



UNIVERSIDADE FEDERAL DO MARANHÃO
Programa de Pós-Graduação em Ciência da Computação

Jose Denes Lima Araujo

***Diagnóstico de Glaucoma a partir de Imagens de Fundo de Olho
Utilizando Índices de Diversidade***

**São Luís - MA
2018**

JOSE DENES LIMA ARAUJO

**DIAGNÓSTICO DE GLAUCOMA A PARTIR DE IMAGENS DE FUNDO
DE OLHO UTILIZANDO ÍNDICES DE DIVERSIDADE**

Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação da UFMA como requisito parcial para obtenção do grau de Mestre em Ciência da Computação.

Orientador: Prof. Dr. Anselmo Cardoso de Paiva

Coorientador: Prof. Dr. Aristófanês Corrêa Silva

SÃO LUÍS - MA

2018

Ficha gerada por meio do SIGAA/Biblioteca com dados fornecidos pelo(a) autor(a).
Núcleo Integrado de Bibliotecas/UFMA

LIMA ARAUJO, JOSE DENES.

DIAGNÓSTICO DE GLAUCOMA A PARTIR DE IMAGENS DE FUNDO DE OLHO UTILIZANDO ÍNDICES DE DIVERSIDADE / JOSE DENES LIMA ARAUJO. - 2018.

65 p.

Coorientador(a): Aristófanês Corrêa Silva.

Orientador(a): Anselmo Cardoso de Paiva.

Dissertação (Mestrado) - Programa de Pós-graduação em Ciência da Computação/ccet, Universidade Federal do Maranhão, São Luís - MA, 2018.

1. Diagnóstico. 2. Glaucoma. 3. Imagem de fundo de olho. 4. Índice de diversidade. I. Cardoso de Paiva, Anselmo. II. Corrêa Silva, Aristófanês. III. Título.

JOSE DENES LIMA ARAUJO

**DIAGNÓSTICO DE GLAUCOMA A PARTIR DE IMAGENS DE FUNDO
DE OLHO UTILIZANDO ÍNDICES DE DIVERSIDADE**

Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação da UFMA como requisito parcial para obtenção do grau de Mestre em Ciência da Computação.

Dissertação aprovada em ____ de _____ de _____.

Prof. Dr. Anselmo Cardoso de Paiva
Orientador

Prof. Dr. Aristófanês Corrêa Silva
Coorientador

Prof. Dr. Geraldo Braz Junior
Membro da Banca Examinadora

Prof. Dr. Kelson Romulo Teixeira
Aires
Membro da Banca Examinadora

SÃO LUÍS - MA
2018

Aos meus pais, irmãos, família e amigos

AGRADECIMENTOS

A Deus.

A minha família pelo incentivo, carinho e confiança. Em especial aos meus pais, Gdalva Florês de Lima Araújo e José Edimar de Araújo, pelos ensinamentos, conselhos e pelo esforço em sempre proporcionar a seus filhos tudo de melhor.

Ao orientador Anselmo Paiva por toda a paciência, confiança, conselhos e ensinamentos.

Aos professores por todo o conhecimento repassado. Em especial a João Dallyson, Geraldo e Aristófanés.

Aos amigos que sempre me apoiaram e me fizeram crescer como pessoa e como profissional. Em especial a Otilio e Oseas por sempre me ajudarem na realização deste trabalho.

A CAPES pelo apoio financeiro durante o mestrado.

A todos vocês muito obrigado.

*“Para realizar grandes conquistas, devemos não apenas agir, mas também sonhar;
não apenas planejar, mas também acreditar”*

Anatole France

RESUMO

O glaucoma é uma das principais causas de cegueira no mundo, sendo causado usualmente pelo aumento da pressão intraocular que danifica o nervo óptico e provoca perda da visão, gradualmente. É uma doença que não apresenta sintomas nas fases iniciais e seu diagnóstico precoce pode prevenir a perda da visão e a cegueira. Imagens de fundo de olho são utilizadas por especialistas para examinar o disco óptico com o objetivo de identificar as mudanças causadas pelo glaucoma. Além disso, técnicas de processamento de imagens e reconhecimento de padrões são utilizadas para o desenvolvimento de ferramentas computacionais com o objetivo de auxiliar no processo de análise destas imagens. Este trabalho propõe uma metodologia para o diagnóstico do glaucoma a partir de imagens de fundo de olho utilizando índices de diversidade, como descritores de textura. Após a extração de características de textura, algoritmos genéticos são utilizados para a seleção das características mais relevantes. E por fim, a máquina de vetores de suporte foi aplicada para realizar a classificação. A metodologia proposta apresenta resultados promissores para o diagnóstico do glaucoma alcançando, como melhor resultado, acurácia de 93,41%, sensibilidade de 92,36% e especificidade de 95,05%

Palavras-chave: Imagem de fundo de olho, Glaucoma, Diagnóstico, Índice de diversidade.

ABSTRACT

Glaucoma is one of the leading causes of blindness worldwide, and is usually caused by an increase in the intraocular pressure that damages the optic nerve and gradually causes vision loss. It is a disease that has no symptoms in the early stages and its early diagnosis can prevent the vision loss and blindness. Fundus images are used by experts to examine the optic disc in order to identify the changes caused by glaucoma. In addition, image processing and pattern recognition techniques are used for the development of computational tools in order to provide support in the process of analyzing these images. This work proposes a methodology for the glaucoma diagnosis from fundus images using diversity indexes as texture descriptors. After extraction of texture features, genetic algorithms are used to select the best set of features. Finally, the support vector machine is used to perform the classification. The proposed methodology revealed promising results for glaucoma diagnosis, reaching accuracy of 93.41%, sensitivity of 92.36% and specificity of 95.05%, as best results.

Keywords: Fundus images, Glaucoma, Diagnosis, Diversity index

LISTA DE ILUSTRAÇÕES

Figura 1 – Estrutura interna do olho humano.	21
Figura 2 – Estruturas fisiológicas da retina.	24
Figura 3 – Partes do DO.	24
Figura 4 – Mudanças causadas no DO pelo glaucoma.	25
Figura 5 – Razão escavação disco.	26
Figura 6 – ISNT e atrofia peripapilar.	26
Figura 7 – Passos fundamentais em processamento de imagens.	27
Figura 8 – Filtro homomórfico.	29
Figura 9 – Exemplo de utilização do filtro homomórfico.	30
Figura 10 – Exemplo de utilização da equalização de histograma.	33
Figura 11 – Exemplos de imagens de fundo de olho.	39
Figura 12 – Etapas da metodologia.	40
Figura 13 – Aplicação da correção de iluminação com Retinex.	41
Figura 14 – Aplicação da correção de iluminação com filtro homomórfico na imagem em escala de cinza.	41
Figura 15 – Canais R, G, B e imagem em escala de cinza.	42
Figura 16 – Exemplo de melhoramento de contraste e redução de ruído.	43
Figura 17 – Obtenção da região do DO.	44
Figura 18 – Exemplos de sub-regiões em forma de círculos.	45
Figura 19 – Exemplos de sub-regiões em forma de anéis.	45

LISTA DE TABELAS

Tabela 1 – Resumo dos trabalhos relacionados.	19
Tabela 2 – Correspondência entre os termos da biologia e da metodologia proposta.	35
Tabela 3 – Parâmetros do algoritmo genético.	46
Tabela 4 – Proporções de treinamento e teste para a etapa de classificação.	47
Tabela 5 – Resultados do índice de <i>Shannon</i> com correção de iluminação <i>Retinex</i>	49
Tabela 6 – Resultados do índice de <i>McIntosh</i> com correção de iluminação <i>Retinex</i>	50
Tabela 7 – Resultados do índice de Diversidade Total com correção de iluminação <i>Retinex</i>	50
Tabela 8 – Resultados combinando todos os índices com correção de iluminação <i>Retinex</i>	51
Tabela 9 – Resultados do índice de <i>Shannon</i> com correção de iluminação filtro homomórfico.	51
Tabela 10 – Resultados do índice de <i>McIntosh</i> com correção de iluminação filtro homomórfico.	52
Tabela 11 – Resultados do índice de Diversidade Total com correção de iluminação filtro homomórfico.	52
Tabela 12 – Resultado combinando todos os índices com correção de iluminação filtro homomórfico.	53
Tabela 13 – Resultados do melhor experimento.	53
Tabela 14 – Resultados do melhor experimento com aumento do tamanho da região de análise em 10%.	54
Tabela 15 – Resultados do melhor experimento com aumento do tamanho da região de análise em 20%.	54
Tabela 16 – Resultados do melhor experimento com diminuição do tamanho da região de análise em 10%.	54
Tabela 17 – Resultados do melhor experimento com diminuição do tamanho da região de análise em 20%.	55
Tabela 18 – Comparação da metodologia com os trabalhos relacionados.	57
Tabela 19 – Artigos publicados e submetidos que possuem relação com a metodologia proposta.	60

LISTA DE ABREVIATURAS E SIGLAS

AC	Acurácia
CADx	<i>Computer-Aided Diagnosis</i>
CDR	<i>Cup-to-Disk Ratio</i>
DO	Disco Óptico
ESP	Especificidade
FN	Falso Negativo
FP	Falso Positivo
HOS	<i>Higher Order Spectra</i>
ISNT	Inferior, Superior, Nasal, Temporal
LBP	<i>Local Binary Pattern</i>
LRSR	<i>Light Random Sprays Retinex</i>
MVS	Máquina de Vetores de Suporte
PIO	Pressão Intraocular
RBF	<i>Radial Basis Function</i>
RGB	<i>Red, Green, Blue</i>
SBG	Sociedade Brasileira de Glaucoma
SEN	Sensibilidade
VN	Verdadeiro Negativo
VP	Verdadeiro Positivo

SUMÁRIO

1	INTRODUÇÃO	13
1.1	Objetivos	14
1.2	Organização do Trabalho	15
2	TRABALHOS RELACIONADOS	16
3	FUNDAMENTAÇÃO TEÓRICA	21
3.1	Olho Humano	21
3.2	Glaucoma	22
3.3	Imagem de Fundo de Olho	23
3.4	Processamento Digital de Imagens	26
3.5	Técnicas de Pré-processamento	28
3.5.1	Filtro Homomórfico	28
3.5.2	Retinex	30
3.5.3	Filtros Espaciais	31
3.5.3.1	Filtro Gaussiano	31
3.5.3.2	Filtro da Mediana	32
3.5.4	Equalização de Histograma	32
3.6	Extração de Características	33
3.6.1	Índices de Diversidade para Extração de Características de Textura	34
3.7	Seleção de Características usando Algoritmo Genético	36
3.8	Reconhecimento de Padrões	36
3.8.1	Máquina de Vetores de Suporte (MVS)	37
3.9	Métricas de Desempenho	38
4	MATERIAIS E MÉTODOS	39
4.1	Base de Imagens	39
4.2	Metodologia Proposta	40
4.2.1	Pré-processamento	40
4.2.2	Decomposição Espacial	43
4.2.3	Extração de características	45

4.2.4	Reconhecimento de Padrões	46
5	RESULTADOS E DISCUSSÃO	48
5.1	Experimentos utilizando <i>Retinex</i>	49
5.2	Experimentos utilizando filtro homomórfico	51
5.3	Alterando o tamanho da região de análise	53
5.4	Discussão	55
5.5	Comparação da metodologia com outros trabalhos	57
6	CONCLUSÃO	59
6.1	Produções científicas	60
	REFERÊNCIAS	61

1 INTRODUÇÃO

O glaucoma é uma doença ocular crônica em que o nervo óptico é progressivamente danificado, provocando perda irreversível da visão periférica e cegueira se não for tratado (ALMAZROA et al., 2015; HALEEM et al., 2013). Atualmente é a segunda maior causa de cegueira no mundo (WGA, 2017). Estima-se que, o número de casos mundiais da doença, aumente para 76 milhões em 2020, e fique próximos de 112 milhões em 2040 (THAM et al., 2014). De acordo com a Sociedade Brasileira de Glaucoma (SBG) existem no Brasil cerca de 900.000 portadores da doença (SBG, 2016).

Uma das principais causas do glaucoma é o aumento da pressão intraocular (PIO), a qual é responsável por manter a forma do olho humano. A PIO é regulada por um fluido chamado humor aquoso¹ que é constantemente produzido e drenado para manter o olho funcionando. A drenagem incorreta do humor aquoso aumenta a PIO, o que provoca danos em estruturas da retina e no nervo óptico (HALEEM et al., 2013).

O glaucoma é uma doença assintomática nas fases iniciais. Uma detecção precoce é importante, pois pode minimizar os danos causados, evitar a perda de visão, e garantir um tratamento rápido e adequado (MARY; RAJSINGH; NAIK, 2016). O diagnóstico do glaucoma é baseado principalmente no histórico médico do paciente, aferição da PIO, teste de perda do campo visual e avaliação manual da cabeça do nervo óptico (disco óptico) através de oftalmoscopia ou imagens (LIN et al., 2007).

Atualmente estão disponíveis técnicas de captura de imagens para examinar a camada de fibras nervosas e o disco óptico (DO) para o diagnóstico do glaucoma. Exemplos dessas técnicas são a *Confocal Scanning Laser Ophthalmoscopy*, *Optical Coherence Tomography* e *Scanning Laser Polarimetry* (RAJA; GANGATHARAN, 2015). Esses métodos são caros, demorados e exigem supervisão qualificada (MAHESHWARI et al., 2017; OH et al., 2015).

Uma alternativa a essas técnicas é o exame de imagem de fundo de olho que é um meio não invasivo, de baixo custo e pode ser usado para diagnosticar diferentes anormalidades oculares, como o glaucoma. Essas imagens são analisadas manualmente por especialistas para verificar as mudanças anatômicas na retina, causadas pela doença. Essa observação manual consome tempo e está sujeita a erros de interpretações entre especialistas, onde diferentes interpretações podem ser atribuídas à mesma imagem. Além

¹ Líquido incolor de consistência aquosa responsável por nutrir estruturas do olho.

disso, é uma tarefa repetitiva e tediosa, isto é, qualquer desvio de atenção pode ocasionar erros (HALEEM et al., 2013; NORONHA et al., 2014).

Os avanços recentes em processamento de imagens e computação de alto desempenho contribuíram para o desenvolvimento de sistemas de diagnóstico do glaucoma auxiliado por computador (*Computer-Aided Diagnosis - CADx*) (MAHESHWARI et al., 2017). Esses sistemas podem ser utilizados pelos especialistas como ferramentas complementares que auxiliam no diagnóstico e superam os problemas na análise das imagens (NORONHA et al., 2014). Imagens de fundo de olho são as mais utilizadas para o desenvolvimento de métodos computadorizados para o diagnóstico do glaucoma (ZHANG et al., 2014).

Características morfológicas como área do disco óptico, escavação e anel neuroretinal, diâmetro do disco óptico e razão vertical escavação/disco (*Cup-to-Disk Ratio - CDR*) são extraídas de imagens de fundo do olho para realizar o diagnóstico (ACHARYA et al., 2014). As abordagens baseadas em características morfológicas assumem que foi realizada uma segmentação correta do disco óptico e suas partes. Pequenos erros de segmentação podem resultar em mudanças significativas nas medidas e erro no diagnóstico (MOOKIAH et al., 2012).

Baseado no exposto pretende-se avaliar a eficácia de índices de diversidade para extração de características de textura do DO, que pode estar sujeito a erros de segmentação. Os índices de diversidade de Shannon (SHANNON, 1949), McIntosh (MCINTOSH, 1967) e Diversidade Total (MARRUGAN, 2004) são utilizados em conjunto com técnicas de processamento de imagens e reconhecimento de padrões para classificação das imagens em glaucomatosas e saudáveis.

1.1 Objetivos

O objetivo geral deste trabalho é propor uma metodologia para o diagnóstico do glaucoma a partir de imagens de fundo de olho, robusta a erros de segmentação do DO, utilizando índices de diversidade para a descrição da textura do DO.

Destaca-se como objetivos específicos desse trabalho:

- Aplicar técnicas de pré-processamento para redução de ruído, correção de iluminação e melhoramento de contraste em imagens de fundo de olho;
- Investigar índices de diversidade para descrição de textura da região do DO;

- Propor e avaliar uma metodologia através de experimentos utilizando uma base de imagens pública.

1.2 Organização do Trabalho

Além deste capítulo inicial, o restante desta dissertação está organizado em mais cinco capítulos que são descritos resumidamente a seguir.

O Capítulo 2 apresenta um resumo dos trabalhos relacionados ao diagnóstico de glaucoma em imagens de fundo de olho utilizando análise de textura.

O Capítulo 3 trata da fundamentação teórica necessária para a construção desta pesquisa. São abordados os conceitos referentes ao glaucoma, imagens de fundo de olho, índices de diversidade, seleção de características com algoritmo genético, reconhecimento de padrões e máquina de vetores de suporte.

O Capítulo 4 descreve a base de imagens utilizada para os testes e descreve todas as etapas que compõem a metodologia proposta neste trabalho.

O Capítulo 5 apresenta os resultados obtidos através da metodologia proposta, as discussões e comparação com os trabalhos relacionados.

O Capítulo 6 apresenta as conclusões e propostas de trabalhos futuros.

2 TRABALHOS RELACIONADOS

Na literatura estão disponíveis trabalhos relacionados com o problema de diagnóstico automático de glaucoma utilizando imagens de fundo de olho. A seguir, tem-se os resumos dos métodos correlatos com o proposto e que utilizaram apenas análise de textura.

Acharya et al. (2011) apresentam um método que utiliza características *higher order spectra* (HOS) combinadas com características de textura extraídas *gray level co-occurrence matrix* e *gray level difference matrix*. Para os testes foram utilizadas 60 imagens, sendo 30 normais e 30 glaucomatosas, de uma base privada, do hospital *Kasturba Medical College* (KMC), Manipal, Índia. As características foram classificadas com os classificadores máquina de vetores de suporte (MVS), *sequential minimal optimization*, *naive bayesian* e *random forest*. O método alcançou uma taxa de acerto de 91,7% utilizando o classificador *random forest*.

