$\text{Assimetria} = \left(\frac{n}{(n-1) \times (n-2)} \right) \times \sum_{i=1}^n \left(\frac{P_i - \bar{P}}{s} \right)^3 \quad (\text{Equação 3.6})$$

Em que:

- P_i - Intensidade do canal no ponto i ;
- n - Número de pontos da amostra;
- s - Desvio padrão da amostra;
- \bar{P} - Média das intensidades da amostra

- **Relação da média do canal vermelho com a média do canal verde**

$$\text{Relação}_{\text{MédiaVermelhoVerde}} = \frac{\bar{P}_{\text{Vermelho}}}{\bar{P}_{\text{Verde}}} \quad (\text{Equação 3.7})$$

Em que:

- $\bar{P}_{\text{Vermelho}}$ - Média das intensidades do canal vermelho;
- \bar{P}_{Verde} - Média das intensidades do canal verde.

- **Relação da média do canal vermelho com a média do canal azul**

$$\text{Relação}_{\text{MédiaVermelhoAzul}} = \frac{\bar{P}_{\text{Vermelho}}}{\bar{P}_{\text{Azul}}} \quad (\text{Equação 3.8})$$

Em que:

- $\bar{P}_{\text{Vermelho}}$ - Média das intensidades do canal vermelho;
- \bar{P}_{Azul} - Média das intensidades do canal azul.

- **Relação da média do canal verde com a média do canal azul**

$$\text{Relação}_{\text{MédiaVerdeAzul}} = \frac{\bar{P}_{\text{Verde}}}{\bar{P}_{\text{Azul}}} \quad (\text{Equação 3.9})$$

Em que:

- \bar{P}_{Verde} - Média das intensidades do canal verde;
- \bar{P}_{Azul} - Média das intensidades do canal azul.

3.3.2. Domínio da frequência

Para se processar a imagem no domínio da frequência é necessário efetuar uma transformação a partir do domínio espacial e uma das mais utilizadas é a transformada de Fourier, mais concretamente, a transformada discreta de Fourier, uma vez que os dados das imagens são discretos e finitos. É um método que permite decompor uma imagem num conjunto de senos e cosenos de diferentes frequências. A transformada de Fourier é dada por:

$$F(u, v) = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) e^{-j2\pi(ux/M + vy/N)} \quad (\text{Equação 3.10})$$

em que $u = x = 0, 1, \dots, M-1$ e $v = y = 0, 1, \dots, N-1$ em que M corresponde ao número de pixels na horizontal e N ao número de pixels na vertical.

A sua representação, uma vez que por vezes pode-se tornar difícil de visualizar, representa-se separadamente em amplitude e fase (Figura 3.12).

O valor de amplitude é dado por:

$$|F(u, v)| = \sqrt{R^2(u, v) + I^2(u, v)} \quad (\text{Equação 3.11})$$

E o valor da fase por:

$$\phi(u, v) = \tan^{-1}\left(\frac{I(u, v)}{R(u, v)}\right) \quad (\text{Equação 3.12})$$




Figura 3.12- Decomposição da transformada de Fourier na componente amplitude e fase: (a) Imagem original; (b) Amplitude; (c) Fase

Na Tabela 3.3 encontram-se as características escolhidas para analisar no domínio da frequência.

Tabela 3.3 – Características do domínio da frequência.

Magnitude média
Desvio padrão da magnitude

A escolha de estas características deveu-se ao facto de, em outras áreas de processamento de imagem, como a impressão digital, terem obtido bons resultados na avaliação da qualidade de imagem. Com a extração destas características foi possível efetuar uma análise ao contraste e à focagem da imagem, pois imagens com maior contraste e melhor focagem terão, por norma, valores mais elevados de magnitude média.

