



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

Camila Costa Silva

***Diagnóstico de Glaucoma em Imagens de Fundo de Olho
Utilizando Estatística Espacial***

**São Luís
2018**

CAMILA COSTA SILVA

**Diagnóstico de Glaucoma em Imagens de Fundo de
Olho Utilizando Estatística Espacial**

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

Orientador: Prof. Dr. Anselmo Cardoso de Paiva

Coorientador: Prof. Dr. João Dallyson Sousa de Almeida

São Luís

2018

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

Silva, Camila Costa.

Diagnóstico de Glaucoma em Imagens de Fundo de Olho
Utilizando Estatística Espacial / Camila Costa Silva. -
2018.

82 f.

Coorientador(a): João Dallyson Sousa de Almeida.

Orientador(a): Anselmo Cardoso de Paiva.

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

1. Estatística Espacial. 2. Glaucoma. 3. Máquina de
Vetores de Suporte. 4. Retinografia. I. Almeida, João
Dallyson Sousa de. II. Paiva, Anselmo Cardoso de. III.
Título.

Dissertação de autoria de Camila Costa Silva, sob o título “**Diagnóstico de Glaucoma em Imagens de Fundo de Olho Utilizando Estatística Espacial**”, apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal do Maranhão, como requisito parcial para obtenção do título de Mestre em Ciência da Computação, aprovado em __ de __ de 2018 pela comissão examinadora constituída pelos doutores:

Prof. Dr. Anselmo Cardoso de Paiva
Orientador

Prof. Dr. João Dallyson Sousa de Almeida
Coorientador

Prof. Dr. Tiago Bonini Borchardt
Examinador Interno

Prof. Dr. Kelson Romulo Teixeira Aires
Examinador Externo

A Deus toda honra e toda glória.

Agradecimentos

A Deus em primeiro lugar.

Aos meus pais, irmãos e toda a família pela confiança, apoio e amor incondicionais.

Ao professor Anselmo, o melhor orientador que eu poderia ter, pela perseverança na orientação, conhecimentos, incentivo, carinho e todos os valiosos conselhos que levarei para toda vida, aos quais nunca serei capaz de agradecer apropriadamente.

Ao professor João Dallyson pelas dicas e orientação.

Aos amigos de laboratório Alex, Daniel, José Denes e Johnatan. E em especial gostaria de agradecer ao amigo Jefferson que acompanhou e me auxiliou incansavelmente durante toda pesquisa.

A todos os amigos do Núcleo de Computação Aplicada da UFMA.

A todos os professores que contribuíram sem medir esforços para a minha formação desde a graduação até o mestrado.

A todos que compõem a PPGCC-UFMA: professores, alunos e funcionários.

Aos colegas de trabalho da DIGTI/IFMA pelo apoio e compreensão.

Agradeço a todos que contribuíram direta ou indiretamente para a conclusão deste trabalho.

*”Não se amoldem ao padrão deste mundo,
mas transformem-se pela renovação da sua mente,
para que sejam capazes de experimentar e comprovar
a boa, agradável e perfeita vontade de Deus.”*

(Bíblia Sagrada, Romanos 12 - 2)

Resumo

O glaucoma é uma doença da retina considerada a segunda principal causa de cegueira no mundo, atingindo uma prevalência aproximada entre 1% e 2% da população, segundo dados da Organização Mundial de Saúde (OMS). É normalmente ocasionado pelo aumento da pressão do líquido no nervo óptico, levando a perda progressiva e irreversível da visão. O diagnóstico precoce do glaucoma é, portanto, fundamental para garantir um tratamento rápido e adequado, sendo capaz de minimizar o dano e evitar a perda da visão. Assim, o uso de sistemas computacionais de auxílio à detecção e diagnóstico (*Computer Aided Detection* - CAD e *Computer Aided Diagnosis* - CADx) para auxiliar o especialista tem aumentado as chances de diagnósticos corretos. Imagens fotográficas de fundo de olho (retinografias) são usadas como um valioso recurso em diagnósticos médicos, pois frequentemente apresentam indicações sobre doenças oculares como o glaucoma. Neste contexto, este trabalho apresenta uma metodologia baseada em processamento de imagem para diagnosticar o glaucoma a partir da análise de textura da imagem representada usando *Compound Local Binary Pattern* e estatística espacial aplicada em imagens médicas de retinografias. O método é aplicado sobre a região de interesse que representa o disco óptico, cuja segmentação baseia-se na marcação do especialista contida na base pública RIM-ONE. As amostras são pré-processadas através do método das cores oponentes seguida da equalização de histograma. O Índice de Moran e a função K de Ripley são utilizadas para descrever a textura da região do disco óptico. A Máquina de Vetores de Suporte é usada para realizar a classificação. O método apresentou resultados promissores, alcançando como melhor resultado uma acurácia de 95,08%, sensibilidade de 93,4% e especificidade de 96,4%, e demonstra um notável desempenho da metodologia proposta quando comparada aos métodos disponíveis na literatura para diagnóstico de glaucoma.