O trabalho de Dua et al. (2012) apresenta uma metodologia para o diagnóstico do glaucoma utilizando características extraídas dos coeficientes obtidos pela aplicação de transformada discreta de *wavelet*. Testes foram realizados utilizando 60 imagens, sendo 30 imagens normais e 30 imagens glaucomatosas, da base privada do KMC. As características são classificadas com MVS, *sequential minimal optimization*, *naive bayesian* e *random forest*. O melhor resultado foi obtido utilizando o classificador *naive bayesian* e alcançou uma taxa de acerto de 93%.

Mookiah et al. (2012) e Mookiah e Faust (2013) também utilizaram características HOS. Os dois trabalhos são testados utilizando uma base privada contendo 60 imagens, sendo 30 imagens normais e 30 imagens glaucomatosas, da base privada do KMC. Antes da extração de características é aplicada a transformada de *Radom* nas imagens. A classificação é realizada utilizando MVS com diferentes funções de *kernel*. No primeiro trabalho são extraídas características HOS e transformada discreta de *wavelet*. Este apresenta como melhor resultado uma acurácia de 95%, sensibilidade de 93,33% e especificidade 96,67%. No segundo trabalho são extraídas características HOS, transformada discreta de *wavelet* e *trace transform*. Como melhor resultado este alcançou uma acurácia de 91,67%, sensibilidade de 90% e especificidade 93,33%.

O trabalho proposto por Ali et al. (2014) utiliza *Local Binary Pattern* (LBP)

e suas variantes para extração de características de textura. Além de utilizar a forma clássica do LBP, utilizou-se o LBPM (*Local Binary Pattern Magnitude*) e LBPC (*Local Binary Pattern Center*). Para os testes é utilizada a média dos canais *blue* e *green* da imagem colorida. As imagens são classificadas utilizando *K-nearest neighbor* (KNN). O método obteve como melhor resultado uma especificidade de 92,3%, sensibilidade de 96,4% e acurácia de 95,1%, para um conjunto de 41 imagens, sendo 28 normais e 13 glaucomatosas.

Acharya et al. (2014) propuseram um método de detecção onde a transformada de *Gabor* é aplicada sobre as imagens e características como média, variância, curtose, energia e entropia são extraídas dos coeficientes gerados pela transformada. O número de características é reduzido utilizando *Principal Component Analysis*. São utilizadas para os testes 510 imagens, sendo 266 normais e 244 glaucomatosas, da base privada do KMC. A classificação é realizada utilizando os classificadores MVS e *naive bayesian*, obtendo-se 93,1% de acurácia, 89,75% de sensibilidade e 96,2% de especificidade.

Em Noronha et al. (2014) são utilizadas características HOS cumulantes extraídas após a aplicação da transformada de Radon nas imagens. As características mais significativas são selecionadas utilizando análise discriminante linear. Foram utilizados os classificadores MVS e *naive bayesian*. A metodologia obteve como melhor resultado 92,65% de acurácia, 100% de sensibilidade e especificidade de 92%, utilizando *naive bayesian* como classificador. O trabalho é validado utilizando 272 imagens, sendo 100 imagens normais e 172 glaucomatosas de uma base privada do KMC.

Já Gajbhiye e Kamthane (2015) propuseram uma metodologia para detecção de glaucoma utilizando transformada de *wavelet* para decomposição da imagem e *higher order moments* (HOM) para cálculo das características. Para a classificação são utilizados os classificadores MVS, *k-Nearest Neighbors* e *Error Back-Propagation Training Algorithm*. A metodologia alcança uma acurácia de 86,57%. Para os testes são utilizadas 350 imagens da base RIM-ONE.

Na metodologia proposta por Haleem et al. (2015) é utilizada a transformada de *wavelet* aplicada de forma regional no disco óptico. As imagens são divididas em quatro quadrantes seguindo a regra ISNT (Inferior, Superior, Nasal e Temporal). Para cada região é calculada a energia *wavelet* através de diferentes sub-bandas, usando diferentes famílias *wavelet*. O método alcançou uma acurácia de 92,95% em um conjunto de 158 imagens da base RIM-ONE (TRUCCO et al., 2013).

O método proposto por Maheshwari, Pachori e Acharya (2017) utiliza transformada de *wavelet* empírica (*Empirical wavelet transform*) para decomposição das imagens. Correntropia é utilizada para extrair características dos componentes gerados pela transformada. As características são selecionadas utilizando teste-t. A classificação é realizada com *least squares support vector machine*. Como entrada para extração de características foram utilizados os 3 canais (RGB) mais a imagem em escala de cinza. Para os testes foram utilizadas imagens de duas bases: 60 imagens (30 normais e 30 glaucomatosas) da base privada do KMC e 455 imagens (255 normais e 200 glaucomatosas) da base pública (RIM-ONE). Na base privada obteve-se como melhor resultado uma especificidade de 96,67%, sensibilidade de 100%, e acurácia de 98,33%. Na base pública obteve-se uma acurácia de 81,32%, sensibilidade de 77,01% e especificidade de 84,31%.

Na metodologia proposta por Acharya et al. (2017) as imagens são convoluídas pelos filtros leung-malik, schmid e máxima resposta (MR4 e MR8) para serem gerados microestruturas básicas chamadas *textons*. Essas microestruturas são descritas utilizando *Local Configuration Pattern* (LCP). Em seguida, as características mais discriminantes foram selecionadas utilizando o algoritmo *sequential floating forward search*, e teste-t foi utilizado para o ranqueamento das características mais significativas. Ao final são utilizados os classificadores árvore de decisão, análise discriminante quadrática, MVS, KNN e redes neurais probabilísticas. Os testes foram realizados em 702 imagens, sendo 143 normais e 559 glaucomatosas, da base privada do KMC. O método obteve como melhor resultado uma acurácia de 95,73%, uma sensibilidade de 96,24% e uma especificidade de 93,71%, utilizando o filtro leung-malik e KNN para classificação.

Sousa et al. (2017) propõem um método para o diagnóstico de glaucoma utilizando funções geoestatísticas (semivariograma, semimadograma, covariograma e correlograma) como descritores de textura. O LBP é utilizado para gerar uma nova representação da textura da imagem. As características são extraídas da região do disco óptico. Na classificação, utiliza-se MVS combinada com algoritmo genético para a escolha do melhor modelo de classificação. Os testes foram realizados em 455 imagens da base RIM-ONE, sendo 255 imagens saudáveis e 200 glaucomatosas. Foi alcançado como melhor resultado uma acurácia de 91%, sensibilidade de 95% e especificidade de 88%.

Na metodologia proposta por Maheshwari et al. (2017) é utilizado *Variational Mode Decomposition* (VMD) para a decomposição da imagem. Várias características de entropia e dimensão fractal são extraídas. O algoritmo Relief é utilizado para selecionar e

ranquear as características. Ao final, LS-SVM é utilizada para a classificação. Os testes são realizados com imagens de duas bases: 488 imagens (244 normais e 244 glaucomatosas) da base privada do KMC e 455 imagens (255 normais e 200 glaucomatosas) da base RIM-ONE. O melhor resultado é obtido ao aplicar a metodologia na base privada, alcançando 94,7% e 95,1% de acurácia usando validação cruzada com k igual a 10 e 3 respectivamente. Ao aplicar na base RIM-ONE foi alcançado acurácias de 81,63% e 81,22% usando validação cruzada com k igual 10 e 3 respectivamente.

Esses são exemplos de metodologias que realizam o diagnóstico do glaucoma em imagens de fundo de olho utilizando análise de textura. A Tabela 1 apresenta um resumo dos trabalhos relacionados citados nesta seção, contendo a base de imagens, o número de amostras de teste (Amostra) e os percentuais dos resultados produzidos em termos de acurácia (AC), sensibilidade (SEN) e especificidade (ESP).

Tabela 1 – Resumo dos trabalhos relacionados.

Trabalho	Técnica	Base	Amostra	AC (%)	SEN (%)	ESP (%)
Acharya et al. (2011)	HOS GLCM GLDM	Privada	60	91,7	—	—
Dua et al. (2012)	<i>Wavelet</i>	Privada	60	93	—	—
Mookiah et al. (2012)	<i>Radon</i> HOS <i>Wavelet</i>	Privada	60	95	93,33	96,67
Mookiah e Faust (2013)	<i>Radon</i> HOS <i>Wavelet</i> <i>Trace</i>	Privada	60	91,67	90	93,33
Noronha et al. (2014)	HOS <i>Radon</i>	Privada	272	92,65	100	92
Acharya et al. (2014)	<i>Gabor</i>	Privada	510	93,1	89,75	96,2
Ali et al. (2014)	LBP LBPM LBPC	Privada	48	95,1	96,4	92,3
Maheshwari et al. (2017)	VMD	Privada	488	95,19	93,62	96,71
Acharya et al. (2017)	LCP	Privada	702	95,73	96,24	93,71
Maheshwari, Pachori e Acharya (2017)	<i>Wavelet</i>	Privada	60	98,33	100	96,67
Gajbhiye e Kamthane (2015)	HOM <i>Wavelet</i>	RIM-ONE	350	86,57	—	—
Haleem et al. (2015)	<i>Wavelet</i>	RIM-ONE	158	92,95	—	—
Maheshwari, Pachori e Acharya (2017)	<i>Wavelet</i>	RIM ONE	455	81,32	77,01	84,31
Maheshwari et al. (2017)	VMD	RIM ONE	455	81,63	—	—
Sousa et al. (2017)	Geoestatística	RIM-ONE	455	91	95	88

Analisando os trabalhos relacionados percebe-se que alguns utilizam uma quantidade pequena de amostras. O glaucoma afeta principalmente o DO e seu entorno. Os trabalhos relacionados analisam a imagem de fundo de olho completa ou uma sub-imagem que contenha o DO. Ao analisar dessa forma, podem ser capturadas informações de

regiões que não contribuem para identificação do glaucoma e que ainda podem prejudicar a classificação.

Diante disso, é necessário propor uma metodologia que analise a região do DO, que corresponde a parte da imagem de fundo de olho que possui as informações mais significativas, do ponto de vista clínico, para o diagnóstico do glaucoma, sem a necessidade de segmentação da escavação. A metodologia proposta necessita de uma segmentação ou marcação prévia da região do DO e deve ser robusta em relação a variações desta marcação (erros de segmentação), ou seja, o diagnóstico deve ser correto mesmo quando a região analisada for menor ou maior que o DO.

3 FUNDAMENTAÇÃO TEÓRICA

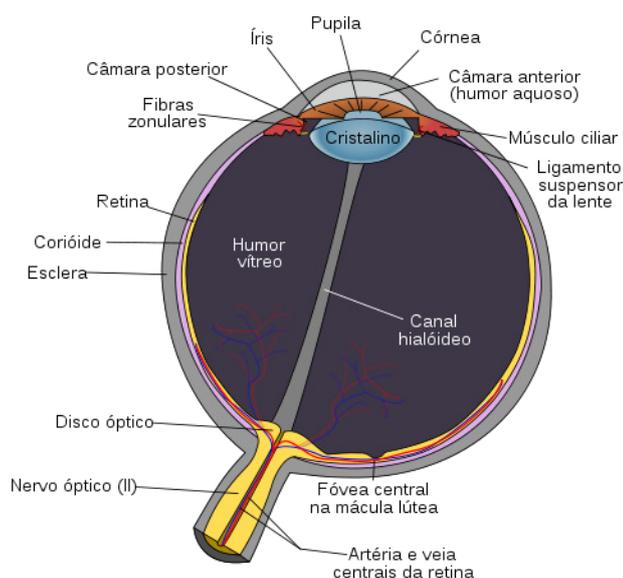
Neste capítulo é apresentada a fundamentação teórica utilizada para a elaboração da metodologia proposta. As seções seguintes abordam tópicos sobre anatomia ocular, glaucoma, imagens de fundo de olho, extração de características de textura baseadas em índices de diversidade, seleção de características, reconhecimento de padrões e métricas para validação dos resultados.

3.1 Olho Humano

O olho humano é um órgão sensorial complexo, que captura relações espaciais e temporais de objetos que se encontram no espaço visual, convertendo energia luminosa em sinais elétricos processados no cérebro. A energia luminosa passa pelo olho onde a retina, através do nervo óptico, envia impulsos ao cérebro (CONCI; AZEVEDO; LETA, 2008).

A Figura 1 mostra um corte horizontal do olho humano onde é possível observar as partes que o compõem. O globo ocular possui formato aproximadamente esférico, e é envolvido por três membranas, uma camada externa formada pela esclera e pela córnea, uma camada intermediária formada pela coróide, íris e corpo ciliar, e uma camada interna formada pela retina (PEDRINI; SCHWARTZ, 2008).

Figura 1 – Estrutura interna do olho humano.



Fonte: Adaptado de (MARY; RAJSINGH; NAIK, 2016)

A esclera é uma camada resistente e opaca que envolve o globo ocular. A córnea é um tecido transparente por onde a luz penetra no olho e localiza-se na parte frontal do globo. A coróide é uma membrana que contém uma rede de vasos sanguíneos que nutrem os olhos e está localizada abaixo da esclera. A íris é responsável por controlar a quantidade de luz que penetra no olho através da pupila (abertura central com diâmetro que varia de 2 a 8 mm). (PEDRINI; SCHWARTZ, 2008).

A retina é a membrana mais interna do olho e se estende por toda a porção posterior da parede. A retina é responsável pela sensação da imagem visual projetada pelas estruturas da parte frontal do olho, pela codificação dessas informações em sinais nervosos e transmissão para o cérebro. A retina é composta por cones e bastonetes que são células sensíveis à luz. Essas células transformam a energia luminosa das imagens em impulsos elétricos que são transmitidos ao cérebro pelo nervo óptico (GONZALEZ; WOODS, 2010; PEDRINI; SCHWARTZ, 2008).

3.2 Glaucoma

Glaucoma é um termo que descreve um grupo de distúrbios oculares, que possuem variadas origens. Esses distúrbios são unidos por uma neuropatia óptica progressiva, caracterizada pela perda de fibras nervosas, com alterações características no DO (dano estrutural) e no campo visual (dano funcional) (MENEZES, 2012). As alterações no campo visual somente são percebidas quando já existe uma perda significativa das fibras nervosas. Os danos causados pela doença são irreversíveis e se não for tratada pode levar a cegueira (CASSON et al., 2012).

Os principais fatores de risco para o desenvolvimento do glaucoma são: idade superior a 45 anos, pessoas de descendência africana, histórico familiar de glaucoma, pressão intraocular (PIO) alta e pessoas que tiveram diabetes, miopia, uso regular a longo prazo de esteroides/cortisona ou uma lesão visual anterior (TGF, 2017).

Uma PIO alta por muito tempo danifica o nervo óptico. O aumento da PIO é causado pela obstrução do humor aquoso que é um líquido responsável por nutrir estruturas do olho. Em um olho saudável a produção, fluxo e drenagem deste líquido é um processo ativo e contínuo que mantém o olho saudável. A PIO depende do equilíbrio entre produção e drenagem desse líquido no olho. Mesmo sendo um fator de risco, existem casos onde pessoas com PIO normal sofrem com o glaucoma. (GRF, 2017).

Existem vários tipos de glaucoma. Os principais são glaucoma primário de ângulo aberto, glaucoma primário de ângulo fechado, glaucoma de pressão normal e glaucomas secundários.

O glaucoma primário de ângulo aberto é a forma mais comum de glaucoma, possui como causa o entupimento lento dos canais de drenagem, resultando em aumento da PIO, é caracterizado pelo desenvolvimento lento e assintomático. A perda de visão somente é percebida em estágios avançados. O glaucoma primário de ângulo fechado manifesta-se bruscamente com grande dor nos olhos, diminuição brusca da visão, náuseas, vômitos, dor de cabeça, etc, e tem origem no fechamento súbito das vias de eliminação do humor aquoso. Já no glaucoma de pressão normal o nervo óptico é danificado mesmo que a PIO não esteja muito alta e possui causas desconhecidas. Os glaucomas secundários desenvolvem-se como resultado de uma lesão ocular, inflamação, tumor, em casos avançados de catarata ou diabetes ou por medicamentos, como esteróides (GRF, 2017; TGF, 2017).

O diagnóstico do glaucoma é baseado no histórico médico do paciente, aferição da PIO, teste de perda do campo visual e avaliação manual do disco óptico (DO) através da oftalmoscopia ou imagens (LIN et al., 2007).

3.3 Imagem de Fundo de Olho

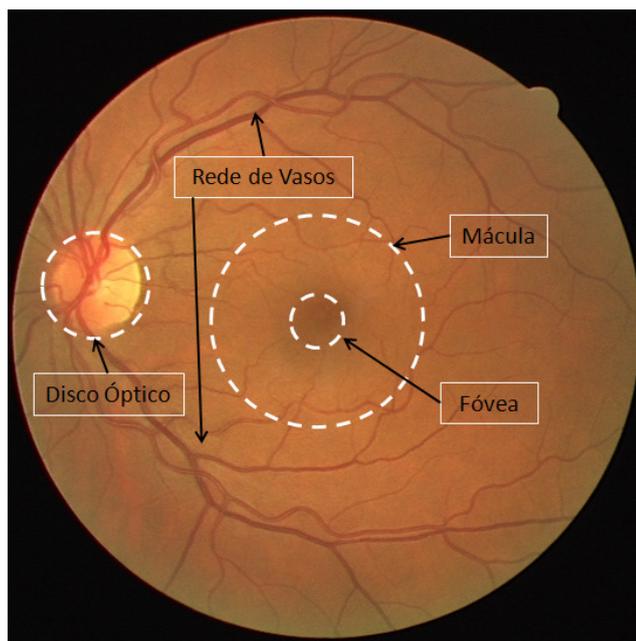
As imagens de fundo de olho são obtidas através do exame clínico de retinografia, o qual consiste na observação da retina. Esse exame é realizado para acompanhar a evolução de algumas doenças oculares e deve ser feito periodicamente dependendo da patologia. Nesse exame o paciente deve estar com a pupila dilatada. Dessa maneira, o olho é iluminado por uma luz interna ao retinógrafo e a retina pode então ser fotografada, filmada ou observada pelo médico (CARVALHO, 2006). Assim, é possível analisar as principais estruturas presentes em uma retina saudável, que são o DO, a mácula, a fóvea e a rede de vasos sanguíneos.