3.3.3. Localização do Disco Óptico

Nesta fase, em que todas as características seleccionadas foram extraídas da imagem, efetuou-se uma comparação das intensidades médias na escala de cinzentos das regiões 1 e 2. O DO é geralmente o zona mais brilhante da imagem da retina e, portanto, um conjunto de pixéis de alta intensidade na escala de cinzentos irá localizar o DO na imagem (Chaudhuri et al. 1989). Esta análise permite estudar a localização do DO, ainda que com algum grau de incerteza, uma vez que nas imagens do fundo ocular podem surgir muitas zonas com intensidades elevadas, como os exsudados, o que pode levar a uma falsa localização do DO (M. H. Goldbaum et al. 1990). Outro tipo de estudo com menor grau de incerteza foi feito, mas os resultados obtidos foram semelhantes com a agravante de adicionar tempo de processamento desnecessário. O método alternativo utilizado foi o apresentado por Foracchia et al. (Foracchia et al. 2004) e consiste numa deteção preliminar dos principais vasos sanguíneos e por essa razão o processamento é mais complexo e demorado.

Caso a intensidade média, numa escala de cinzentos, da região 1 seja superior à intensidade média, numa escala de cinzento, da região 3, existe uma troca dos dados de uma pela região pela outra, caso contrário, não existe troca. Na Figura 3.13 é possível ver um exemplo de uma imagem em que não existiu troca e na Figura 3.14 um caso em que a troca foi efetuada. Em ambas as figuras é também possível constatar que o DO foi corretamente localizado. Efetuar a troca dos dados das regiões confere uma maior consistência aos dados recolhidos pela razão anteriormente indicada.



Figura 3.13 – Exemplo em que não existe troca dos dados das regiões 1 e 2.




Figura 3.14 – Exemplo em que existe troca dos dados das regiões 1 e 2.

3.4. Classificação das imagens

Com base nas características extraídas de cada uma das regiões foi construída uma árvore de decisão para efetuar a classificação das imagens. As árvores de decisão são uma forma simples de avaliar relações por vezes complexas entre múltiplas variáveis.

Uma árvore de decisão é uma estrutura simples em que as folhas contêm classes e os nós representam atributos baseados em testes com um ramo para cada saída possível. Para se efetuar a classificação de um objeto, parte-se da raiz, e de seguida é feito um teste e consoante o seu resultado segue-se na direção do ramo correspondente. Este processo continua até se encontrar uma folha, sendo o objeto classificado consoante a classe encontrada na folha (Ruiz et al. 2008).

Para a criação da árvore de decisão recorreu-se ao *software* CART for Windows, *version* 4.0 desenvolvido pela *Salford Systems*. As opções selecionadas para a geração da árvore de decisão foram as que se encontram por defeito no programa: Gini como método de eleição do melhor atributo e o critério para a seleção da melhor árvore é o que minimiza o custo da árvore independente do tamanho da mesma. Do banco de imagens, 67% das imagens foram selecionadas como conjunto de treino para a geração da árvore de decisão.

As imagens foram classificadas numa de duas classes: válida ou inválida. Com a recolha de 48 características, 8 por região, de cada imagem do conjunto de treino, o CART gerou a seguinte árvore de decisão para a classificação da qualidade de imagens com 6 nós terminais:

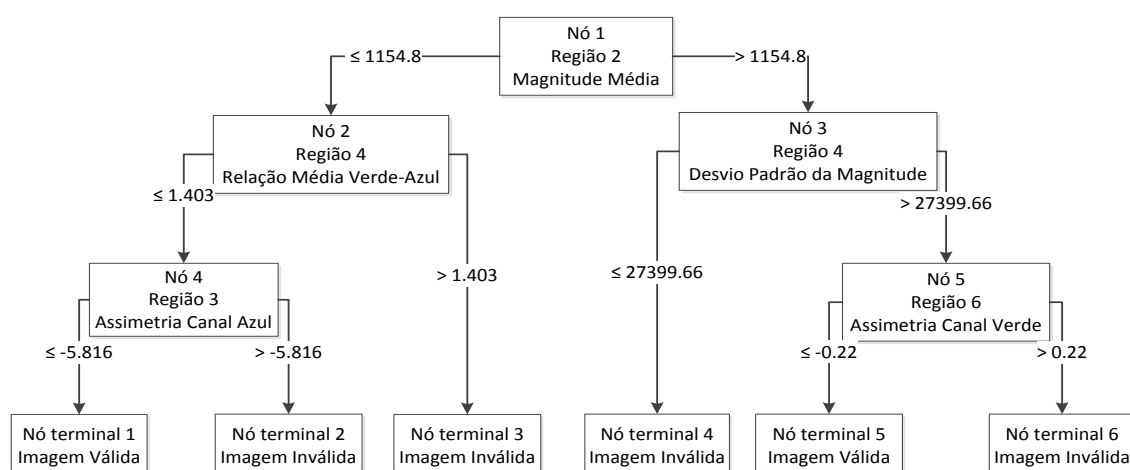


Figura 3.15 – Árvore de decisão gerada pelo CART.