Palavras-chaves: Glaucoma, Retinografia, Máquina de Vetores de Suporte, Estatística Espacial.

Abstract

Glaucoma is a disease of the retina considered the second leading cause of blindness in the world reaching an approximate prevalence between 1% and 2% of the population, according to data from the World Health Organization (WHO). It is usually caused by increased fluid pressure in the optic nerve, leading to progressive and irreversible loss of vision. Early diagnosis of glaucoma is therefore critical to ensure a prompt and adequate treatment, being able to minimize damage and prevent loss of vision. Thus, the use of detection and diagnostic systems (CAD - Computer Aided Detection and CADx - Computer Aided Diagnosis) to assist the specialist has increased the chances of correct diagnoses. Photographs of fundus eye (retinographies) are used as a valuable resource in medical diagnoses, as they often present indications about eye diseases such as glaucoma. In this context, this work presents a methodology based on image processing to diagnose glaucoma from the image texture analysis represented using Compound Local Binary Pattern and spatial statistics applied in medical images of retinographies. The method is applied on the region of interest that represents the optical disk, whose segmentation is based on the gold standards in the RIM-ONE public base. Samples are preprocessed using the opponent colors method followed by histogram equalization. The Moran Index and Ripley's K function are used to describe the texture of the optical disc region. The Support Vector Machine is used to perform classification. The method presented promising results, reaching 95.08% accuracy, 93.4% sensitivity and 96.4% specificity as the best result, and it demonstrates a remarkable performance of the proposed methodology when compared to the methods available in the literature for diagnosis of glaucoma.

Keywords: Glaucoma, Retinography, Support Vector Machine, Spatial Statistics.

Lista de figuras

Figura 1 – A anatomia do olho mostrando as três camadas principais (retina, coróide e esclera), nervo óptico, disco óptico e outras características.	24
Figura 2 – Estruturas fisiológicas da retina.	26
Figura 3 – Sinais e sintomas do glaucoma. (a) Um campo visual normal. (b) O mesmo cenário com perda de visão avançada pelo glaucoma.	27
Figura 4 – Imagens de retina: (a) olho normal, (b) olho glaucomatoso.	28
Figura 5 – Exemplo de cálculo da relação entre a escavação e o disco óptico em uma imagem de retina.	29
Figura 6 – Exemplos de retinógrafos do mercado.	30
Figura 7 – Retinografias. (a) Retinografia Simples. (b) Angiografia Fluorescente Ocular.	30
Figura 8 – Etapas fundamentais do processamento de imagens digitais.	32
Figura 9 – Aplicação da equalização de histograma a imagem com baixo contraste. Imagem original (a) com seu histograma (b). Imagem equalizada (c) com seu histograma (d).	35
Figura 10 – Geração dos dois padrões sub-CLBP 10111010 e 11111010 a partir do código CLBP original 101111110101010.	38
Figura 11 – Funcionamento da Função K de Ripley.	42
Figura 12 – Separação entre duas classes através de hiperplanos.	47
Figura 13 – Vetores de Suporte (destacados por círculos).	49
Figura 14 – Etapas da metodologia proposta.	52
Figura 15 – Imagens de retina contidas na base RIM-ONE com marcação do disco óptico: (a) classe <i>normal</i> , (b) classe <i>glaucoma and glaucoma suspicious</i>	54
Figura 16 – Exemplo de ROI extraída da base RIM-ONE a partir da marcação feita por especialistas.	54
Figura 17 – Etapas do pré-processamento em cada canal de uma imagem glaucomatosa com seus respectivos histogramas: (a) canal <i>Red</i> , (b) canal <i>Green</i> , (c) canal <i>Blue</i>	56
Figura 18 – Resultado do pré-processamento na ROI.	57
Figura 19 – Resultado da aplicação do CLBP.	57