O disco óptico (DO) é a parte do nervo óptico vista no fundo dos olhos, formado pelo encontro de todos os axônios das células ganglionares da retina. O DO é uma estrutura circular que apresenta uma tonalidade rosa pálido ou esbranquiçada com bordas bem definidas e está localizado no lado nasal da retina. É a parte mais brilhante na imagem de fundo de olho e também a região de convergência dos vasos sanguíneos. A mácula é uma área circular localizada temporalmente ao DO que não apresenta vasos e possui uma

tonalidade mais escura do que o restante do fundo do olho. No centro da mácula está localizada a fóvea. Os vasos sanguíneos da retina ramificam-se do DO para a periferia e apresentam tonalidade vermelha e diferentes calibres.

A Figura 2 apresenta um exemplo de imagem gerada pela retinografia e nessa estão indicadas as principais estruturas presentes em uma retina saudável.

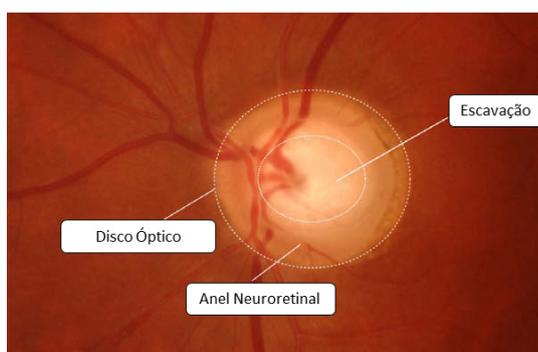
Figura 2 – Estruturas fisiológicas da retina.



Fonte: (VERAS, 2014)

Em imagens 2D o DO pode ser dividido em duas zonas distintas: uma região central brilhante chamada escavação e uma região periférica chamada anel neuroretinal. A Figura 3 apresenta uma parte da imagem de fundo de olho centrada no DO indicando a localização da borda do DO, a escavação e o anel neuroretinal.

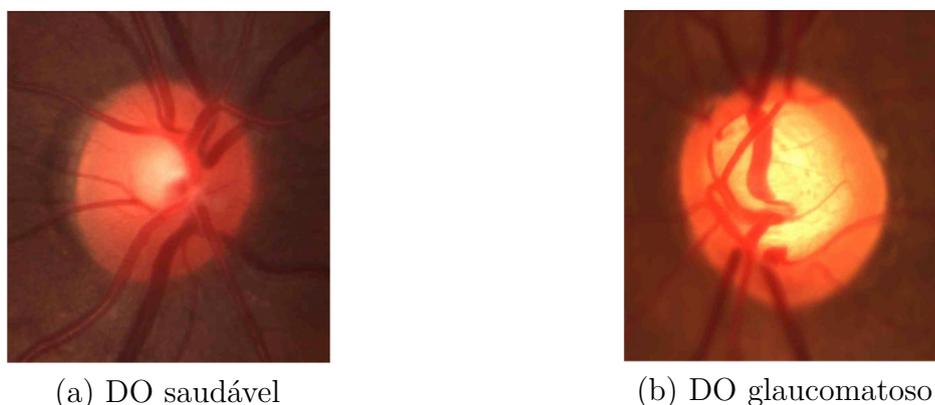
Figura 3 – Partes do DO.



Fonte: Adaptado de (BOCK et al., 2010)

O glaucoma causa danos estruturais mais aparentes no disco óptico e seu entorno. Uma das alterações mais visíveis é o alargamento da escavação em relação ao DO e a conseqüente diminuição do anel neuroretinal. A Figura 4(b) apresenta um DO glaucomatoso onde é possível observar a escavação ocupando uma área maior do DO em relação a um DO saudável (Figura 4(a)) Este é um dos indicadores importantes, e vários parâmetros relacionados a esse alargamento da escavação têm sido utilizados para detectar o glaucoma (ZHANG et al., 2014).

Figura 4 – Mudanças causadas no DO pelo glaucoma.



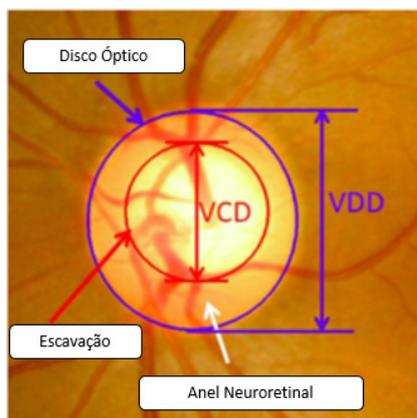
Fonte: (ACHARYA et al., 2017).

Alguns dos parâmetros utilizados para detecção do glaucoma são: o Cup-to-Disc Ratio (CDR), regra ISNT (Inferior, Superior, Nasal, Temporal) e atrofia peripapilar. O CDR é a razão entre o diâmetro vertical da escavação (VCD) e o diâmetro vertical do DO (VDD). Quando o DO é afetado pelo glaucoma há um aumento da escavação e conseqüentemente um aumento do valor do CDR. A Equação 3.1 (CHENG et al., 2013) apresenta como calcular o valor do CDR. A Figura 5 indica as medidas utilizadas no cálculo do CDR.

$$CDR = \frac{VCD}{VDD} \quad (3.1)$$

Em olhos saudáveis o anel neuroretinal segue um padrão característico de localização chamado regra ISNT apresentado na Figura 6(a). A distância da borda da escavação para a borda do DO deve ser maior na região inferior, seguida pelas regiões superior, nasal e temporal. A atrofia peripapilar é a degeneração da retina ao redor do DO como exemplificado na Figura 6(b). Para o cálculo das medidas CDR e ISNT é necessário

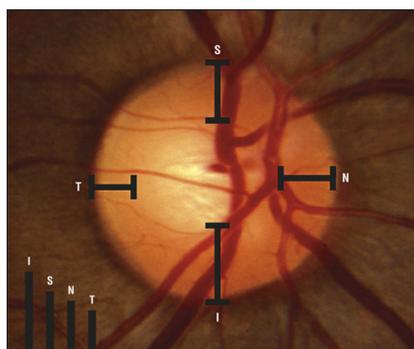
Figura 5 – Razão escavação disco.



Fonte: Adaptado de (ZHANG et al., 2014)

que a segmentação do disco óptico e escavação sejam precisas, pois pequenos erros de segmentação podem resultar em erros de diagnóstico.

Figura 6 – ISNT e atrofia peripapilar.



(a) ISNT



(b) Atrofia peripapilar

Fontes: (HALEEM et al., 2013; OPTICIAN, 2016)

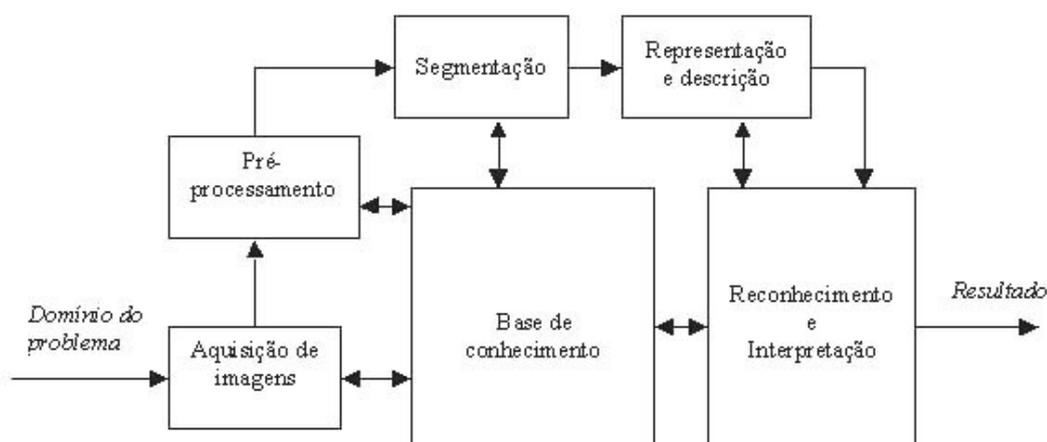
3.4 Processamento Digital de Imagens

O processamento digital de imagens consiste em um conjunto de técnicas para capturar, representar e transformar imagens com o auxílio do computador. Essas técnicas permitem extrair e identificar informações das imagens e melhorar a qualidade visual de certos aspectos estruturais, facilitando a percepção humana e a interpretação automática por meio de máquinas (PEDRINI; SCHWARTZ, 2008).

O processamento de imagens segue várias etapas que estão representadas na Figura 7 (GONZALEZ; WOODS, 2010). Essas etapas são: aquisição das imagens digitais,

pré-processamento, segmentação, representação, descrição e, reconhecimento e interpretação. O resultado gerado por uma etapa é utilizado como entrada na etapa seguinte onde cada entrada e resultado pode ou não ser uma imagem digital. Uma metodologia de processamento de imagens pode conter apenas um subconjunto de todas as etapas apresentadas (BRAZ, 2014).

Figura 7 – Passos fundamentais em processamento de imagens.



Fonte: Adaptado de (GONZALEZ; WOODS, 2010)

Na etapa de aquisição as imagens são capturadas por meio de um dispositivo ou sensor e convertidas para uma representação adequada para o processamento subsequente. A imagem resultante desse processo pode apresentar imperfeições decorrentes, por exemplo, das condições de iluminação ou características dos dispositivos.

O pré-processamento tem o objetivo de melhorar a qualidade da imagem por meio de técnicas para diminuição de ruído, correção de contraste ou brilho e suavização de determinadas propriedades da imagem.

A segmentação realiza a identificação e extração de áreas de interesse contidas na imagem, ou seja, a segmentação tem a função de dividir a imagem em seus componentes básicos.

A representação e descrição, que juntas são chamadas de extração de características, tem o objetivo de extrair propriedades que possam ser utilizadas na discriminação entre classes de objetos.

Na última etapa são realizados o reconhecimento e a interpretação. O reconhecimento é o processo que atribui um identificador aos objetos da imagem. A interpretação

consiste em atribuir um significado ao conjunto de objetos reconhecidos. O conhecimento sobre o domínio do problema está codificado na forma de uma base de conhecimento.

Para o desenvolvimento dessa dissertação, foram utilizadas as etapas de extração de características e reconhecimento de padrões, com base no modelo apresentado.

3.5 Técnicas de Pré-processamento

As imagens de fundo de olho possuem variações não relacionadas ao glaucoma. Essas variações incluem iluminação não homogênea, ruídos e baixo contraste, que ocorrem devido a complexidade do sistema óptico no processo de aquisição das imagens (BOCK et al., 2010; MARY; RAJSINGH; NAIK, 2016; ABRAMOFF; GARVIN; SONKA, 2010). Alguns dos principais fatores que contribuem para a existência dessas variações são: superfície curva da retina, grau de dilatação da pupila, movimentos inesperados do olho e outras doenças oculares (XIONG; LI; XU, 2017).

Técnicas de pré-processamento são de grande importância para o melhoramento das imagens e o aprimoramento do desempenho dos algoritmos de extração de características. Nesta seção são apresentadas as técnicas de pré-processamento de imagens utilizadas na metodologia proposta neste trabalho.

3.5.1 Filtro Homomórfico

O filtro homomórfico é utilizado para corrigir problemas de iluminação e reflectância em imagens digitais. A reflectância $r(x, y)$ é a quantidade de luz refletida pelos objetos da imagem e a iluminação $i(x, y)$ é a quantidade de luz na imagem. O filtro analisa essas informações para obter uma imagem com realce das altas frequências e atenuação das baixas frequências (BURGISS; GOODRIDGE, 2001).

A filtragem homomórfica inicia com uma imagem em escala de cinza, representada por $f(x, y)$. Em seguida os valores dos *pixels* são convertidos para o resultado do logaritmo $f(x, y) = \log(1 + f(x, y))$ onde a iluminação e reflectância são separados. Nessa imagem é aplicado um filtro passa baixa e um filtro passa alta que resultam em $\log(i(x, y))$ e $\log(r(x, y))$ respectivamente (MELO; VIEIRA; CONCI, 2004).

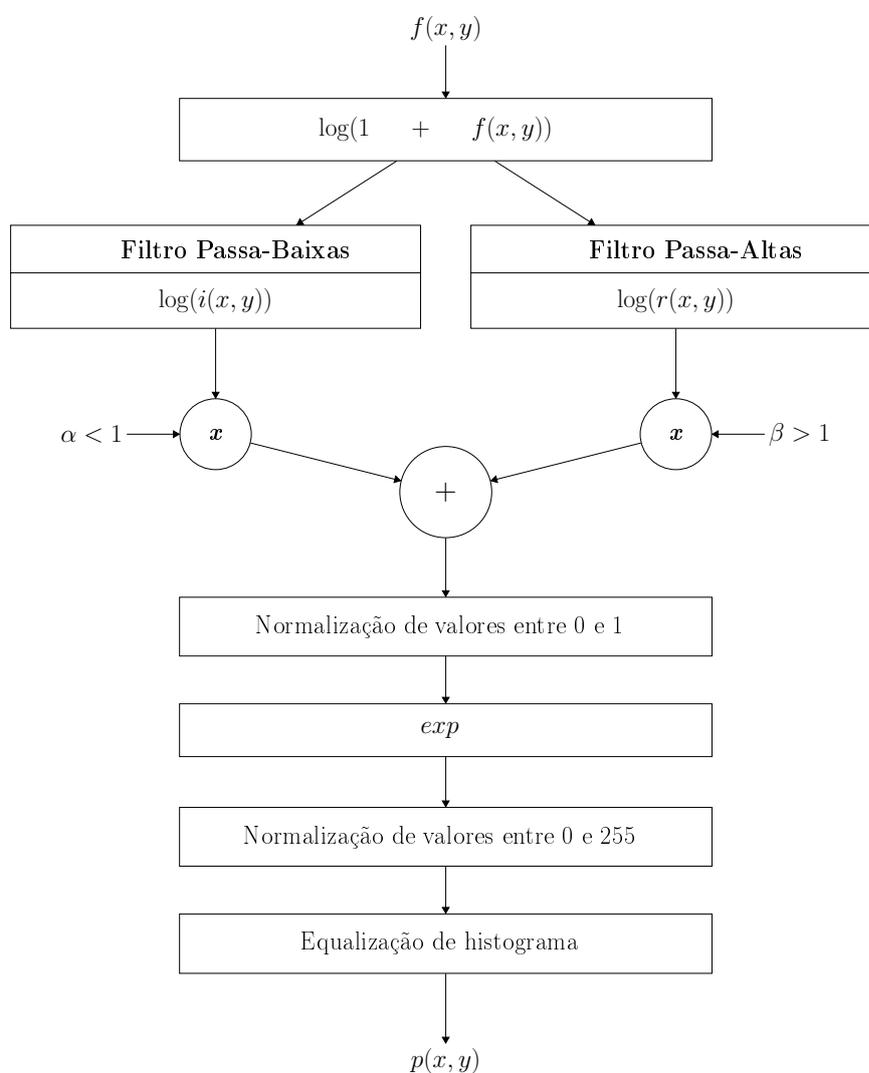
As imagens resultantes dos filtros passa-alta e passa-baixa são multiplicadas por α e β respectivamente, diminuindo os limites amplos de intensidade em $\log(i(x, y))$ e

aumentando o contraste local em $\log(r(x, y))$. Em seguida as imagens são somadas e normalizadas entre 0 e 1.

Ao final, é calculado o exponencial da imagem normalizada, seguida da normalização para os níveis de cinza entre 0 e 255, e equalização do histograma. A Figura 8 apresenta um resumo dos passos seguidos pelo filtro homomórfico. A sua utilização tem por finalidade diminuir a influência da iluminação no processamento das imagens.

A Figura 9(b) apresenta uma imagem após a aplicação do filtro homomórfico sobre a Figura 9(a).

Figura 8 – Filtro homomórfico.

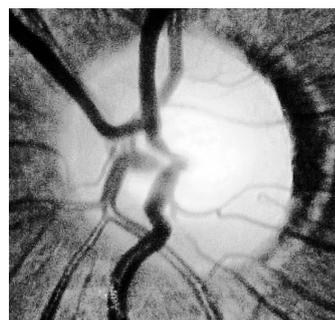


Fonte: (GOMES, 2017).

Figura 9 – Exemplo de utilização do filtro homomórfico.



(a) Imagem original



(b) Imagem após a aplicação do filtro homomórfico

Fonte: Elaborado pelo autor

3.5.2 Retinex

O algoritmo *Retinex* realiza a correção de iluminação de imagens. Para isso, assume que as variações espaciais pequenas nas imagens são consequências da iluminação do objeto, enquanto que variações grandes são decorrentes da própria superfície do objeto. É um algoritmo baseado na constância de cor que é a habilidade que o sistema visual humano possui de perceber a cor dos objetos relativamente constantes em diferentes condições de iluminação. O nome *retinex* é um termo derivado da contração das palavras retina e córtex que juntos compõem sistemas que captam informações de baixa, alta e média frequência da faixa visível do espectro eletromagnético (LAND; MCCANN, 1971).