Na tabela seguinte são apresentadas, por ordem de importância, as variáveis que segundo o *software* CART tiveram importância na geração do classificador: É de notar que a medida de importância é atribuída pelo *software* a todas as variáveis e não só às variáveis usadas na árvore de decisão.

Tabela 3.4 – Importância de cada variável na construção do classificador.

Variável	Pontuação
Região 2 - Magnitude média	100.00
Região 4 - Magnitude média	87.14
Região 3 - Magnitude média	87.14
Região 2 - Assimetria canal vermelho	65.25
Região 4 - Desvio padrão da magnitude	42.21
Região 5 - Magnitude média	40.81
Região 6 - Magnitude média	38.92
Região 3 - Desvio padrão da magnitude	34.19
Região 4 - Relação da média canal verde com canal azul	25.94
Região 4 - Assimetria canal verde	25.40
Região 1 - Desvio padrão da magnitude	25.40
Região 1 - Assimetria canal verde	24.95
Região 3 - Relação da média canal verde com canal azul	20.73
Região 6 - Relação da média canal verde com canal azul	20.36
Região 3 - Relação da média canal vermelho com canal azul	20.36
Região 2 - Desvio padrão da magnitude	20.01
Região 4 - Relação da média canal vermelho com canal azul	14.99
Região 2 - Relação da média canal verde com canal azul	14.99
Região 6 - Relação da média canal vermelho com canal azul	6.20
Região 6 - Assimetria canal verde	6.20
Região 6 - Relação da média canal vermelho com canal verde	6.20
Região 3 - Assimetria canal azul	5.79
Região 4 - Assimetria canal azul	3.15
Região 5 - Relação da média canal vermelho com canal verde	3.15

Analisando a Tabela 3.4, a variável que tem mais importância na construção do classificador é a magnitude média da região 2. A importância da região 2 justifica-se pelo facto de ser realizada uma deteção prévia da localização do DO, e caso se encontre na região 1, as regiões são trocadas, levando a que região 2 possua uma maior preponderância na construção do classificador. Devido ao facto de o DO se encontrar na região 2 e uma vez que o cálculo da magnitude média permite realizar uma análise do contraste e focagem da região, torna-se dessa forma um fator distintivo. Existem outras características recolhidas que têm grande importância, tais como, as magnitudes médias das regiões 3 e 4. A razão para essa importância prende-se com o facto de, mais uma vez, estas características permitirem analisar o contraste e a focagem da imagem. Pela mesma razão se pode justificar a importância do desvio padrão da magnitude média da região 4 assim como das magnitudes médias das regiões 5 e 6.

A primeira variável que surge com alguma importância que pertence ao domínio espacial é a assimetria do canal vermelho da região 2. Como descrito anteriormente, imagens com melhor qualidade têm valores de assimetria mais elevados, uma vez que não têm uma luminosidade uniforme. Esta característica juntamente com a relação da média do canal verde com o canal azul da região 4, que permite de uma outra forma, analisar a luminosidade da imagem, revelaram-se importantes na construção do classificador.

Pode-se portanto concluir após a análise da Tabela 3.4, que as variáveis do domínio da frequência, embora sendo em menor número, têm uma maior importância em comparação com as variáveis do domínio espacial.

Se nos cingirmos apenas aos nós principais, o número de variáveis diminui consideravelmente como se pode constatar pela seguinte tabela, ordenada pela ordem de importância:

Tabela 3.5 – Importância de cada variável na construção do classificador (apenas nós principais).