Figura 20 – Divisões retangulares aplicadas à região para preservar associações locais antes da aplicação de métodos para extração de características: (a) horizontal, (b) vertical, (c) janelas e em (d) janelas centralizadas.	58
Figura 21 – Representação da decomposição em diagonais.	59
Figura 22 – Representação da decomposição em círculos.	59
Figura 23 – Representação da decomposição em anéis.	60
Figura 24 – Fluxo de atividades da etapa de reconhecimento de padrões.	64

Lista de tabelas

Tabela 1 – Quantidade total de características extraídas por abordagem de decomposição.	62
Tabela 2 – Critério de divisão treino/teste utilizado na etapa de classificação. . . .	65
Tabela 3 – Resultados produzidos pela Função K de Ripley a partir de diferentes abordagens de decomposição espacial	68
Tabela 4 – Resultados produzidos pela Função K de Ripley a partir da abordagem de decomposição retangular com seleção de características	68
Tabela 5 – Resultados produzidos pelo Índice de Moran a partir de diferentes abordagens de decomposição espacial	70
Tabela 6 – Resultados produzidos pelo Índice de Moran a partir da abordagem de decomposição retangular com seleção de características	70
Tabela 7 – Resultados produzidos pela Função K de Ripley em conjunto com Índice de Moran a partir de diferentes abordagens de decomposição espacial .	71
Tabela 8 – Comparação dos trabalhos relacionados.	74

Lista de abreviaturas e siglas

AC	Acurácia
ANEL	Abordagem de decomposição espacial em anéis
CAD	<i>Computer-Aided Detection</i>
CADx	<i>Computer-Aided Diagnostic</i>
CDR	<i>Cup-to-Disc Ratio</i>
CIRC	Abordagem de decomposição espacial circular
CLBP	<i>Compound Local Binary Pattern</i>
DO	Disco Óptico
DWT	<i>Discrete Wavelet Transform</i>
EBPTA	<i>Error Back-Propagation Training Algorithm</i>
ESP	Especificidade
EWT	<i>Empirical Wavelet Transform</i>
FN	Falso Negativo
FP	Falso Positivo
GLCM	<i>Gray-Level Cooccurrence Matrix</i>
GLDM	<i>Gray Level Difference Matrix</i>
GSO	<i>Group Search Optimizer</i>
HOS	<i>Higher Order Spectra</i>
HVDJ	Abordagem de decomposição espacial retangular (horizontal, vertical, diagonal, janelas, janelas centralizadas)
HWT	<i>Hyper Analytic Wavelet Transformation</i>
KNN	<i>K-Nearest Neighbors</i>

LBP	<i>Local Binary Pattern</i>
LBPC	<i>Local Binary Pattern Center</i>
LBPM	<i>Local Binary Pattern Magnitude</i>
LCP	<i>Local Configuration Pattern</i>
LDA	<i>Linear Discriminant Analysis</i>
LM	<i>Leung-Malik</i>
LS-SVM	<i>Least Squares Support Vector Machine</i>
NB	<i>Naive Bayes</i>
PCA	<i>Principal Component Analysis</i>
PIO	Pressão Intra-Ocular
PSO	<i>Particle Swarm Optimization</i>
QDA	<i>Quadratic Discriminant Analysis</i>
RBF	<i>Radial Basis Function</i>
RGB	<i>Red, Green, Blue</i>
ROI	Região de Interesse
RT	<i>Radon Transform</i>
SEN	Sensibilidade
SFFS	<i>Sequential Floating Forward Search</i>
SVM	<i>Support Vector Machine</i>
VC	Vetor de Características
VMD	<i>Varitional Mode Decomposition</i>
VN	Verdadeiro Negativo
VP	Verdadeiro Positivo