O sistema visual humano utiliza um fenômeno psicofisiológico chamado localidade de percepção de cor. Nesse fenômeno as cores de uma área não são percebidas independentemente da cena visual que se encontra. Em vez disso, é fortemente influenciado pelo conteúdo cromático de outras áreas da cena (PROVENZI et al., 2007).

Existem várias implementações do *Retinex* para alcançar a constância de cor em imagens. Para esse trabalho foi utilizado o *Light Random Sprays Retinex (LRSR)* (BANIĆ; LONČARIĆ, 2013). Esse algoritmo é uma melhoria em termos computacionais e de qualidade de imagem do algoritmo *Random Sprays Retinex* proposto por (BANIĆ; LONČARIĆ, 2013).

O *Random Sprays Retinex* utiliza objetos 2D para representar a vizinhança de um pixel. Esses objetos recebem o nome de *spray* e são utilizados para calcular a nova intensidade de *pixel*. Para uma imagem de entrada as mudanças relativas de um pixel i

são calculadas usando a Equação 3.2,

$$C_{c,k}(i) = \frac{(I_c * k)(i)}{(R_c * k)(i)}, \quad (3.2)$$

onde $C_{c,k}(i)$ é a intensidade alterada do pixel i para um canal c , I_c é a intensidade original, R_c é a intensidade depois de executar o *Random Sprays Retinex*, e k é um filtro passa baixa.

Em seguida, outro filtro passa baixa é utilizado para uma nova redução dos ruídos, definido pela Equação 3.3,

$$C_{c,k_1,k_2}^*(i) = (C_{c,k}(i) * k_2)(i). \quad (3.3)$$

Ao final a mudança de intensidade para obter a imagem de saída O onde a intensidade para um pixel i de um canal c é calculada pela Equação 3.4,

$$O_c(i) = \frac{I_c(i)}{C_{c,k_1,k_2}^*(i)}. \quad (3.4)$$

3.5.3 Filtros Espaciais

Filtros são utilizados para o realce de imagens. Os filtros espaciais são aplicados no próprio plano da imagem, ou seja, no conjunto de *pixels* que compõem a imagem. O nível de cinza de um ponto após a transformação depende do valor do nível de cinza original do ponto e de outros pontos da vizinhança. O processo de filtragem é normalmente realizado por meio de máscaras que são aplicadas sobre a imagem (PEDRINI; SCHWARTZ, 2008).

3.5.3.1 Filtro Gaussiano

O filtro gaussiano é um filtro linear onde os coeficientes da máscara são derivados a partir de uma função gaussiana bidimensional (PEDRINI; SCHWARTZ, 2008). A máscara gaussiana é definida pela Equação 3.5,

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}}, \quad (3.5)$$

onde x é a distância da origem no eixo horizontal, y é a distância da origem no eixo vertical, e σ o desvio padrão da distribuição gaussiana.

A máscara é convoluída na imagem de entrada substituindo o valor do *pixel* central da máscara por uma média ponderada da sua vizinhança. O *pixel* central recebe o valor mais alto da gaussiana e os vizinhos recebem pesos menores à medida que a sua distância para o *pixel* central aumenta.

3.5.3.2 Filtro da Mediana

O filtro da mediana é um filtro de estatística de ordem não linear (GONZALEZ; WOODS, 2010). O filtro consiste em substituir a intensidade de cada pixel pela mediana das intensidades na vizinhança do pixel.

Dada uma janela J de tamanho $N \times N$ em torno de um *pixel* p_{ij} , todos os valores dentro dessa janela serão ordenados e, então o valor de p_{ij} é substituído pela mediana dos valores da janela $N \times N$. Se N é par, a mediana é a média dos valores dos elementos centrais encontrados pelas posições $\frac{N^2}{2}$ e $\frac{N^2}{2} + 1$. Se N é ímpar, a mediana é o valor do elemento da posição m , encontrada pela Equação 3.6,

$$m = \frac{N^2 + 1}{2} \quad (3.6)$$

O filtro da mediana é adequado para reduzir ruído impulsivo do tipo sal-e-pimenta (pontos brancos e pretos) pois as intensidades que diferem muito de uma dada vizinhança são descartadas. O filtro suaviza a imagem afetando menos as bordas em relação aos filtros lineares de suavização com tamanho similar.

3.5.4 Equalização de Histograma

O histograma de uma imagem corresponde à distribuição dos níveis de intensidade da imagem, o qual é representado por um gráfico indicando o número de pixels para cada nível de intensidade (PEDRINI; SCHWARTZ, 2008). O histograma de uma imagem digital com níveis de intensidade variando no intervalo de $0 \dots L - 1$ é dado pela expressão $h(r_k) = n_k$ onde r_k é a k -ésimo nível de intensidade e n_k é o número de pixels da imagem com intensidade r_k (GONZALEZ; WOODS, 2010).

A equalização de histograma tem por objetivo melhorar o contraste da imagem. O contraste pode ser definido como uma medida da variação relativa da intensidade dos pixels por unidade de área, ou seja, está relacionada com a distribuição dos níveis de intensidade em uma imagem. A equalização modifica o histograma de forma que a imagem

resultante possua uma distribuição mais uniforme dos níveis de intensidades, ou seja, os níveis devem aparecer na imagem aproximadamente com a mesma frequência (PEDRINI; SCHWARTZ, 2008).

O histograma acumulado de $h(r_k)$ pode ser calculado pela Equação 3.7,

$$H(0) = h(0); H(1) = H(0) + h(1); H(r_k) = H(r_k - 1) + h(r_k), \quad (3.7)$$

para $r_k = 1, \dots, L - 1$.

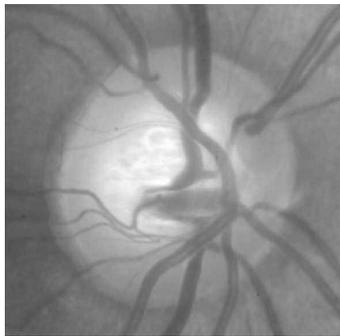
O novo histograma é obtido utilizando a Equação 3.8,

$$T(r_k) = \frac{L - 1}{MN} H(r_k), \quad (3.8)$$

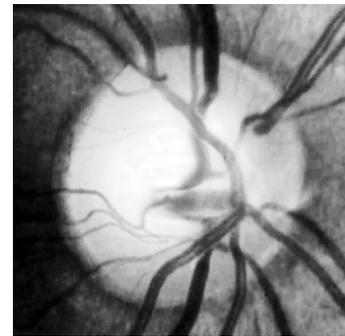
onde M e N são as dimensões da imagem.

A imagem equalizada é obtida por pixel por $I = T(r_k)$. A Figura 10(b) apresenta uma imagem após a aplicação da equalização de histograma sobre a Figura 10(a).

Figura 10 – Exemplo de utilização da equalização de histograma.



(a) Imagem original.



(b) Imagem após a equalização do histograma.

Fonte: Elaborado pelo autor.

3.6 Extração de Características

A etapa de extração de características tem o objetivo de extrair informações quantitativas das imagens em busca de padrões. As características extraídas das imagens devem ser descorrelacionadas e ter propriedades invariantes a rotação, translação e escala. (CONCI; AZEVEDO; LETA, 2008). A extração de características pode ser dividida em duas categorias de análise, que são: textura e forma.

A textura contém informações sobre a distribuição espacial e a variação de luminosidade, além de descrever o arranjo estrutural das superfícies e relações entre regiões vizinhas. A textura é caracterizada bidimensionalmente, sendo que uma dimensão contém as propriedades primitivas ou estatísticas de tonalidades e a outra corresponde aos relacionamentos espaciais entre elas (PEDRINI; SCHWARTZ, 2008; CONCI; AZEVEDO; LETA, 2008).

Também é possível extrair informações sobre propriedades morfológicas das imagens. Essas medidas, em sua essência, caracterizam forma e aparência dos objetos através do contorno ou da área do objeto em estudo (BRAZ, 2014).

Esta dissertação propõe a análise de textura por meio de índices de diversidade para o reconhecimento de padrões de textura. Os índices de diversidade, utilizados na ecologia, são empregados nesse estudo para a caracterização da textura da região do DO em imagens de fundo de olho, para o reconhecimento em glaucomatosas ou saudáveis.

3.6.1 Índices de Diversidade para Extração de Características de Textura

Diversidade, no contexto de ecologia, refere-se a variedade de espécies em uma comunidade ou *habitat*. Biodiversidade envolve dois conceitos: riqueza de espécies e uniformidade. Riqueza de espécie é simplesmente o número de espécies presentes em uma determinada comunidade ou área de interesse. Uniformidade descreve a variabilidade na abundância de espécies. Em uma comunidade em que todas as espécies tem aproximadamente o mesmo número de indivíduos sua uniformidade é máxima. Um índice de diversidade é uma estatística que incorpora informações de riqueza e uniformidade. Esse é utilizado para medir a diversidade de uma comunidade onde cada membro pertence a uma única espécie (MARRUGAN, 2004).

Os índices de diversidade são utilizados em situações comparativas. Pode-se utilizá-los para dizer que a comunidade *A* possui uma maior ou menor diversidade que a comunidade *B* (MELO, 2008). Para entender as equações que calculam os índices são necessárias algumas definições: S é o número de espécies presentes na amostra, N é o número total de indivíduos da amostra, n_i é o número de indivíduos da espécie i , e p_i é a probabilidade de um indivíduo pertencer à espécie i , sendo calculado por $p_i = n_i/N$.

O índice de *Shannon* é derivado da teoria da informação e assume que indivíduos são amostrados aleatoriamente de uma comunidade infinitamente grande e que todas

as espécies estão representadas na amostra (MARRUGAN, 2004), sendo definido pela Equação 3.9,

$$H = - \sum_{i=1}^S p_i \ln p_i. \quad (3.9)$$

Espécies raras e abundantes têm pesos iguais. Valores altos do índice representam maior heterogeneidade da comunidade, o que implica uma maior riqueza.

O índice de *McIntosh* parte do princípio que uma comunidade pode ser vista como um ponto em um hiper-volume S-dimensional e a distância euclidiana da comunidade para a origem pode ser utilizada como uma medida de diversidade. O índice é uma medida de probabilidade de dois indivíduos selecionados aleatoriamente de uma comunidade infinitamente grande pertencerem à mesma espécie (MARRUGAN, 2004), sendo definido pela Equação 3.10,

$$Mc = \frac{N - U}{N - \sqrt{N}}, \quad (3.10)$$

onde $U = \sqrt{\sum_{i=1}^S n_i^2}$ é a distância euclidiana da comunidade para a origem. O valor do índice varia de 0 a 1, que indicam diversidade baixa e máxima respectivamente.

O índice de Diversidade Total estima a riqueza total de uma população com base na variação de espécies (MARRUGAN, 2004), sendo definido pela Equação 3.11,

$$Dt = - \sum_{i=1}^S w_i (p_i (1 - p_i)), \quad (3.11)$$

onde w_i é o peso dado individualmente a uma espécie caracterizado por $\frac{1}{n_i}$

Esta dissertação investiga o uso dos índices de diversidade de *Shannon*, *McIntosh* e *Diversidade Total*, como descritores de textura, para diferenciar imagens de fundo de olho como saudáveis ou glaucomatosas. Para realizar essa implementação é necessário fazer a correspondência entre os termos utilizados na biologia e os utilizados nesse trabalho. A Tabela 2 mostra essa correspondência.

Tabela 2 – Correspondência entre os termos da biologia e da metodologia proposta.

Biologia	Metodologia
Comunidade	Região de análise na imagem
Indivíduos	<i>Pixels</i> da região de análise
Espécies	Valores de intensidade dos <i>pixels</i>

3.7 Seleção de Características usando Algoritmo Genético

Algoritmos genéticos são algoritmos de busca e otimização baseados em teorias e conceitos de seleção natural e genética. A estrutura de soluções potenciais é codificada na forma de cromossomos. Uma população de cromossomos é evoluída por meio de conceitos básicos de genética (operações de *crossover* e mutação) e seleção natural (operações de seleção), com o objetivo de criar indivíduos (cromossomos) mais aptos a cada geração (GOLDBERG, 1989; SILVA, 2011).

Para aplicar algoritmos genéticos para seleção de características os cromossomos podem ser representados por uma sequência de 0 e 1 para indicar a ausência e a presença respectivamente de uma característica no subconjunto selecionado. O 1 representa que a k -ésima característica da sequência será selecionada e o 0 representa que essa característica não será selecionada (SIEDLECKI; SKLANSKY, 1989).

Inicialmente um conjunto de possíveis soluções do problema, denominado população, é gerado sendo formado por um conjunto aleatório de cromossomos. Durante cada incremento temporal, chamado geração, a população é avaliada. Os indivíduos da população recebem notas que refletem sua habilidade de adaptar-se ao ambiente. Uma parte dos indivíduos mais adaptados é mantida e os outros são descartados. Os indivíduos mantidos sofrem modificações em suas características por meio de cruzamentos (*crossover*) e mutações para gerarem uma população de indivíduos descendentes para a próxima geração. As populações de indivíduos evoluem por sucessivas gerações até que um critério de parada seja satisfeito.

3.8 Reconhecimento de Padrões

Padrão é um termo genérico que se refere a qualquer elemento que possa ser definido quantitativamente (CONCI; AZEVEDO; LETA, 2008). Técnicas de reconhecimento de padrões são utilizadas para classificar objetos através de um conjunto de características extraídas. O objetivo do reconhecimento de padrões é a classificação (agrupamento das amostras em classes) e o reconhecimento de objetos desconhecidos como pertencentes a uma das classes.

A classificação pode ser feita de duas formas: supervisionada e não-supervisionada. Na classificação supervisionada um conjunto de treinamento é executado anteriormente para a obtenção dos parâmetros que caracterizam cada classe. Em seguida, o classificador

é capaz de identificar a classe de qualquer objeto desconhecido da mesma população do treinamento. Já na classificação não-supervisionada não existe treinamento prévio. Nesse caso, todas as informações de interesse devem ser obtidas a partir dos próprios objetos a serem classificados (PEDRINI; SCHWARTZ, 2008).

Este trabalho usa máquina de vetor de suporte para o reconhecimento de padrão das imagens de fundo de olho em saudáveis ou glaucomatosas.

3.8.1 Máquina de Vetores de Suporte (MVS)

A MVS (VAPNIK, 1998) é um método para estimar uma função de classificação dos dados baseada na construção de um hiperplano como superfície de decisão de forma que a margem de separação entre as classes seja maximizada. A MVS utiliza o princípio de minimização do risco estrutural, que se baseia no fato de que a taxa de erro de uma máquina de aprendizado nos dados de teste é limitada pela soma da taxa de erro de treinamento e por um termo que depende da dimensão Vapnik-Chervonenkis (dimensão VC) (ZHUANG; DAI, 2006).

Na MVS a superfície de decisão é definida pela Equação 3.12,

$$f(x) = \sum_{i=1}^l \alpha_i y_i k(x, x_i) + b, \quad (3.12)$$

onde $k(x, x_i) = \Phi(x) \cdot \Phi(x_i)$ é a função de *kernel* (Φ representa a transformação dos dados de entrada para um espaço de característica de maior dimensão), e os coeficientes α_i e b , são soluções da Equação 3.13,

$$\min_{w, b, \xi} \frac{1}{2} w^T \cdot w + C \sum_{i=1}^l \xi_i, \quad (3.13)$$

sujeito a Equação 3.14,

$$y_i [w^T \cdot \phi(x_i) + b] \geq 1 - \xi_i, \quad (3.14)$$

onde w é um vetor de pontos perpendicular no hiperplano de separação, $C > 0$ é um parâmetro escolhido pelo usuário, correspondendo a penalidade do erro, e os ξ_i 's são variáveis de folga que penalizam os erros de treinamento.

Funções de *kernel* são utilizadas pela MVS para lidar com distribuição de dados que possuem separação de limites complexa. Os dados no espaço de características são transformados para outro espaço de maior dimensão onde é possível criar um hiperplano

de separação. A *Radial Basis Function* (RBF) é definida pela equação $k(x, y) = e^{-\gamma\|x-y\|^2}$ onde $\gamma > 0$ é um parâmetro escolhido pelo usuário.

3.9 Métricas de Desempenho

O resultado da classificação é identificar as imagens como saudáveis ou glaucomatosas. Para avaliar o desempenho do método proposto são utilizadas as métricas de sensibilidade, especificidade e acurácia que são estatísticas tipicamente aplicadas a análise de imagens médicas (BLAND, 2015). Para a avaliação do teste, quatro situações são possíveis:

1. Verdadeiro Positivo (VP): Uma imagem glaucomatosa é corretamente classificada;
2. Falso Positivo (FP): Uma imagem saudável é considerada glaucomatosa;
3. Verdadeiro Negativo (VN): Uma imagem saudável é corretamente classificada;
4. Falso Negativo (FN): Uma imagem glaucomatosa é considerada saudável;

A sensibilidade (SEN) indica a porcentagem de vezes que o teste acertou imagens glaucomatosas, sendo definida pela Equação 3.15,

$$SEN = \frac{VP}{VP + FN}. \quad (3.15)$$

A especificidade (ESP) é a porcentagem de vezes que o teste acertou imagens saudáveis, sendo definida pela Equação 3.16,

$$ESP = \frac{VN}{VN + FP}. \quad (3.16)$$

A acurácia (AC) é a porcentagem de casos classificados corretamente sobre o número total de casos, sendo definida pela Equação 3.17,

$$AC = \frac{VP + VN}{VP + FP + VN + FN}. \quad (3.17)$$

4 MATERIAIS E MÉTODOS

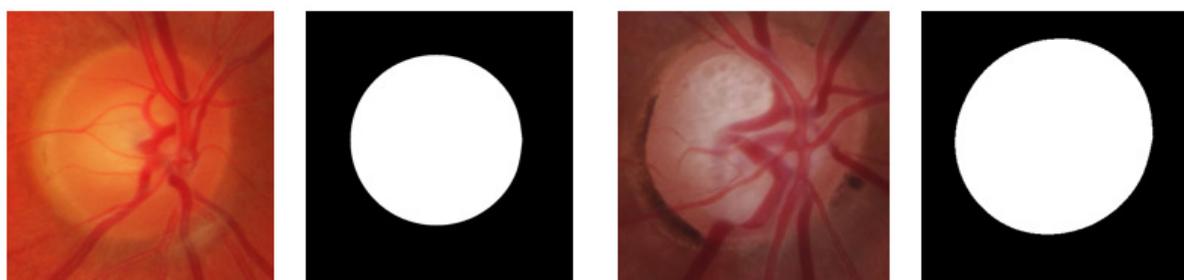
Neste capítulo serão descritos os procedimentos utilizados para o diagnóstico do glaucoma a partir de imagens de fundo de olho. Primeiramente a base de imagens em que será aplicada a metodologia é apresentada. E em seguida, é descrita a sequência de etapas realizadas para alcançar o objetivo da metodologia.