Variável	Pontuação
Região 2 - Magnitude média	100.00
Região 4 - Desvio padrão da magnitude	42.21
Região 4 - Relação da média canal verde com canal azul	25.94
Região 6 - Assimetria canal verde	6.20
Região 3 - Assimetria canal azul	5.79

Constata-se que a variável com mais importância continua a ser a mesma da tabela anterior, assim como se mantém a maior importância do domínio da frequência face ao domínio espacial.

Partindo de um conjunto de 48 características iniciais, após a geração do classificador, a classificação da imagem é feita apenas recorrendo a 5 características, o que reduz o tempo de classificação, uma vez que o tempo de processamento é menor.

Com a construção do classificador concluída, procedeu-se à avaliação das imagens presentes no banco de imagens, cujos resultados serão analisados no capítulo seguinte.

3.5. Aplicação desenvolvida (RetQuality)

Para validar o algoritmo proposto nesta tese foi desenvolvida a aplicação RetQuality que permite efetuar uma classificação automática da qualidade de imagens da retina. A aplicação foi desenvolvida em linguagem de programação C# e a ferramenta de desenvolvimento utilizada foi Microsoft Visual Studio 2010. A aplicação foi desenvolvida com a preocupação de ser de fácil utilização e intuitiva permitindo ao utilizador selecionar uma imagem, ou um grupo de imagens, e obter a sua classificação ao fim de poucos segundos (Figura 3.15).

Na lateral esquerda da aplicação foi colocada uma tabela contendo a lista de imagens e a sua correspondente classificação. Nessa tabela é possível visualizar o nome da imagem e o resultado da sua classificação, que tem como valores possíveis, válida e inválida. Selecionando uma imagem, esta é visualizada na parte central e onde é possível também ver cada região e a respetiva identificação, de onde foram extraídas as características.

Na parte inferior da aplicação existe uma descrição da classificação efetuada à imagem. À esquerda é identificado qual o nó terminal e quais os valores que levaram à escolha desse nó, permitindo ao utilizador visualizar de uma forma rápida quais os valores que conduziram à classificação da imagem. À direita são mostrados os valores importantes para a classificação de uma imagem. Se o utilizador desejar visualizar os valores de todas as características deverá pressionar o botão “Ver todos os valores”.