Sumário

1	Introdução	15
1.1	Organização do Trabalho	17
2	Trabalhos Relacionados	18
3	Fundamentação Teórica	23
3.1	Anatomia do Olho	23
3.2	Glaucoma	25
3.3	Retinografia (Imagem de fundo de olho)	29
3.4	Processamento de Imagens Digitais	31
3.4.1	Modelos de Cores	33
3.4.2	Cores Oponentes	34
3.4.3	Equalização do Histograma	34
3.5	Análise de Textura	36
3.5.1	<i>Compound Local Binary Pattern (CLBP)</i>	37
3.5.2	Estatística Espacial	39
3.5.3	Função K de Ripley	41
3.5.4	Índice de Moran	42
3.6	Seleção de Características	43
3.6.1	Análise Discriminante Linear	44
3.7	Reconhecimento de Padrões	45
3.7.1	Máquina de Vetores de Suporte	47
3.8	Validação de Resultados	50
4	Materiais e Métodos	52
4.1	Base de Imagens	53
4.2	Extração da Região de Interesse	53
4.3	Pré-Processamento	54
4.4	Representação da Imagem	55
4.5	Extração de Características	55
4.5.1	Decomposição Espacial	57

4.5.2	Índices Geoestatísticos	61
4.6	Seleção de Características	63
4.7	Reconhecimento de Padrões	63
4.8	Validação	65
5	Resultados e Discussão	66
5.1	Resultados Obtidos	66
5.1.1	Função K de Ripley	67
5.1.2	Índice de Moran	69
5.1.3	Função K de Ripley em conjunto com Índice de Moran .	71
5.2	Discussão	71
5.3	Comparação com outros trabalhos	73
6	Conclusão	75
6.1	Trabalhos futuros	76
	Referências	78

1 Introdução

O glaucoma é uma doença ocular crônica causada pelo aumento da pressão do fluido no nervo óptico. Ele ocasiona danos de maneira progressiva, irreversível e, posteriormente, pode provocar a perda total da visão.

Segundo a Organização Mundial de Saúde (OMS), o glaucoma constitui a segunda maior causa de cegueira do mundo, com número de casos inferior apenas ao da catarata. A prevalência do glaucoma está aproximadamente entre 1% e 2% da população mundial (RESNIKOFF et al., 2004). Dado o envelhecimento populacional, estima-se que quase 80 milhões de pessoas serão portadoras da doença em 2020 (QUIGLEY; BROMAN, 2006). Tham et al. (2014) projetam que em 2040 esse número pode aumentar para 111,8 milhões. No Brasil existem cerca de 900.000 pessoas com glaucoma, conforme levantamento realizado pela Sociedade Brasileira de Glaucoma (SBG, 2017).

A pressão intra-ocular (PIO), acima de níveis considerados estatisticamente normais, é o mais importante fator de risco para o desenvolvimento e progressão do glaucoma. Entre os outros fatores de risco constam etnia negra, idade maior que 40 anos, histórico familiar e alto grau de miopia (SBG, 2017).

As pessoas que sofrem com o glaucoma muitas vezes desconhecem a progressão assintomática da doença até uma fase avançada de deterioração da visão, quando o tratamento é menos eficaz. Embora o glaucoma não possa ser curado, a sua progressão pode ser desacelerada. O diagnóstico da doença é tipicamente baseado no histórico médico, PIO e perda de campo visual, juntamente com uma avaliação manual do disco óptico, através de oftalmoscopia¹ (FUMERO et al., 2011).

O diagnóstico precoce do glaucoma é, portanto, fundamental para minimizar o dano e a perda da visão, e garantir um tratamento rápido e adequado (MARY; RAJSINGH; NAIK, 2016). As mudanças na aparência estrutural do disco óptico, que constantemente precedem o desenvolvimento de perda de campo visual no glaucoma, são observadas a partir de análises realizadas por médicos especialistas. Até agora, essa avaliação tem sido predominantemente subjetiva e obtida com alta variabilidade entre observadores (NAITHANI et al., 2007).

Entre os métodos disponíveis de varredura do disco óptico utilizados para diagnosticar o glaucoma estão a Tomografia Retiniana de Heidelberg (*Heidelberg Retina*

¹ Exame do fundo do olho realizado com o auxílio do oftalmoscópio. Também conhecido por fundoscopia.

Tomography - HTR), a Polarimetria de Varredura a Laser e a Tomografia de Coerência Óptica (*Optical Coherence Tomography* - OCT). Esses métodos são caros e requerem médicos experientes para usá-los. Uma alternativa para realizar a avaliação do disco óptico com precisão e baixo custo é através da fotografia de fundo de olho (Retinografia) (MAHESHWARI; PACHORI; ACHARYA, 2017).