4.1 Base de Imagens

A base de imagens de fundo de olho utilizada neste trabalho é a RIM-ONE segunda versão (TRUCCO et al., 2013), que é disponibilizada com imagens fornecidas por três hospitais: Hospital Universitário de Canarias, Hospital Clínico San Carlos e Hospital Universitário Miguel Servet. A base possui 455 imagens separadas em duas classes. A classe *Normal*, possui 255 imagens de retinas saudáveis, e a classe *Glaucoma and Suspicious* possui 200 imagens de retinas com glaucoma, ou suspeitas. Algumas das imagens da classe *Glaucoma and Suspicious*, por não apresentarem o diagnóstico claro e definitivo, são semelhantes às imagens da classe *Normal*.

As imagens são fornecidas no formato JPEG, sistema de cor RGB e acompanhadas por uma marcação, indicando a região do DO. A Figura 11(a) apresenta exemplo de imagem da classe *Normal* e a Figura 11(b) da classe *Glaucoma and Suspicious* acompanhadas de suas respectivas marcações do DO.

Figura 11 – Exemplos de imagens de fundo de olho.



(a) *Normal*

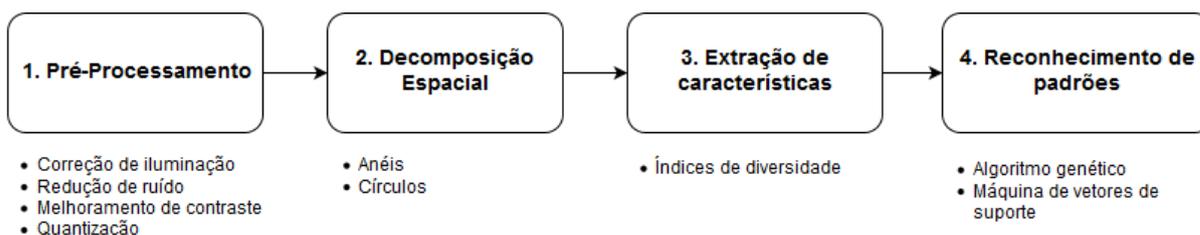
(b) *Glaucoma and Suspicious*

Fonte: Elaborado pelo autor

4.2 Metodologia Proposta

A metodologia proposta neste trabalho possui quatro etapas. A sequência que essas etapas são realizadas é apresentada na Figura 12. Na primeira etapa é realizado o pré-processamento onde é feita a correção de iluminação, redução de ruído e melhoramento de contraste, com o objetivo de eliminar variações na imagem, não relacionadas ao glaucoma, e realçar elementos da textura. No pré-processamento também é realizada a quantização. Na segunda etapa a região do DO é obtida utilizando a máscara fornecida pela base e em seguida essa é decomposta em sub-regiões. Na terceira etapa é realizada a extração de características utilizando os índices de diversidade de *Shannon*, *Mcintosh* e Diversidade Total. Por fim, na quarta etapa, ocorre a seleção de características com algoritmo genético e classificação utilizando MVS.

Figura 12 – Etapas da metodologia.



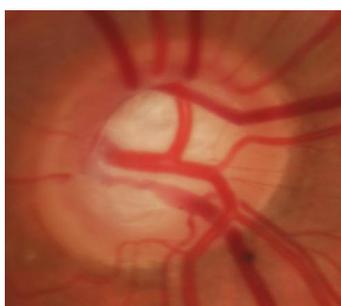
Fonte: Elaborado pelo autor

4.2.1 Pré-processamento

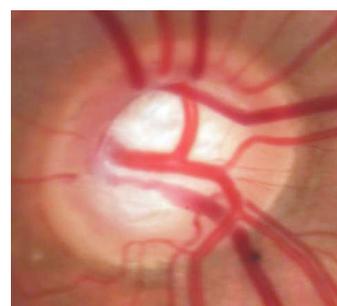
As imagens de fundo de olho são inicialmente submetidas a uma etapa de pré processamento que tem por objetivo retirar as variações não relacionadas ao glaucoma (Seção 3.5) e melhorar o contraste. O pré-processamento está dividido em quatro sub-etapas, que serão realizadas nessa ordem: correção de iluminação, redução de ruído, melhoramento de contraste e quantização.

A primeira subetapa é a correção de iluminação. Para essa sub-etapa foram realizados testes com o algoritmo de correção de iluminação *Retinex* (Seção 3.5.2) e também com o filtro homomórfico (Seção 3.5.1). Os dois algoritmos não foram utilizados em conjunto, ou seja, serão mostrados experimentos utilizando um por vez para a sub-etapa de correção de iluminação. Quando é utilizado o algoritmo *Retinex* a correção de iluminação é realizada na imagem colorida. A Figura 13 apresenta um exemplo do resultado da aplicação do algoritmo *Retinex*.

Figura 13 – Aplicação da correção de iluminação com Retinex.



(a) Imagem Original



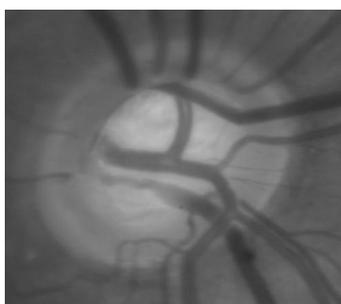
(b) Imagem após a aplicação do *Retinex*

Fonte: Elaborado pelo autor

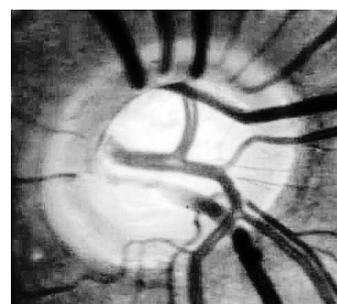
Quando é utilizado o filtro homomórfico (Seção 3.5.1) a correção de iluminação é aplicada a cada canal RGB da imagem isoladamente e na imagem em escala de cinza. A imagem em escala de cinza é gerada a partir da aplicação da Equação 4.1 (KANAN; COTTRELL, 2012). A Figura 14 apresenta um exemplo do resultado da aplicação do filtro homomórfico na imagem em escala de cinza.

$$GrayScale = 0,3.R + 0,59.G + 0,11.B \quad (4.1)$$

Figura 14 – Aplicação da correção de iluminação com filtro homomórfico na imagem em escala de cinza.



(a) Imagem em escala de cinza



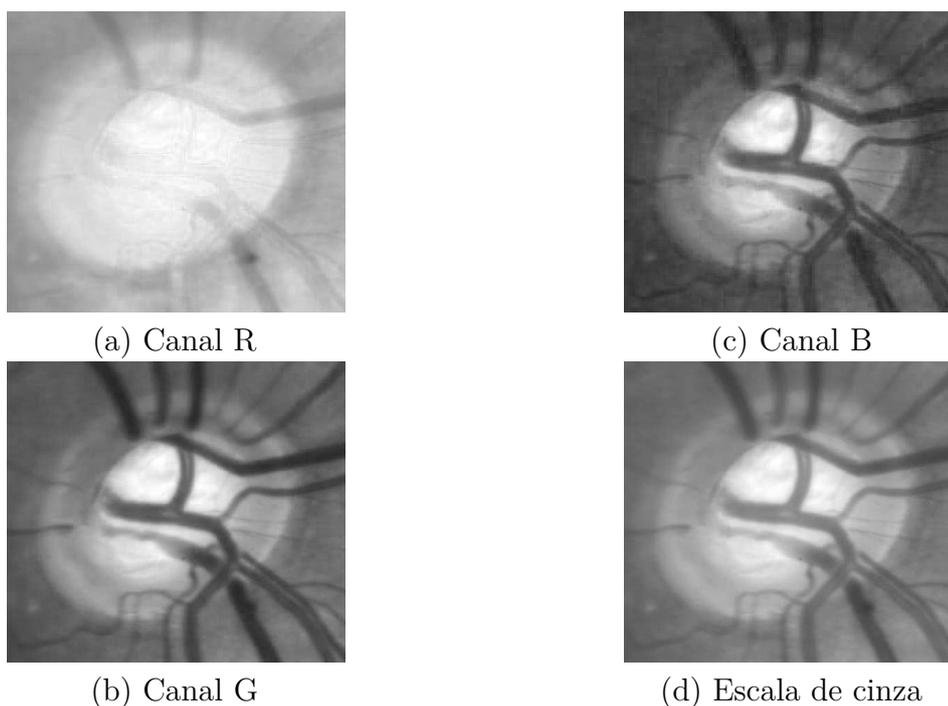
(b) Imagem após a aplicação do filtro homomórfico

Fonte: Elaborado pelo autor

A Figura 15 apresenta, após a aplicação da correção de iluminação, os canais red - R (Figura 15(a)), blue - B (Figura 15(b)) e green - G (Figura 15(c)) de uma imagem de fundo de olho, e a imagem em escala de cinza (Equação 4.1) (Figura 15(d)). Essas imagens (R, G, B e escala de cinza) serão utilizadas para as próximas etapas da metodologia. Cada um dos canais RGB da imagem representa características diferentes da anatomia do fundo do olho. O DO e suas bordas são mais visíveis no canal R (HALEEM et al.,

2013). Essa propriedade é utilizada para verificar as mudanças causadas pelo glaucoma que se encontram próximas às bordas do DO. O canal G apresenta um melhor contraste (ISSAC; SARATHI; DUTTA, 2015) e, assim como no canal B, a escavação é mais visível pois seus *pixels* tem uma intensidade maior (mais brilhosos) que os *pixels* do restante do DO (ALMAZROA et al., 2015). A imagem em escala de cinza é utilizada para gerar mais informação acerca da região do DO.

Figura 15 – Canais R, G, B e imagem em escala de cinza.



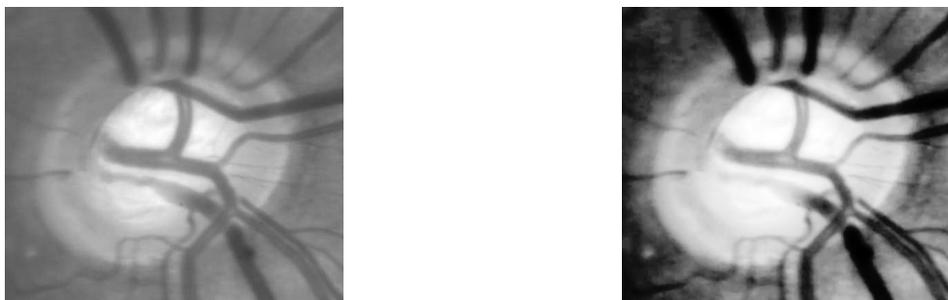
Fonte: Elaborado pelo autor.

A segunda sub-etapa é a redução de ruídos utilizando um filtro da mediana e um filtro da gaussiana, ambos com tamanho de janela 3×3 . O filtro da mediana remove ruído do tipo sal-e-pimenta. O filtro gaussiano suaviza a imagem (GONZALEZ; WOODS, 2010).

A terceira sub-etapa é o melhoramento do contraste utilizando equalização de histograma (Seção 3.5.4). Esse processo ajusta as intensidades dos *pixels* para obter a máxima variância do histograma, obtendo assim uma imagem com melhor contraste (GONZALEZ; WOODS, 2010). A Figura 16 (b) mostra o resultado da aplicação dos filtros e da equalização de histograma. Pode-se notar pelo resultado da aplicação da equalização de histograma uma melhor visualização da escavação, do DO, do anel neuroretinal, da região peripapilar e dos vasos sanguíneos. Com isso, espera-se que o método de extração

de características consiga extrair com mais detalhes as variações que o glaucoma provoca no DO e seu entorno.

Figura 16 – Exemplo de melhoramento de contraste e redução de ruído.



(a) Imagem com correção de iluminação Retinex (b) Imagem após a aplicação dos filtros e equalização de histograma

Fonte: Elaborado pelo autor.

A quarta subetapa consiste em quantizar cada imagem em outras cinco imagens com faixa máxima de valores diferentes. São utilizadas imagens quantizadas com: 7, 6, 5, 4, e 3 *bits*. O processo de quantização linear é utilizado para combinar os indivíduos (*pixels*) em um número menor de espécies (intensidades). Assim, espera-se aumentar a capacidade de capturar informações sobre indivíduos de baixa ocorrência ao serem unidos com outros indivíduos. Cada imagem gerada pelo processo de quantização e a imagem com 8 *bits* (totalizando 6 imagens) são utilizadas separadamente durante a etapa de extração de características. Porém, as seis imagens pertencentes a cada canal/imagem (R, G, B e Escala de cinza) são utilizadas em conjunto na etapa de reconhecimento.

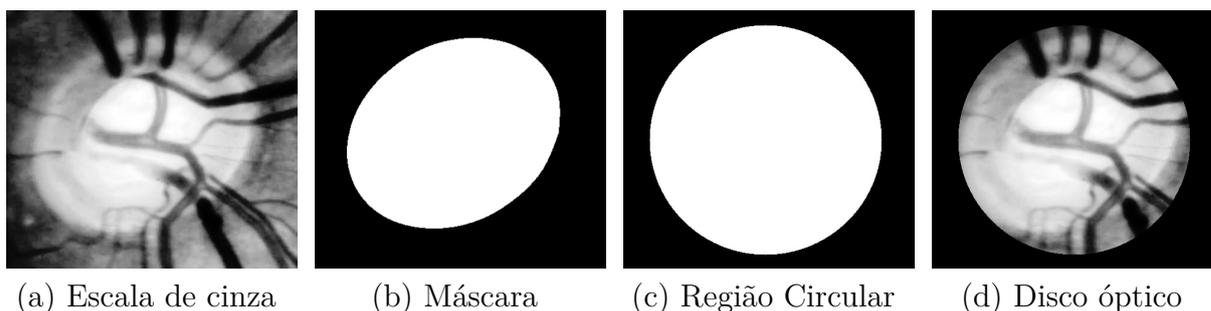
4.2.2 Decomposição Espacial

Após o pré-processamento, as imagens resultantes passam por um processo de divisão espacial com o objetivo de descrever melhor as características das diversas partes que compõem a região de interesse. Primeiro é necessário obter a região do DO utilizando a máscara fornecida pelo especialista (Figura 17 (b)). Inicialmente é encontrado o valor do raio que circunscreve toda a máscara. Esse raio é utilizado para gerar um círculo (Figura 17 (c)) que terá o mesmo centro da máscara. Esse círculo será utilizado para obter a região do DO e região peripapilar¹ (Figura 17 (d)).

A região do DO é dividida em sub-regiões em forma de círculos ou anéis. Essas divisões permitem analisar a textura do DO regionalmente. O objetivo dessas divisões

¹ Região compreendida ao redor do disco óptico.

Figura 17 – Obtenção da região do DO.



Fonte: Elaborado pelo autor.

é verificar o padrão de comportamento da textura iniciando da região central, onde está localizada a escavação², passando pelo anel neuroretinal³ e seguindo na direção da região peripapilar, uma vez que, imagens glaucomatosas apresentam atrofia peripapilar⁴ e a escavação ocupa uma maior área na região central do DO em relação a imagens saudáveis. As divisões espaciais em círculos e anéis não são utilizadas em conjunto, ou seja, serão mostrados experimentos utilizando uma decomposição por vez para a etapa de decomposição espacial.

Para a decomposição em círculos, o raio de cada círculo é calculado utilizando-se como base o valor do maior raio, o qual corresponde ao raio da região circular, que engloba o DO (Figura 17 (d)).

Os valores dos raios de cada círculo concêntrico são calculados utilizando a Equação 4.2,

$$R_i = i \cdot \frac{R_{max}}{nr}, \quad (4.2)$$

onde R_i é o raio do i -ésimo círculo, R_{max} é o valor do maior raio, i é o índice do raio do círculo a ser determinado e nr é o total de círculos que cada imagem será dividida. A Figura 18 apresenta exemplos de sub-regiões geradas em forma de círculos.

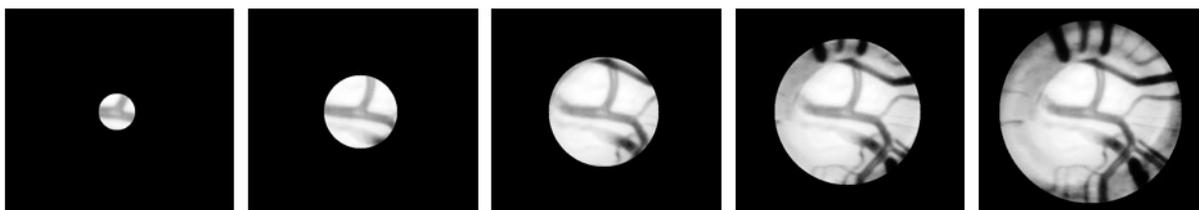
A partir dos círculos são obtidas as sub-regiões em forma de anéis. A área de um anel é formada entre dois círculos consecutivos pois esses compartilham o mesmo centro. Tomando por base o círculo de maior raio é retirada sua intersecção com o círculo de raio menor, obtendo-se assim uma sub-região em forma de anel. A Figura 19 apresenta

² Região central brilhante do DO.