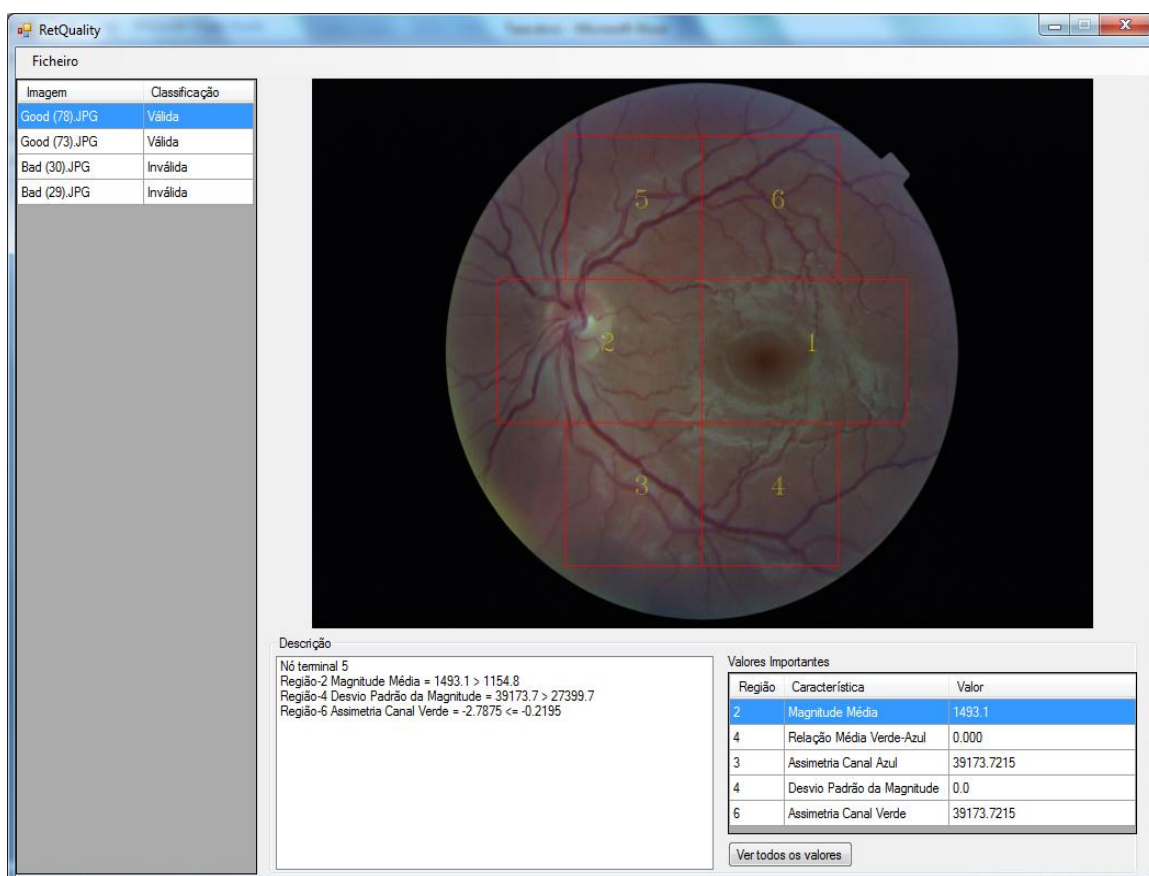


Figura 3.16 – Layout da aplicação.

Para classificar uma imagem ou mais imagens, o utilizador deverá seleccionar o menu “Ficheiro” e em seguida “Classificar Imagens”. Aparecerá uma janela, onde o utilizador deverá seleccionar as imagens que deseja classificar.

Capítulo 4 –

Análise e Discussão dos resultados

Neste capítulo são apresentados e discutidos os resultados da classificação das imagens utilizando o algoritmo proposto nesta tese.

4.1. Resultados

O banco de imagens utilizado proveio de um rastreo oftalmológico a nível nacional e é composto por 161 imagens da retina captadas por uma câmara de *fundus* e têm uma dimensão de 2896x1944 pixéis. As imagens foram previamente analisadas por um especialista, o qual avaliou 81 como válidas e 80 como inválidas. 67% (57 imagens inválidas e 61 imagens válidas) foram utilizadas como conjunto de treino na geração do classificador e 33% (23 imagens inválidas e 20 imagens válidas) como conjunto de teste do classificador gerado.

O algoritmo tem como objetivo verificar em tempo real a qualidade de uma imagem da retina. O tempo médio está diretamente relacionado com a dimensão das imagens e com o processador utilizado. Neste trabalho as imagens foram classificadas utilizando um processador Intel Core 2 Duo 2.66 GHz e o tempo médio para classificar uma imagem foi de aproximadamente 7 segundos.

A qualidade do classificador foi avaliada utilizando duas medidas de desempenho, sensibilidade e especificidade. São duas formas de medição muito comuns, utilizadas para avaliar classificadores binários e são calculadas segundo as seguintes equações:

$$\text{Sensibilidade} = \frac{\text{número de verdadeiros positivos}}{\text{número de verdadeiros positivos} + \text{número de falsos negativos}} \times 100\% \quad (\text{Equação 4.1})$$

$$\text{Especificidade} = \frac{\text{número de verdadeiros negativos}}{\text{número de verdadeiros negativos} + \text{número de falsos positivos}} \times 100\% \quad (\text{Equação 4.2})$$

A precisão do classificador foi calculada através da seguinte equação:

$$\text{Precisão} = \frac{\text{número de classificações corretas}}{\text{número total de imagens}} \times 100\% \quad (\text{Equação 4.3})$$

De seguida são apresentados os resultados alcançados pelo classificador, obtido a partir das características extraídas de cada região e gerado pelo *software* CART. Os nós terminais 1, 3 e 5 da permitem classificar imagens válidas, os nós terminais 2,4 e 6, imagens inválidas.

Na tabela seguinte é possível visualizar a distribuição da classificação das imagens, obtida pelo conjunto de treino, por cada um dos nós terminais da árvore de decisão.

Tabela 4.1 – Distribuição da classificação das imagens obtida pelo conjunto de treino.

Nó terminal	Casos	Imagens Válidas	Imagens Inválidas
1	1	1	0
		0.80%	0.00%
2	48	0	48
		0.00%	40.70%
3	5	5	0
		4.20%	0.00%
4	8	0	8
		0.00%	6.80%
5	55	55	0
		46.60%	0.00%
6	1	0	1
		0.00%	0.80%

Os resultados obtidos para o desempenho do classificador assim como a sua precisão, com o conjunto de treino, foram os seguintes:

Tabela 4.2 – Desempenho do classificador com o conjunto de treino.

Sensibilidade	100.00%
Especificidade	100.00%
Precisão	100.00%

Na tabela seguinte encontra-se a distribuição da classificação das imagens, obtida pelo conjunto de teste:

Tabela 4.3 – Distribuição da classificação das imagens obtida pelo conjunto de teste.

Nó terminal	Casos	Imagens Válidas	Imagens Inválidas
1	1	1	0
		2.30%	0.00%
2	17	2	15
		4.65%	34.85%
3	4	2	2
		4.65%	4.65%
4	6	0	6
		0.00%	14.00%
5	15	15	0
		34.90%	0.00%
6	0	0	0
		0.00%	0.00%

Os resultados obtidos para o desempenho do classificador assim como a sua precisão, com o conjunto de teste, foram os seguintes:

Tabela 4.4 – Desempenho do classificador com o conjunto de teste.

Sensibilidade	90.91%
Especificidade	92.00%
Precisão	90.70%

4.2. Discussão dos resultados

A análise dos resultados obtidos pelo classificador com o conjunto de treino, tem como objetivo principal, uma primeira avaliação do classificador gerado pelo *software* CART. Seria um mau indicador da qualidade do classificador se o mesmo obtivesse resultados insatisfatórios com o conjunto de treino. No entanto os resultados obtidos são bastante bons e permite concluir, numa primeira análise, que as características escolhidas para a construção do classificador são suficientemente distintas na aferição da qualidade de imagem da retina.

Os resultados obtidos pelo conjunto de teste mostram que o algoritmo desenvolvido tem uma precisão de 90.7%. Do conjunto de teste, apenas quatro foram incorretamente classificadas, duas como sendo inválidas e outras duas como válidas. Por essa razão obteve-se uma sensibilidade de 90.91% e uma especificidade de 92%. No contexto do trabalho, um falso negativo tem uma menor influência em comparação com um falso positivo, uma vez que apenas implicaria a repetição do exame por parte do paciente. Pelo contrário, um falso positivo, significaria a não repetição do exame quando se justificava e no pior caso poderia significar um diagnóstico incorreto. Por estas razões é mais importante obter percentagens mais elevadas de

especificidade do que de sensibilidade, o que foi possível obter com o algoritmo proposto nesta tese.

Analisando a Tabela 4.3 é possível verificar que 75% das classificações feitas às imagens válidas foram através do nó terminal 5. Pode-se então concluir que os fatores mais decisivos e distintivos na classificação das imagens foram a magnitude média da região 2 e o desvio padrão da magnitude da região 4, uma vez que, através destas variáveis consegue-se selecionar 75% das imagens válidas e excluir 100% das imagens inválidas.

É também possível concluir que imagens com melhor qualidade, têm por norma, valores mais elevados de magnitude média e esse facto reflete-se na importância que esta característica tem na avaliação da qualidade da imagem.

A troca da região 1 pela região 2 quando a sua intensidade média é superior à da região 2, para diferenciar o olho direito do esquerdo, foi uma operação que se revelou decisiva e que fortaleceu a importância da magnitude média da região 2.

Como se pode ver na Tabela 4.5, em comparação com outros métodos pesquisados, o método proposto neste trabalho, embora sendo inferiores, apresenta desempenhos semelhantes. Em termos de especificidade apresenta o segundo melhor resultado, o que no contexto do trabalho, acaba por ser o fator que deve ser mais valorizado.

Tabela 4.5 – Comparação de resultados com outros métodos.