³ Área localizada entre as bordas do DO e da escavação.

⁴ Degeneração da retina na região peripapilar.

Figura 18 – Exemplos de sub-regiões em forma de círculos.



Fonte: Elaborado pelo autor.

exemplos de sub-regiões geradas em forma de anéis.

Figura 19 – Exemplos de sub-regiões em forma de anéis.



Fonte: Elaborado pelo autor.

Para esta metodologia adotou-se um total de cinco sub-regiões tanto para a decomposição em círculos como em anéis. Este número foi obtido empiricamente. Cada sub-região gerada será submetida por todo o processo de descrição de textura.

4.2.3 Extração de características

Após as etapas de pré-processamento e decomposição espacial as sub-regiões geradas são submetidas a etapa de extração de características baseada somente em textura, as quais, formarão os vetores de características que serão utilizados na etapa de classificação. Este trabalho utiliza índices de diversidade para extrair características da região do DO em imagens de fundo de olho. Os índices utilizados são: *Shannon* (Equação 3.9), *McIntosh* (Equação 3.10) e *Diversidade Total* (Equação 3.11), apresentados na Seção 3.6.1.

Os índices de diversidade são utilizados para analisar a distribuição de espécies em uma região de análise. Adaptando o conceito para análise de imagens essa distribuição é obtida utilizando o histograma da região da imagem a ser analisada.

Através do histograma obtêm-se os itens básicos utilizados para calcular os índices de diversidade:

- S: número de intensidades de cinza que tem ocorrência maior que zero que equivale ao número de espécies presentes na região;
- N: número total de *pixels* da imagem que equivale ao número de indivíduos;
- i: valor do *pixel* (intensidade) que equivale a espécie;
- n_i : número de *pixels* com a intensidade i que equivale ao número de indivíduos de uma espécie i.

4.2.4 Reconhecimento de Padrões

A última etapa da metodologia é o reconhecimento de padrões e consiste em classificar as imagens de fundo de olho em glaucomatosas e saudáveis. Os vetores de características são obtidos utilizando os índices de diversidade como descritores de textura. Esta metodologia utiliza MVS com o *kernel Radial Base Function* para classificar as imagens.

A base utilizada na classificação é constituída pelos vetores de características extraídos das imagens acompanhados dos rótulos das suas classes. Os vetores de características são normalizados entre -1 e 1. Esse procedimento ajuda a melhorar a performance do classificador (DUDA; HART, 1973).

Em seguida é realizada a seleção de características utilizando algoritmo genético (Seção 3.7). A aplicação da seleção gera um número específico de variáveis para cada técnica de extração de características. A Tabela 3 mostra os parâmetros utilizados para a seleção.

Tabela 3 – Parâmetros do algoritmo genético.

Parâmetro	Valor(%)
Probabilidade de <i>crossover</i>	0,6
Número de gerações	1000
Probabilidade de mutação	0,033
Número de indivíduos	1200

Para realizar a classificação, a base de vetores com as características selecionadas é dividida em duas partes: treinamento e teste. Para as divisões, as proporções utilizadas são apresentadas na Tabela 4 com os dados de treinamento e teste escolhidos aleatoriamente. A quantidade de combinações de treinamento e teste pretende verificar o desempenho da metodologia com diferentes quantidades de dados para treinamento.

Tabela 4 – Proporções de treinamento e teste para a etapa de classificação.

Proporções	Treinamento(%)	Teste(%)
50/50	50	50
60/40	60	40
70/30	70	30
80/20	80	20

Em seguida os parâmetros C e γ da MVS foram estimados para cada novo conjunto de treinamento/teste com o objetivo de alcançar a melhor taxa de acerto. Durante o treinamento é gerado um modelo que será utilizado para classificar os vetores de características da base de teste. Para a execução dos testes foi utilizada a implementação da MVS disponível na biblioteca LIBSVM (CHANG; LIN, 2011).

Para mensurar o desempenho da metodologia proposta e validar seus resultados foram utilizadas as técnicas de análise de sensibilidade, especificidade e acurácia, apresentados na Seção 3.9. Essas são as métricas de desempenho tipicamente aplicadas a análise de imagens médicas (BLAND, 2015).

5 RESULTADOS E DISCUSSÃO

Este capítulo apresenta e discute os resultados obtidos pela metodologia proposta para classificação de imagens de fundo de olho em saudáveis e glaucomatosas. Para os testes da metodologia foram utilizadas todas as 455 imagens da base RIM-ONE segunda versão apresentada na Seção 4.1.

Inicialmente todas as imagens foram submetidas à etapa de pré-processamento explicado na Seção 4.2.1. Essa etapa se inicia com a correção de iluminação. Em seguida são obtidas 4 imagens que correspondem aos 3 canais (R, G e B) da imagem colorida e a imagem em escala de cinza. Cada uma das imagens passa pelos processos de redução de ruído, melhoramento de contraste e quantização.

Após o pré-processamento, a região do DO é obtida utilizando a marcação da base e realiza-se sua decomposição espacial em sub-regiões, conforme apresentado na Seção 4.2.2.

Cada sub-região é descrita utilizando os índices de diversidade (Seção 4.2.3). Inicialmente a base de características obtida é normalizada entre -1 e 1. Em seguida é realizada a seleção de características e logo após a base é dividida em treinamento e teste, conforme explicado na Seção 4.2.4, partindo de uma proporção de treinamento menor até uma maior. Para cada proporção de treinamento/teste são realizadas cinco classificações. Essa configuração de número de proporções e repetições tem o objetivo de mostrar que a metodologia é robusta em diversas situações. Os parâmetros C e γ da MVS com *kernel* RBF foram estimados para cada novo conjunto de treinamento/teste.

Nas próximas seções são apresentados os resultados dos experimentos realizados neste trabalho. Os experimentos estão divididos pela técnica de correção de iluminação utilizada. Destaca-se que para cada experimento foram investigadas as duas abordagens de decomposição espacial detalhadas na Seção 4.2.2. Também foram realizados experimentos com variações no tamanho da região de análise do DO, cujo objetivo é verificar a capacidade da metodologia para classificar as imagens mesmo com possíveis erros de segmentação ou marcação da região do DO. São apresentadas as médias de acurácia, sensibilidade e especificidade, juntamente com seus desvios-padrão, para cada proporção utilizada, destacando-se o melhor resultado em cada experimento.

5.1 Experimentos utilizando *Retinex*

A seguir, são apresentados os resultados dos experimentos em que se utilizou *Retinex* para a correção de iluminação. Os experimentos foram realizados para cada índice de diversidade, individualmente e combinados.

A Tabela 5 apresenta os resultados médios e os respectivos desvios-padrão obtidos utilizando o índice de *Shannon*. Ao todo são geradas 120 características (4 imagens (R, G, B, Escala de cinza) . 6 quantizações . 5 sub-regiões . 1 índice). Após a seleção, na decomposição espacial em círculos, resultaram 28 características. O melhor resultado obtido por essa abordagem foi com a proporção 80/20 alcançando uma média de acurácia de 86,59%, média de sensibilidade de 89,92% e média de especificidade de 84,94%. Na decomposição espacial em anéis, após a seleção, resultaram 29 características. O melhor resultado obtido por essa abordagem foi com a proporção 80/20 alcançando uma média de acurácia de 89,45%, média de sensibilidade de 88,16% e média de especificidade de 90,32%.

Tabela 5 – Resultados do índice de *Shannon* com correção de iluminação *Retinex*.

Decomposição	Proporção (%)	Acurácia (%)	Sensibilidade (%)	Especificidade (%)
Círculos	50/50	82,28 ± 2,05	85,04 ± 5,97	80,03 ± 3,63
	60/40	83,74 ± 3,78	81,44 ± 10,27	86,17 ± 2,80
	70/30	83,80 ± 4,01	81,56 ± 8,60	85,20 ± 4,91
	80/20	86,59 ± 7,37	89,92 ± 4,86	84,94 ± 11,81
Anéis	50/50	85,18 ± 1,60	82,08 ± 5,29	87,41 ± 3,32
	60/40	86,26 ± 2,11	85,96 ± 6,35	86,12 ± 8,84
	70/30	85,99 ± 4,67	84,75 ± 8,36	86,57 ± 10,78
	80/20	89,45 ± 4,04	88,16 ± 7,11	90,32 ± 4,16

A Tabela 6 apresenta os resultados médios e os respectivos desvios-padrão obtidos utilizando o índice de *McIntosh*. Assim como a abordagem anterior também são geradas 120 características. Após a seleção, na decomposição espacial em círculos, resultaram 19 características. O melhor resultado obtido por essa abordagem foi com a proporção 70/30 alcançando uma média de acurácia de 85,11%, média de sensibilidade de 82,78% e média de especificidade de 87,94%. Na decomposição espacial em anéis, após a seleção, resultaram 31 características. O melhor resultado obtido por essa abordagem foi com a proporção 80/20 alcançando uma média de acurácia de 93,41%, média de sensibilidade de 92,83% e média de especificidade de 93,69%.

A Tabela 7 apresenta os resultados médios e os respectivos desvios-padrão obtidos

Tabela 6 – Resultados do índice de *McIntosh* com correção de iluminação *Retinex*.

Decomposição	Proporção (%)	Acurácia (%)	Sensibilidade (%)	Especificidade (%)
Círculos	50/50	83,07 ± 1,93	85,72 ± 1,50	80,93 ± 3,47
	60/40	82,42 ± 3,94	83,64 ± 6,45	81,42 ± 4,25
	70/30	85,11 ± 3,46	82,78 ± 8,48	87,00 ± 5,09
	80/20	83,96 ± 4,95	87,19 ± 3,71	81,05 ± 8,00
Anéis	50/50	83,95 ± 1,41	81,39 ± 7,16	86,33 ± 7,40
	60/40	86,37 ± 3,19	87,53 ± 1,37	85,53 ± 5,09
	70/30	84,38 ± 5,69	83,39 ± 4,51	85,31 ± 8,91
	80/20	93,41 ± 2,76	92,83 ± 4,97	93,69 ± 2,80

utilizando o índice de Diversidade Total. Assim como a abordagem anterior também são geradas 120 características. Após a seleção, na decomposição espacial em círculos, resultaram 23 características. O melhor resultado obtido por essa abordagem foi com a proporção 50/50 alcançando uma média de acurácia de 83,07%, média de sensibilidade de 80,86% e média de especificidade de 84,85%. Na decomposição espacial em anéis, após a seleção, resultaram 20 características. O melhor resultado obtido por essa abordagem foi com a proporção 60/40 alcançando uma média de acurácia de 83,52%, média de sensibilidade de 82,12% e média de especificidade de 84,46%.

Tabela 7 – Resultados do índice de Diversidade Total com correção de iluminação *Retinex*.

Decomposição	Proporção (%)	Acurácia (%)	Sensibilidade (%)	Especificidade (%)
Círculos	50/50	83,07 ± 2,86	80,86 ± 2,35	84,85 ± 4,67
	60/40	81,76 ± 3,34	77,95 ± 12,08	84,83 ± 4,87
	70/30	81,61 ± 3,25	76,66 ± 10,08	85,24 ± 2,04
	80/20	82,64 ± 1,11	80,58 ± 10,27	84,92 ± 7,48
Anéis	50/50	82,81 ± 3,38	75,52 ± 5,94	89,07 ± 3,19
	60/40	83,52 ± 3,54	82,12 ± 9,46	84,46 ± 7,66
	70/30	82,92 ± 2,38	81,49 ± 3,59	84,02 ± 4,06
	80/20	81,98 ± 5,07	84,20 ± 5,17	80,78 ± 7,95

A Tabela 8 apresenta os resultados médios e os respectivos desvios-padrão obtidos utilizando os três índices de diversidade em conjunto. Ao todo são geradas 360 características (4 imagens (R, G, B, Escala de cinza) . 6 quantizações . 5 sub-regiões . 3 índices). Após a seleção, na decomposição espacial em círculos, resultaram 105 características. O melhor resultado obtido por essa abordagem foi com a proporção 80/20 alcançando uma média de acurácia de 92,31%, média de sensibilidade de 91,12% e média de especificidade de 93,92%. Na decomposição espacial em anéis, após a seleção, resultaram 98 características. O melhor resultado obtido por essa abordagem foi com a proporção 80/20 alcançando uma média de acurácia de 93,41%, média de sensibilidade de 92,36% e média de especificidade

de 95,05%.

Tabela 8 – Resultados combinando todos os índices com correção de iluminação *Retinex*.

Decomposição	Proporção (%)	Acurácia (%)	Sensibilidade (%)	Especificidade (%)
Círculos	50/50	86,61 ± 1,75	84,66 ± 2,86	89,99 ± 5,45
	60/40	89,34 ± 1,85	88,11 ± 3,27	91,26 ± 3,56
	70/30	89,12 ± 1,41	88,15 ± 4,04	90,95 ± 4,67
	80/20	92,31 ± 2,06	91,12 ± 3,20	93,92 ± 0,76
Anéis	50/50	86,96 ± 1,75	85,73 ± 3,02	88,86 ± 2,17
	60/40	90,55 ± 1,52	88,20 ± 2,44	94,00 ± 3,17
	70/30	90,88 ± 1,43	88,98 ± 3,76	93,57 ± 3,15
	80/20	93,41 ± 0,78	92,36 ± 1,37	95,05 ± 2,94

5.2 Experimentos utilizando filtro homomórfico

A seguir, são apresentados os resultados dos experimentos em que se utilizou filtro homomórfico para a correção de iluminação. Assim como na seção anterior, os experimentos foram realizados para cada índice de diversidade, individualmente e combinados.

A Tabela 9 apresenta os resultados médios e os respectivos desvios-padrão obtidos utilizando o índice de *Shannon*. Assim como na seção anterior também são geradas 120 características. Após a seleção, na decomposição espacial em círculos, resultaram 22 características. O melhor resultado obtido por essa abordagem foi com a proporção 50/50 alcançando uma média de acurácia de 83,51%, média de sensibilidade de 82,48% e média de especificidade de 84,30%. Na decomposição espacial em anéis, após a seleção, resultaram 20 características. O melhor resultado obtido por essa abordagem foi com a proporção 70/30 alcançando uma média de acurácia de 85,11%, média de sensibilidade de 84,70% e média de especificidade de 85,22%.

Tabela 9 – Resultados do índice de *Shannon* com correção de iluminação filtro homomórfico.

Decomposição	Proporção (%)	Acurácia (%)	Sensibilidade (%)	Especificidade (%)
Círculos	50/50	83,51 ± 2,12	82,48 ± 6,88	84,30 ± 3,50
	60/40	81,87 ± 4,50	83,03 ± 8,68	80,77 ± 2,17
	70/30	82,92 ± 5,52	80,10 ± 7,77	85,01 ± 6,31
	80/20	79,56 ± 4,54	77,19 ± 6,80	81,38 ± 6,67
Anéis	50/50	82,37 ± 3,00	85,79 ± 4,62	79,82 ± 2,56
	60/40	80,77 ± 1,44	77,71 ± 7,25	83,52 ± 6,11
	70/30	85,11 ± 2,40	84,70 ± 6,67	85,22 ± 3,72
	80/20	83,96 ± 2,38	82,14 ± 4,54	85,58 ± 4,27

A Tabela 10 apresenta os resultados médios e os respectivos desvios-padrão obtidos utilizando o índice de *McIntosh*. Assim como a abordagem anterior também

são geradas 120 características. Após a seleção, na decomposição espacial em círculos, resultaram 25 características. O melhor resultado obtido por essa abordagem foi com a proporção 70/30 alcançando uma média de acurácia de 85,11%, média de sensibilidade de 85,30% e média de especificidade de 84,81%. Na decomposição espacial em anéis, após a seleção, resultaram 27 características. O melhor resultado obtido por essa abordagem foi com a proporção 80/20 alcançando uma média de acurácia de 85,49%, média de sensibilidade de 80,40% e média de especificidade de 89,91%.

Tabela 10 – Resultados do índice de *McIntosh* com correção de iluminação filtro homomórfico.

Decomposição	Proporção (%)	Acurácia (%)	Sensibilidade (%)	Especificidade (%)
Círculos	50/50	83,42 ± 2,18	82,11 ± 5,14	84,55 ± 3,96
	60/40	80,55 ± 2,84	81,13 ± 3,28	79,88 ± 3,64
	70/30	85,11 ± 3,72	85,30 ± 4,12	84,81 ± 10,02
	80/20	83,96 ± 5,75	81,86 ± 5,59	85,50 ± 10,15
Anéis	50/50	83,25 ± 4,72	82,30 ± 5,28	84,07 ± 4,92
	60/40	82,97 ± 2,69	81,23 ± 3,77	84,49 ± 5,32
	70/30	83,94 ± 2,54	83,82 ± 3,89	84,03 ± 2,31
	80/20	85,49 ± 5,99	80,40 ± 9,85	89,91 ± 6,49

A Tabela 11 apresenta os resultados médios e os respectivos desvios-padrão obtidos utilizando o índice de Diversidade Total. Assim como a abordagem anterior também são geradas 120 características. Após a seleção, na decomposição espacial em círculos, resultaram 13 características. O melhor resultado obtido por essa abordagem foi com a proporção 80/20 alcançando uma média de acurácia de 85,49%, média de sensibilidade de 83,43% e média de especificidade de 87,08%. Na decomposição espacial em anéis, após a seleção, resultaram 16 características. O melhor resultado obtido por essa abordagem foi com a proporção 60/40 alcançando uma média de acurácia de 82,31%, média de sensibilidade de 77,55% e média de especificidade de 85,88%.

Tabela 11 – Resultados do índice de Diversidade Total com correção de iluminação filtro homomórfico.