Método	Sensibilidade	Especificidade
Método proposto neste trabalho	90.91%	92.00%
Davis et al. 2009	100.00%	96.00%
Fleming et. al. 2006	99.10%	89.40%

Conclusões e Trabalho Futuro

5.1. Conclusões

O trabalho desenvolvido nesta tese na criação de um algoritmo que, em tempo real, possibilitasse a avaliação da qualidade de imagens da retina.

O algoritmo que baseia a classificação das imagens numa avaliação genérica da qualidade das mesmas. Partindo do método apresentado por Davis et al. (Davis et al. 2009), foram efetuadas algumas modificações no sentido de reduzir o número de características extraídas da imagem, sendo também selecionadas outro tipo de características, como a magnitude média e o desvio padrão da magnitude média. Com a redução do número de características, conseguiu-se também diminuir o tempo de processamento.

A definição da ROI da imagem foi dividida em seis regiões, a partir das quais foram extraídas características do domínio espacial e do domínio da frequência. As características escolhidas permitiram efetuar um estudo da qualidade de imagem em termos de contraste, focagem e luminosidade.

Com base nessas características e recorrendo ao *software* CART, foi gerada uma árvore de decisão que permitiu classificar uma imagem como válida ou inválida.

O tempo médio necessário para efetuar a classificação de uma imagem foi de aproximadamente 7 segundos. A este nível pode-se concluir que algoritmo cumpre o objetivo a que se propôs, ainda que algumas melhorias pudessem ser realizadas no sentido de diminuir o tempo de processamento. A sua utilização num ambiente que necessite de uma avaliação em tempo real da qualidade das imagens de retina é, ainda assim, viável. A comparação do tempo de execução com outros métodos de avaliação de qualidade, não é possível, pois esse estudo não foi realizado, nos métodos pesquisados.

No âmbito deste trabalho foi criada uma aplicação que permite efetuar a classificação de um grupo de imagens assim como visualizar os dados extraídos de cada região, validando o algoritmo proposto.

Os resultados obtidos demonstram que o algoritmo desenvolvido, também a este nível, cumpriu os objetivos a que se propôs. De um conjunto de 161 imagens presentes no banco de imagens, dos quais 67% foram utilizados como conjunto de treino na geração do classificador e 33% como conjunto de teste, apenas quatro imagens foram incorretamente avaliadas.

Apresenta um bom desempenho, uma vez que obteve uma sensibilidade de 90.91%, uma especificidade de 92% e uma precisão de 90.7%.

5.2. Trabalho Futuro

O algoritmo desenvolvido revelou um bom desempenho para o conjunto de imagens fornecido, que têm uma dimensão fixa. Como trabalho a ser desenvolvido no futuro seria interessante avaliar o desempenho do algoritmo com imagens de outras dimensões.

Em termos de tempo de processamento, algum trabalho poderia ser desenvolvido no sentido de diminuí-lo e para isso alguns melhoramentos poderiam ser feitos ao nível do algoritmo. Uma pesquisa por outras características de outros domínios, como por exemplo, CIELab poderia ser uma solução, uma vez que, em outros métodos, já apresentou resultados bastante satisfatórios.

Por fim seria igualmente interessante integrar o algoritmo numa aplicação de deteção automática de doenças através de imagens de retina. O algoritmo seria utilizado como avaliador da qualidade das imagens que, caso fossem consideradas inválidas, não seriam processadas pelo detetor automático de doenças evitando desta forma possíveis diagnósticos errados.

Bibliografia

Alonso-Fernandez, F., Julian, F., Ortega-Garcia, J., Gonzalez-Rodriguez, J., Fronthaler H., Kollreider K., Bigun, J., (2007). A Comparative Study of Fingerprint Image-Quality Estimation Methods. IEEE TRANSACTIONS ON INFORMATION FORENSICS AND SECURITY, VOL. 2, NO. 4.

Bupa, Age-related Macular Degeneration (2010). Available at: <http://www.bupa.co.uk/individuals/health-information/directory/a/age-related-macular-degeneration>.

Chaudhuri, S. et al. (1989). Detection of retinal blood vessels in retinal images using two-dimensional matched filters. IEEE Trans. Med. Imag, pp.263–369.

Chen, Y., Dass, S., and Jain, A. (2005), “Fingerprint quality indices for predicting authentication performance,” in Proc. AVBPA, pp. 160–170.

Davis, H., Russell, S., Barriga, E., Abramoff, M., Soliz, P., (2009). Vision-based, real-time retinal image quality assessment, in: 22nd IEEE International Symposium on Computer-Based Medical Systems. e-Health , Vol. 12, No. 2: 89 -98.

Ferris, J. & Easty, D.L., (1998). Basic Sciences in Ophthalmology. , pp.1–60.

Fleming, A.D., Philip, S., Goatman, K.A., Olson, J.A., Sharp, P.F. (2006). Automated assessment of diabetic retinal image quality based on clarity and field definition, Investigative Ophthalmology & Visual Science 47 pp. 1120–1125.

Foracchia, M., Grisan, E. & Ruggeri (2004). Detection of optic disc in retinal images by means of a geometrical model of vessel structure. *IEEE transactions on medical imaging*, 23(10), pp.1189–95.

Galloway, N.R. et al., (2006). *Common Eye Diseases and their Management* 3rd ed., London: Springer-Verlag.

Giancardo, L. (2008). *Quality Analysis of Retina Images for the Automatic Diagnosis of Diabetic Retinopathy*.

Goldbaum, M.H. et al. (1990). The discrimination of similarly colored objects in computer images of the ocular fundus. *Invest Ophthalmol Vis Sci*, 31(4), pp.617–623.

Guyton, A.C. & Hall, J.E., (2002). *Tratado de Fisiologia Médica* 10th ed., Guanabara Koogan.

Haralick, R.M., Shanmugan, K., and Dinstein, I. (1973). Textural features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*, Vol. 3, No. 6, pp. 610–621

Hipwell, J.H., Sharp, P.F. & Forrester, J.V. (2000). Automated detection of microaneurysms in digital red-free photographs : a diabetic retinopathy screening tool. , pp.588–594.

Kertes, P.J., Johnson, T.M. (2007). *Evidence Based Eye Care*. Lippincott Williams & Wilkins.

Lalonde, M., Gagon, L., and Boucher, M.C. (2001). “Automatic visual quality assessment in optical fundus images”. *Proceedings of Vision Interface*.

Lee SC and Y Wang (1999). “Automatic retinal image quality assessment and enhancement,” *Proceedings of SPIE Medical Imaging Processing*.

Otsu, N. (1975). "A threshold selection method from gray-level histograms." *Automatica* 285-296.

Pearson, K. (1895). Contributions to the mathematical theory of evolution, II: Skew variation in homogeneous material. *Philosophical Transactions of the Royal Society of London*, 186, 343-414.

Ruiz, R.S.R. et al. (2008). Árvores de decisão em classificação de dados astronómicos. , pp.164–169.

Saaddine, J., Honeycutt, A., Narayan, K., Zhang, X., Klein, R., and Boyle, J. (2008). "Projection of diabetic retinopathy and other major eye diseases among people with diabetes mellitus: United states, 2005-2050," *Arch Ophthalmol.*, vol. 126, no. 12, pp. 1740–1747.

Soares, J. (2013). Tese de Mestrado. "Detecção de artefactos em imagens da retina".

Tapp, R.J., Shaw, J.E., Harper, C.A. et al. (2003). "The prevalence of and factors associated with diabetic retinopathy in the Australian population". *Diabetes Care*.

T.Walter and J.-C. Klein, "Segmentation of color fundus images of the human retina: Detection of the optic disc and the vascular tree using morphological techniques," in *Proc. 2nd Int. Symp. Med. Data Anal.*, 2001, pp. 282–287.

Youssif, A., Ghalwash, A., Ghoneim, A., (2008). Optic Disc Detection From Normalized Digital Fundus Images by Means of a Vessel's Direction Matched Filter, in: *IEEE TRANSACTIONS ON MEDICAL IMAGING*, VOL. 27, NO. 1.

Zimmer-Galler, I. and R Zeimer. (2006). "Results of Implementation of the DigiScope for Diabetic Retinopathy Assessment in The Primary Care Environment," *Telemedicine and e - Health* , Vol. 12, No. 2: 89 -98.