Decomposição	Proporção (%)	Acurácia (%)	Sensibilidade (%)	Especificidade (%)
Círculos	50/50	82,19 ± 1,44	77,11 ± 7,43	85,92 ± 2,78
	60/40	84,51 ± 3,10	82,89 ± 4,98	85,71 ± 5,06
	70/30	83,65 ± 2,01	81,46 ± 4,07	85,54 ± 4,19
	80/20	85,49 ± 3,33	83,43 ± 4,02	87,08 ± 5,28
Anéis	50/50	81,32 ± 4,15	78,56 ± 7,26	83,44 ± 3,32
	60/40	82,31 ± 5,34	77,55 ± 7,28	85,88 ± 8,50
	70/30	81,17 ± 1,61	79,37 ± 5,63	82,68 ± 3,83
	80/20	81,98 ± 9,02	82,83 ± 4,35	81,38 ± 12,90

A Tabela 12 apresenta os resultados médios e os respectivos desvios-padrão

obtidos utilizando os três índices de diversidade em conjunto. Assim como na seção anterior são geradas 360 características. Após a seleção, na decomposição espacial em círculos, resultaram 112 características. O melhor resultado obtido por essa abordagem foi com a proporção 80/20 alcançando uma média de acurácia de 90,57%, média de sensibilidade de 87,96% e média de especificidade de 94,13%. Na decomposição espacial em anéis, após a seleção, resultaram 124 características. O melhor resultado obtido por essa abordagem foi com a proporção 80/20 alcançando uma média de acurácia de 92,75%, média de sensibilidade de 90,25% e média de especificidade de 94,32%.

Tabela 12 – Resultado combinando todos os índices com correção de iluminação filtro homomórfico.

Decomposição	Proporção (%)	Acurácia (%)	Sensibilidade (%)	Especificidade (%)
Círculos	50/50	87,93 ± 2,73	86,18 ± 4,56	91,06 ± 3,92
	60/40	89,78 ± 1,48	86,81 ± 3,10	94,32 ± 2,82
	70/30	88,82 ± 2,52	86,48 ± 4,79	92,27 ± 2,26
	80/20	90,57 ± 1,66	87,96 ± 2,88	94,13 ± 0,99
Anéis	50/50	88,28 ± 1,41	87,54 ± 3,81	89,82 ± 4,08
	60/40	88,57 ± 2,89	86,50 ± 3,32	91,78 ± 4,41
	70/30	90,15 ± 2,12	88,45 ± 2,63	92,54 ± 2,06
	80/20	92,75 ± 2,28	90,25 ± 3,86	96,32 ± 1,18

5.3 Alterando o tamanho da região de análise

Para verificar a robustez da metodologia em relação a erros de segmentação ou marcação da região do DO, realizou-se experimentos alterando o tamanho da região de análise. Foram realizados testes aumentando e diminuindo o tamanho da região de análise em 10% e 20%. Os testes foram realizados para a configuração que utiliza o *Retinex* para correção de iluminação, decomposição espacial em anéis e todos os índices de diversidade em conjunto, apresentada na Tabela 8 da Seção 5.1. Essa configuração foi escolhida pois foi a que apresentou os melhores resultados entre todos os experimentos. A Tabela 13 apresenta novamente o resultado desse experimento. Como mostrado nas seções anteriores essa configuração gera um total de 360 características.

Tabela 13 – Resultados do melhor experimento.

Proporção (%)	Acurácia (%)	Sensibilidade (%)	Especificidade (%)
50/50	86,96 ± 1,75	85,73 ± 3,02	88,86 ± 2,17
60/40	90,55 ± 1,52	88,20 ± 2,44	94,00 ± 3,17
70/30	90,88 ± 1,43	88,98 ± 3,76	93,57 ± 3,15
80/20	93,41 ± 0,78	92,36 ± 1,37	95,05 ± 2,94

A Tabela 14 apresenta os resultados médios e os respectivos desvios-padrão obtidos quando o tamanho da região de análise é aumentado 10%. Após a seleção, resultaram 117 características. O melhor resultado obtido por essa abordagem foi com a proporção 80/20 alcançando uma média de acurácia de 91,87%, média de sensibilidade de 90,06% e média de especificidade de 94,33%.

Tabela 14 – Resultados do melhor experimento com aumento do tamanho da região de análise em 10%.

Proporção (%)	Acurácia (%)	Sensibilidade (%)	Especificidade (%)
50/50	87,67 ± 1,49	86,90 ± 2,85	89,22 ± 4,88
60/40	90,22 ± 0,90	87,93 ± 3,40	93,82 ± 3,80
70/30	89,41 ± 1,85	87,96 ± 4,35	91,58 ± 2,79
80/20	91,87 ± 2,00	90,06 ± 2,94	94,33 ± 5,07

A Tabela 15 apresenta os resultados médios e os respectivos desvios-padrão obtidos quando o tamanho da região de análise é aumentado 20%. Após a seleção, resultaram 121 características. O melhor resultado obtido por essa abordagem foi com a proporção 80/20 alcançando uma média de acurácia de 92,97%, média de sensibilidade de 92,45% e média de especificidade de 93,64%.

Tabela 15 – Resultados do melhor experimento com aumento do tamanho da região de análise em 20%.

Proporção (%)	Acurácia (%)	Sensibilidade (%)	Especificidade (%)
50/50	88,19 ± 0,65	87,55 ± 2,54	89,33 ± 2,65
60/40	89,78 ± 1,53	88,09 ± 2,79	92,38 ± 4,85
70/30	92,06 ± 0,62	91,30 ± 1,93	93,28 ± 3,33
80/20	92,97 ± 0,98	92,45 ± 3,72	93,64 ± 2,74

A Tabela 16 apresenta os resultados médios e os respectivos desvios-padrão obtidos quando o tamanho da região de análise é diminuído 10%. Após a seleção, resultaram 109 características. O melhor resultado obtido por essa abordagem foi com a proporção 80/20 alcançando uma média de acurácia de 92,53%, média de sensibilidade de 92,99% e média de especificidade de 91,70%.

Tabela 16 – Resultados do melhor experimento com diminuição do tamanho da região de análise em 10%.

Proporção (%)	Acurácia (%)	Sensibilidade (%)	Especificidade (%)
50/50	88,55 ± 2,75	88,26 ± 3,20	89,17 ± 4,68
60/40	89,89 ± 1,85	87,98 ± 3,70	92,83 ± 3,98
70/30	90,59 ± 1,68	89,58 ± 3,74	92,14 ± 3,85
80/20	92,53 ± 2,62	92,99 ± 2,44	91,70 ± 4,69

A Tabela 17 apresentaram os resultados médios e os respectivos desvios-padrão obtidos quando o tamanho da região de análise é diminuído 20%. Após a seleção, resultaram

73 características. O melhor resultado obtido por essa abordagem foi com a proporção 80/20 alcançando uma média de acurácia de 91,43%, média de sensibilidade de 90,61% e média de especificidade de 92,41%.

Tabela 17 – Resultados do melhor experimento com diminuição do tamanho da região de análise em 20%.

Proporção (%)	Acurácia (%)	Sensibilidade (%)	Especificidade (%)
50/50	87,05 ± 1,91	87,38 ± 2,37	86,90 ± 4,14
60/40	89,89 ± 1,48	88,15 ± 2,75	92,46 ± 3,54
70/30	90,74 ± 1,77	89,45 ± 2,88	92,69 ± 3,81
80/20	91,43 ± 2,25	90,61 ± 2,69	92,41 ± 4,28

5.4 Discussão

Analisando todos os resultados gerados nos experimentos foi possível observar que, o algoritmo *Retinex* obteve um desempenho melhor que o filtro homomórfico para realizar a correção de iluminação, tanto utilizando os índices isoladamente como em conjunto. Nos experimentos onde foram testados os índices individualmente é possível observar que, utilizando o filtro homomórfico, os três índices possuem desempenho parecido, apresentando como melhores resultados uma acurácia próxima a 85%. Já quando foi utilizado o algoritmo *Retinex*, o índice de *McIntosh* apresenta uma acurácia de 93,41% (Tabela 6), mostrando um desempenho melhor que os índices de *Shannon* e *Diversidade Total*. Também foi possível observar que o uso dos índices de diversidade individualmente gera desvios-padrão altos.

Uma das razões para a eficiência da metodologia é a localização das intensidades (espécies) dos *pixels* (indivíduos) em relação às sub-regiões nas quais o DO foi dividido. A diversidade de cada sub-região entre imagens saudáveis e glaucomatosas muda pois, em imagens glaucomatosas a escavação ocupa uma região maior do DO, o anel neuroretinal fica mais estreito e a região peripapilar apresenta atrofia. Verificando todos os experimentos é possível observar que a decomposição espacial em anéis de maneira geral apresentou taxas de acerto maiores que a decomposição espacial em círculos. Acredita-se que isso aconteça pois na decomposição em anéis a análise da textura foi feita em sub-regiões do DO sem intersecção entre si, onde foi possível analisar essas sub-regiões de maneira isolada. Já na decomposição em círculos algumas das sub-regiões geradas possuem partes pertencentes às sub-regiões de raios menores. Os círculos maiores contém os círculos menores, pois são concêntricos.

Os experimentos utilizando todos os índices em conjunto (Tabelas 8 e 12) apresentaram os melhores resultados independente da técnica de correção de iluminação e decomposição espacial, alcançando uma acurácia média acima de 90% para os melhores resultados de cada experimento. Também é possível observar que os desvios-padrão diminuíram em relação ao uso dos índices individualmente, mostrando uma menor variação nos resultados obtidos entre as proporções de treinamento/teste utilizadas. Os valores dos desvios-padrão se mantiveram, em média, inferiores a 3%. As taxas de sensibilidade e especificidade foram melhoradas consideravelmente, assim a metodologia possui a capacidade de acertar tanto indivíduos glaucomatosos como saudáveis. Acredita-se que quando utilizados em conjunto, um índice pode recuperar informações da textura que outro não possa, por isso os melhores resultados que o uso dos índices separadamente.

A Tabela 8 apresenta o melhor resultado da metodologia, o qual foi obtido utilizando-se todos os índices em conjunto, a técnica de correção de iluminação *Retinex* e a decomposição espacial em anéis. Utilizando essa configuração foi possível alcançar uma acurácia média de 93,41%, sensibilidade média de 92,36% e uma especificidade média de 95,05%.

As Tabelas 14, 15, 16 e 17 apresentam os resultados dos experimentos onde foi alterado o tamanho da região de análise, para verificar a robustez da metodologia em relação a erros de segmentação ou marcação da região do DO. Analisando os resultados é possível observar que as médias de acurácia, sensibilidade e especificidade variam no máximo em torno de 3%, para todas as proporções, em relação ao experimento sem mudança no tamanho da região de análise e os desvios-padrão se mantêm baixos. Assim, é possível afirmar que mesmo com variações no tamanho da região de análise a metodologia consegue identificar quais imagens são glaucomatosas.

No geral os experimentos apresentaram valores de especificidades um pouco maiores que os de sensibilidade indicando um acerto maior de casos de imagens saudáveis. Esse comportamento pode ser explicado pelo fato da classe *Glaucoma and suspicious* possuir imagens suspeitas de glaucoma que são semelhantes as imagens da classe *Normal*.

Os resultados apresentados pela metodologia mostram que os índices de diversidade produzem boas taxas de acerto para classificação de imagens de fundo de olho em glaucomatosas e saudáveis.

5.5 Comparação da metodologia com outros trabalhos

Nesta seção, a metodologia proposta será comparada aos trabalhos relacionados apresentados no Capítulo 2. A comparação com outros trabalhos é uma tarefa difícil, pois muitos dos trabalhos utilizam bases de imagens privadas que não foram disponibilizadas, e assim propiciar realizar uma comparação mais rigorosa. Entretanto, é possível elaborar alguns comentários em relação a esses trabalhos. A Tabela 18 apresenta um resumo da comparação entre os resultados encontrados neste trabalho e os trabalhos relacionados fornecendo informações da base, quantidade de imagens e as métricas de desempenho de acurácia (AC), sensibilidade (SEN) e especificidade (ESP) utilizados.

Tabela 18 – Comparação da metodologia com os trabalhos relacionados.

Trabalho	Técnica	Base	Amostra	AC (%)	SEN (%)	ESP (%)
Acharya et al. (2011)	HOS	Privada	60	91,7	—	—
	GLCM					
	GLDM					
Dua et al. (2012)	<i>Wavelet</i>	Privada	60	93	—	—
Mookiah et al. (2012)	<i>Radon</i>	Privada	60	95	93,33	96,67
	HOS					
	<i>Wavelet</i>					
Mookiah e Faust (2013)	<i>Radon</i>	Privada	60	91,67	90	93,33
	HOS					
	<i>Wavelet</i>					
	<i>Trace</i>					
Noronha et al. (2014)	HOS	Privada	272	92,65	100	92
	<i>Radon</i>					
Acharya et al. (2014)	<i>Gabor</i>	Privada	510	93,1	89,75	96,2
Ali et al. (2014)	LBP	Privada	48	95,1	96,4	92,3
	LBPM					
	LBPC					
Maheshwari et al. (2017)	VMD	Privada	488	95,19	93,62	96,71
Acharya et al. (2017)	LCP	Privada	702	95,73	96,24	93,71
Maheshwari, Pachori e Acharya (2017)	<i>Wavelet</i>	Privada	60	98,33	100	96,67
Gajbhiye e Kamthane (2015)	HOM	RIM-ONE	350	86,57	—	—
	<i>Wavelet</i>					
Haleem et al. (2015)	<i>Wavelet</i>	RIM-ONE	158	92,95	—	—
Maheshwari, Pachori e Acharya (2017)	<i>Wavelet</i>	RIM ONE	455	81,32	77,01	84,31
Maheshwari et al. (2017)	VMD	RIM ONE	455	81,63	—	—
Sousa et al. (2017)	Geostatística	RIM-ONE	455	91	95	88
Metodologia Proposta	Índices de Diversidade	RIM-ONE	455	93,41	92,36	95,05

Em relação aos trabalhos que utilizam somente a base RIM-ONE, é possível observar que a metodologia proposta apresenta resultados superiores a todos os trabalhos. Além de um maior equilíbrio entre as métricas avaliadas, a metodologia proposta mostra uma melhor capacidade de identificar tanto indivíduos saudáveis como glaucomatosos.

Entre os trabalhos que utilizam somente bases privadas, alguns obtiveram taxas de acerto maiores que a metodologia proposta. Os trabalhos de Mookiah et al. (2012) e Ali et al. (2014) apresentam resultados superiores porém utilizam um número de amostras de 7 e 9 vezes menor, respectivamente, que o da metodologia proposta. Comparando com

o trabalho de Acharya et al. (2014) é possível observar que a metodologia apresenta um maior equilíbrio entre as métricas de avaliação.

Os trabalhos de Maheshwari, Pachori e Acharya (2017) e Maheshwari et al. (2017) realizam testes tanto em bases privadas como na base RIM-ONE. Observando os resultados desses trabalhos, para a base RIM-ONE é possível verificar que a metodologia proposta apresenta resultados superior aos dois trabalhos. Ao analisar os resultados na base privada a metodologia proposta é inferior aos dois. Porém, o trabalho de Maheshwari, Pachori e Acharya (2017) utiliza um número 7 vezes menor de imagens.

A metodologia proposta apresenta resultados inferiores, porém bem próximos, aos do trabalho de Acharya et al. (2017) e Maheshwari et al. (2017) quando esses utilizam bases privadas. Porém, é importante notar que os trabalhos do seu grupo de pesquisa quando utilizam a base RIM-ONE apresentam resultados inferiores ao do estudo proposto.

Em resumo, é possível observar que o resultado alcançado pela metodologia proposta foi superior ou próximo aos resultados dos trabalhos relacionados.

6 CONCLUSÃO

O glaucoma é a segunda maior causa de cegueira no mundo. É uma doença que não apresenta sintomas nos estágios iniciais e seus danos são irreversíveis. Por isso, é importante o desenvolvimento de métodos que auxiliem na identificação da doença, de maneira precoce, evitando assim perda de visão e a cegueira. Esses métodos são utilizados para o desenvolvimento de sistemas CADx que auxiliem especialistas na tarefa de analisar as imagens de fundo de olho e diagnosticar o glaucoma.

Nesta dissertação foi proposta uma metodologia, robusta a erros de segmentação do DO, para o diagnóstico de glaucoma em imagens de fundo de olho utilizando índices de diversidade para a extração de características da textura, técnicas de processamento de imagens e reconhecimento de padrões.

Foram apresentados os índices de diversidade (*Shannon*, *McIntosh* e *Diversidade Total*) que são comumente utilizados na ecologia para medir diversidade de espécies de uma comunidade. Nesse trabalho esses índices são utilizados como descritores de textura e são aplicados para caracterizar a textura da região do DO. Após a extração de características, foi realizada a seleção dos atributos mais relevantes com algoritmo genético e, por fim, a classificação com MVS. O melhor resultado foi obtido combinando características de todos os índices de diversidade, onde foram alcançadas média de acurácia de 93,41%, média de sensibilidade de 92,36% e média de especificidade de 95,05%.

Os resultados obtidos pela metodologia proposta são promissores, sendo compatíveis aos apresentados na revisão de literatura, e comprovam que os índices de diversidade podem ser utilizados para caracterizar a textura da região do DO em imagens de fundo de olho, mesmo com alterações no tamanho da região de análise, mostrando robustez em relação a erros de segmentação do DO. Assim, a metodologia descrita poderá ser utilizada no desenvolvimento de uma ferramenta CADx para o diagnóstico do glaucoma.

Mesmo apresentando resultados satisfatórios para o diagnóstico do glaucoma algumas tarefas podem ser realizadas para aumentar a eficiência da metodologia. A seguir algumas sugestões para trabalhos futuros são listadas:

- Testar a metodologia proposta em outras bases de imagens de fundo de olho;
- Analisar, implementar e testar o uso de outros índices de diversidade;

- Realizar testes com outras técnicas de reconhecimento de padrões;
- Pesquisar e testar outras técnicas de correção de iluminação, melhoramento de contraste e redução de ruído;
- Pesquisar e testar formas de representação da imagem, como o LBP.

6.1 Produções científicas

A Tabela 19 lista os artigos científicos publicados e submetidos que possuem relação com a metodologia proposta neste trabalho. Todos os trabalhos foram produzidos como autor principal.

Tabela 19 – Artigos publicados e submetidos que possuem relação com a metodologia proposta.

Tipo	Artigo	Status
Congresso	Araújo, J.D.L., Paiva, A. C., Almeida, J. D. S., Silva Neto, O. P., Sousa, J. A., Silva, A. C., Braz Junior, G. (2017). Diagnóstico de Glaucoma em Imagens de Fundo de Olho utilizando os Índices de Diversidade de Shannon e McIntosh. In WIM-XVII Workshop de Informática Médica (pp. 1873-1882).	Publicado
Periódico	Araújo, J.D.L., Souza, J. C, Silva Neto, O. P., Sousa, J. A., Almeida, J. D. S., Paiva, A. C., Silva, A. C., Braz Junior, G., Gattass M. (2017). Glaucoma diagnosis in fundus eye images using diversity indexes. In Multimedia Tools and Applications.	Submetido

REFERÊNCIAS

- ABRAMOFF, M. D.; GARVIN, M. K.; SONKA, M. Retinal imaging and image analysis. **IEEE Reviews in Biomedical Engineering**, v. 3, p. 169–208, 2010. ISSN 1937-3333.
- ACHARYA, U. R.; BHAT, S.; KOH, J. E.; BHANDARY, S. V.; ADELI, H. A novel algorithm to detect glaucoma risk using texton and local configuration pattern features extracted from fundus images. **Computers in Biology and Medicine**, v. 88, n. Supplement C, p. 72 – 83, 2017. ISSN 0010-4825. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0010482517302226>>.
- ACHARYA, U. R.; DUA, S.; DU, X.; S, V. S.; CHUA, C. K. Automated diagnosis of glaucoma using texture and higher order spectra features. **IEEE Transactions on Information Technology in Biomedicine**, v. 15, n. 3, p. 449–455, May 2011. ISSN 1089-7771.
- ACHARYA, U. R.; NG, E. Y. K.; EUGENE, L. W. J.; NORONHA, K. P.; MIN, L. C.; NAYAK, K. P.; BHANDARY, S. V. Decision support system for the glaucoma using Gabor transformation. **Biomedical Signal Processing and Control**, v. 15, p. 18–26, 2014. ISSN 17468108.
- ALI, M. A.; HURTUT, T.; FAUCON, T.; CHERIET, F. Glaucoma Detection based on Local Binary Patterns in Fundus Photographs. In: **SPIE Medical Imaging**. United States: [s.n.], 2014. p. 903531–903531–7. Disponível em: <<https://hal.archives-ouvertes.fr/hal-00993552>>.
- ALMAZROA, A.; BURMAN, R.; RAAHEMIFAR, K.; LAKSHMINARAYANAN, V. Optic disc and optic cup segmentation methodologies for glaucoma image detection: a survey. **Journal of ophthalmology**, Hindawi Publishing Corporation, v. 2015, 2015.
- BANIĆ, N.; LONČARIĆ, S. Light random sprays retinex: Exploiting the noisy illumination estimation. **IEEE Signal Processing Letters**, v. 20, n. 12, p. 1240–1243, Dec 2013. ISSN 1070-9908.
- BLAND, M. **An introduction to medical statistics**. [S.l.]: Oxford University Press (UK), 2015.
- BOCK, R.; MEIER, J.; NYÚL, L. G.; HORNEGGER, J.; MICHELSON, G. Glaucoma risk index: automated glaucoma detection from color fundus images. **Medical Image Analysis**, v. 14, n. 3, p. 471 – 481, 2010. ISSN 1361-8415. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1361841509001509>>.
- BRAZ, G. J. **Detecção de regiões de massas em mamografias usando índices de diversidade, geoestatística e geometria côncava**. Tese (Doutorado) — Universidade Federal do Maranhão, Programa de Pós-Graduação em Engenharia de Eletricidade. São Luis - MA, 2014.
- BURGISS, S. G.; GOODRIDGE, S. G. Multiframe averaging and homomorphic filtering for clarification of dark and shadowed video scenes. In: INTERNATIONAL SOCIETY FOR OPTICS AND PHOTONICS. **Enabling Technologies for Law Enforcement and Security**. [S.l.], 2001. v. 4232, p. 480–489.

CARVALHO, É. G. d. **Desenvolvimento de um sistema óptico para retinografia e angiografia digital**. Tese (Doutorado) — Instituto de Física de São Carlos, Universidade de São Paulo, 2006.

CASSON, R. J.; CHIDLOW, G.; WOOD, J. P.; CROWSTON, J. G.; GOLDBERG, I. Definition of glaucoma: clinical and experimental concepts. **Clinical e Experimental Ophthalmology**, Blackwell Publishing Asia, v. 40, n. 4, p. 341–349, 2012. ISSN 1442-9071. Disponível em: <<http://dx.doi.org/10.1111/j.1442-9071.2012.02773.x>>.

CHANG, C.-C.; LIN, C.-J. Libsvm: A library for support vector machines. **ACM Trans. Intell. Syst. Technol.**, ACM, New York, NY, USA, v. 2, n. 3, p. 27:1–27:27, maio 2011. ISSN 2157-6904. Disponível em: <<http://doi.acm.org/10.1145/1961189.1961199>>.

CHENG, J.; LIU, J.; XU, Y.; YIN, F.; WONG, D. W. K.; TAN, N.-M.; TAO, D.; CHENG, C.-Y.; AUNG, T.; WONG, T. Y. Superpixel classification based optic disc and optic cup segmentation for glaucoma screening. **IEEE Transactions on Medical Imaging**, IEEE, v. 32, n. 6, p. 1019–1032, 2013.

CONCI, A.; AZEVEDO, E.; LETA, F. R. **Computação gráfica**. [S.l.]: Elsevier, 2008.

DUA, S.; ACHARYA, U. R.; CHOWRIAPPA, P.; SREE, S. V. Wavelet-based energy features for glaucomatous image classification. **IEEE Transactions on Information Technology in Biomedicine**, v. 16, n. 1, p. 80–87, Jan 2012. ISSN 1089-7771.

DUDA; HART. **Pattern classification and scene analysis**. [S.l.]: John Wiley., 1973.

GAJBHIYE, G. O.; KAMTHANE, A. N. Automatic classification of glaucomatous images using wavelet and moment feature. In: **2015 Annual IEEE India Conference (INDICON)**. [S.l.: s.n.], 2015. p. 1–5.

GOLDBERG, D. E. Genetic algorithms in search, optimization, and machine learning, 1989. **Reading: Addison-Wesley**, 1989.

GOMES, D. L. J. **Metodologia para construção de aplicações de rv e ra com marcadores naturais em cenários industriais**. Tese (Doutorado) — Universidade Federal do Maranhão, Programa de Pós-Graduação em Engenharia de Eletricidade. São Luis - MA, 2017.

GONZALEZ, R. C.; WOODS, R. C. **Processamento digital de imagens**. [S.l.]: Pearson Prentice Hall, 2010.

GRF. **Glaucoma Research Foundation**. 2017. [Online]. Último acesso em 07 de outubro de 2017. Disponível em: <https://www.glaucoma.org/GRF_Understanding_Glaucoma_EN.pdf>.

HALEEM, M. S.; HAN, L.; HEMERT, J. van; LI, B. Automatic extraction of retinal features from colour retinal images for glaucoma diagnosis: A review. **Computerized Medical Imaging and Graphics**, v. 37, n. 7–8, p. 581 – 596, 2013. ISSN 0895-6111. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0895611113001468>>.

HALEEM, M. S.; HAN, L.; HEMERT, J. van; FLEMING, A. Glaucoma classification using regional wavelet features of the onh and its surroundings. In: **IEEE. Engineering in Medicine and Biology Society (EMBC), 2015 37th Annual International Conference of the IEEE**. [S.l.], 2015. p. 4318–4321.

ISSAC, A.; SARATHI, M. P.; DUTTA, M. K. An adaptive threshold based image processing technique for improved glaucoma detection and classification. **Computer Methods and Programs in Biomedicine**, v. 122, n. 2, p. 229 – 244, 2015. ISSN 0169-2607. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0169260715001996>>.

KANAN, C.; COTTRELL, G. W. Color-to-grayscale: Does the method matter in image recognition? **PLOS ONE**, Public Library of Science, v. 7, n. 1, p. 1–7, 01 2012. Disponível em: <<https://doi.org/10.1371/journal.pone.0029740>>.

LAND, E. H.; MCCANN, J. J. Lightness and retinex theory. **J. Opt. Soc. Am.**, OSA, v. 61, n. 1, p. 1–11, Jan 1971. Disponível em: <<http://www.osapublishing.org/abstract.cfm?URI=josa-61-1-1>>.

LIN, S. C.; SINGH, K.; JAMPEL, H. D.; HODAPP, E. A.; SMITH, S. D.; FRANCIS, B. A.; DUEKER, D. K.; FECHTNER, R. D.; SAMPLES, J. S.; SCHUMAN, J. S. et al. Optic nerve head and retinal nerve fiber layer analysis: a report by the american academy of ophthalmology. **Ophthalmology**, Elsevier, v. 114, n. 10, p. 1937–1949, 2007.

MAHESHWARI, S.; PACHORI, R. B.; ACHARYA, U. R. Automated diagnosis of glaucoma using empirical wavelet transform and correntropy features extracted from fundus images. **IEEE Journal of Biomedical and Health Informatics**, v. 21, n. 3, p. 803–813, May 2017. ISSN 2168-2194.

MAHESHWARI, S.; PACHORI, R. B.; KANHANGAD, V.; BHANDARY, S. V.; ACHARYA, U. R. Iterative variational mode decomposition based automated detection of glaucoma using fundus images. **Computers in Biology and Medicine**, v. 88, p. 142 – 149, 2017. ISSN 0010-4825. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0010482517301816>>.

MARRUGAN, A. Measuring biological diversity. **Victoria, Australia: Blackwell Scienc Ltd a Blackwell Publishing company**, 2004.

MARY, M. C. V. S.; RAJSINGH, E. B.; NAIK, G. R. Retinal fundus image analysis for diagnosis of glaucoma: A comprehensive survey. **IEEE Access**, v. 4, p. 4327–4354, 2016. ISSN 2169-3536.

MCINTOSH, R. P. An index of diversity and the relation of certain concepts to diversity. **Ecology**, Ecological Society of America, v. 48, n. 3, p. 392–404, 1967. ISSN 00129658, 19399170. Disponível em: <<http://www.jstor.org/stable/1932674>>.

MELO, A. S. O que ganhamos confundindo riqueza de espécies e equabilidade em um índice de diversidade. **Biota Neotropica**, SciELO Brasil, v. 8, n. 3, p. 21–27, 2008.

MELO, R. H. C. D.; VIEIRA, E. de A.; CONCI, A. A system to enhance details on partially shadowed images. In: **International workshop on systems, signals & image processing**. [S.l.: s.n.], 2004. p. 307–310.

MENEZES, A. M. d. A. R. **Fisiopatologia do glaucoma de ângulo fechado: novos mecanismos**. Tese (Doutorado) — Universidade do Porto, Mestrado Integrado em Medicina. Porto, 2012.

MOOKIAH, M. R. K.; ACHARYA, U. R.; LIM, C. M.; PETZNICK, A.; SURI, J. S. Data mining technique for automated diagnosis of glaucoma using higher order spectra and wavelet energy features. **Knowledge-Based Systems**, v. 33, p. 73 – 82, 2012. ISSN 0950-7051. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0950705112000500>>.

MOOKIAH, M. R. K.; FAUST, O. Automated glaucoma detection using hybrid feature extraction in retinal fundus images. **Journal of Mechanics in Medicine and Biology**, World Scientific, v. 13, n. 01, p. 1350011, 2013.

NORONHA, K. P.; ACHARYA, U. R.; NAYAK, K. P.; MARTIS, R. J.; BHANDARY, S. V. Automated classification of glaucoma stages using higher order cumulant features. **Biomedical Signal Processing and Control**, v. 10, p. 174 – 183, 2014. ISSN 1746-8094. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1746809413001699>>.

OH, J. E.; YANG, H. K.; KIM, K. G.; HWANG, J.-M. Automatic computer-aided diagnosis of retinal nerve fiber layer defects using fundus photographs in optic neuropathy. **Investigative Ophthalmology e Visual Science**, v. 56, n. 5, p. 2872, 2015. Disponível em: <[+http://dx.doi.org/10.1167/iovs.14-15096](http://dx.doi.org/10.1167/iovs.14-15096)>.

OPTICIAN. **C51251: Glaucoma management part 2 - Optic disc assessment in glaucoma**. 2016. [Online]. Último acesso em 10 novembro de 2017. Disponível em: <<https://www.opticianonline.net/cet-archive/118>>.

PEDRINI, H.; SCHWARTZ, W. R. **Análise de imagens digitais: princípios, algoritmos e aplicações**. [S.l.]: Thomson Learning, 2008.

PROVENZI, E.; FIERRO, M.; RIZZI, A.; CARLI, L. D.; GADIA, D.; MARINI, D. Random spray retinex: A new retinex implementation to investigate the local properties of the model. **IEEE Transactions on Image Processing**, v. 16, n. 1, p. 162–171, Jan 2007. ISSN 1057-7149.

RAJA, C.; GANGATHARAN, N. A hybrid swarm algorithm for optimizing glaucoma diagnosis. **Computers in Biology and Medicine**, v. 63, p. 196 – 207, 2015. ISSN 0010-4825. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S001048251500195X>>.

SBG. **Sociedade Brasileira de Galucoma**. 2016. [Online]. (Último acesso em 20 setembro de 2017). Disponível em: <https://www.sbglaucoma.com.br/wp-content/uploads/2016/05/folheto_glucoma1.pdf>.

SHANNON, C. E. W. weaver the mathematical theory of communication. **Urbana: University of Illinois Press**, v. 29, 1949.

SIEDLECKI, W.; SKLANSKY, J. A note on genetic algorithms for large-scale feature selection. **Pattern Recognition Letters**, v. 10, n. 5, p. 335 – 347, 1989. ISSN 0167-8655. Disponível em: <<http://www.sciencedirect.com/science/article/pii/0167865589900378>>.

SILVA, S. F. d. **Seleção de características por meio de algoritmos genéticos para aprimoramento de rankings e de modelos de classificação**. Tese (Doutorado) — Universidade de São Paulo, 2011.

SOUSA, J. A. de; PAIVA, A. C. de; ALMEIDA, J. D. Sousa de; SILVA, A. C.; JUNIOR, G. B.; GATTASS, M. Texture based on geostatistic for glaucoma diagnosis from fundus eye image. **Multimedia Tools and Applications**, v. 76, n. 18, p. 19173–19190, Sep 2017. ISSN 1573-7721. Disponível em: <<https://doi.org/10.1007/s11042-017-4608-y>>.

TGF. **The Glaucoma Foundation**. 2017. [Online]. Último acesso em 07 de outubro de 2017. Disponível em: <<https://www.glaucomafoundation.org/docs/PatientGuide.pdf>>.

THAM, Y.-C.; LI, X.; WONG, T. Y.; QUIGLEY, H. A.; AUNG, T.; CHENG, C.-Y. Global prevalence of glaucoma and projections of glaucoma burden through 2040: A systematic review and meta-analysis. **Ophthalmology**, v. 121, n. 11, p. 2081 – 2090, 2014. ISSN 0161-6420. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0161642014004333>>.

TRUCCO, E.; RUGGERI, A.; KARNOWSKI, T.; GIANCARDIO, L.; CHAUM, E.; HUBSCHMAN, J. P.; AL-DIRI, B.; CHEUNG, C. Y.; WONG, D.; ABRAMOFF, M. et al. Validating retinal fundus image analysis algorithms: Issues and a proposal validating retinal fundus image analysis algorithms. **Investigative ophthalmology & visual science**, The Association for Research in Vision and Ophthalmology, v. 54, n. 5, p. 3546–3559, 2013.

VAPNIK, V. **Statistical Learning Theory**. [S.l.]: Wiley New York, 1998.

VERAS, R. d. M. S. **Detecção e segmentação de estruturas em imagens médicas de retina**. Tese (Doutorado) — Programa de Pós-Graduação em Engenharia de Teleinformática, Universidade Federal do Ceará, 2014.

WGA. **World Glaucoma Association**. 2017. [Online]. Último acesso em 17 março de 2017. Disponível em: <<http://www.worldglaucoma.org/what-is-glaucoma/>>.

XIONG, L.; LI, H.; XU, L. An enhancement method for color retinal images based on image formation model. **Computer Methods and Programs in Biomedicine**, v. 143, n. Supplement C, p. 137 – 150, 2017. ISSN 0169-2607. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0169260716310811>>.

ZHANG, Z.; SRIVASTAVA, R.; LIU, H.; CHEN, X.; DUAN, L.; WONG, D. W. K.; KWONG, C. K.; WONG, T. Y.; LIU, J. A survey on computer aided diagnosis for ocular diseases. **BMC Medical Informatics and Decision Making**, v. 14, n. 1, p. 80, Aug 2014. ISSN 1472-6947. Disponível em: <<https://doi.org/10.1186/1472-6947-14-80>>.

ZHUANG, L.; DAI, H. Parameter optimization of kernel-based one-class classifier on imbalance learning. **Journal of Computers**, Citeseer, v. 1, n. 7, p. 32–40, 2006.