Sistemas Computacionais de Auxílio a Detecção e Diagnóstico (CAD/CADx - *Computer-Aided Detection and Diagnosis*), que automatizam o processo de detecção e diagnóstico de doenças oftalmológicas, são cada vez mais importantes para dar suporte à análise de estruturas oculares, realizada por especialistas de maneira a auxiliá-los na detecção precoce de alterações patológicas.

A integração de sistemas automáticos de auxílio ao diagnóstico de doenças do sistema visual, através de imagens de retina, em programas de triagem, permite examinar de forma objetiva um elevado número de imagens, com o potencial para economias significativas de tempo e recursos financeiros, além de estar livre de viés e fadiga por parte do observador. Desta análise poderão ser identificados pacientes que, apesar de não apresentarem uma elevada expressão de sintomas, evidenciam alterações prematuras na retina. Desta forma, tais pacientes poderão ser encaminhados a um acompanhamento clínico especializado com uma garantia de tratamento mais eficiente (PATTON et al., 2006).

Assim, o objetivo geral deste trabalho é propor uma nova metodologia computacional para diagnóstico de glaucoma em imagens médicas fotográficas de fundo de olho (retinografias), baseada na análise de textura da região do disco óptico previamente segmentado.

Para alcançar o objetivo geral, destacam-se como objetivos específicos:

- estudar as estruturas do disco óptico;
- estudar a caracterização do glaucoma e as formas de diagnóstico;
- desenvolver técnicas de processamento de imagens para realce das regiões internas do disco óptico;
- desenvolver técnicas de representação de imagens para descrever a textura das imagens, aplicando funções geoestatísticas, tais como: função K de Ripley e Índice de Moran;
- investigar a aplicação de reconhecimento de padrões para classificação das imagens em saudáveis ou glaucomatosas.

1.1 Organização do Trabalho

Este trabalho foi organizado em seis capítulos, sendo o primeiro capítulo introdutório. No Capítulo 2 é exposto um levantamento de trabalhos relacionados que possam ser comparados com a metodologia proposta. O Capítulo 3 trata da fundamentação teórica na qual são mostrados conceitos e técnicas necessárias para o entendimento da metodologia desenvolvida. No Capítulo 4 é apresentada a descrição detalhada da metodologia proposta. Neste capítulo são mostradas todas as etapas realizadas até o diagnóstico de glaucoma. O Capítulo 5 apresenta os resultados e discussões de cada etapa da metodologia proposta. No Capítulo 6, por fim, expõem-se as conclusões sobre os resultados obtidos através da metodologia desenvolvida.

2 Trabalhos Relacionados

A literatura mostra que a eficiência dos sistemas CAD e CADx em imagens médicas está relacionada às técnicas que os constituem. Em meio às formas de se analisar este tipo de imagens digitais, tem se destacado o uso de descritores de textura, em conjunto com técnicas de aprendizagem de máquina para caracterizar regiões suspeitas de patologias.

A seguir, serão apresentados trabalhos considerados relevantes no meio científico que utilizam análise de textura com enfoque na detecção e diagnóstico de glaucoma em retinografias.

No trabalho de Acharya et al. (2011), os autores propõem uma metodologia que utiliza uma combinação de características de textura e de espectros de ordem superior (*Higher Order Spectra* - HOS) para detectar o glaucoma a partir de imagens de fundo de olho. As características de textura foram extraídas a partir de *Gray-Level Cooccurrence Matrix* (GLCM) e *Gray Level Difference Matrix* (GLDM). Uma base privada com 60 imagens (30 normais e 30 glaucomatosas) é utilizada para avaliação do trabalho. Os classificadores *Support Vector Machine* (SVM), *Sequential Minimal Optimization*, *Naive Bayes* (NB) e *Random Forest* foram usados para realizar classificação supervisionada. A metodologia proposta obtém uma precisão de 91,7% com o classificador *Random Forest*.

A utilização da SVM tem se mostrado bastante eficiente e sendo aplicada em um crescente número de trabalhos durante a etapa de reconhecimento de padrões em metodologias de diagnóstico utilizando imagens médicas. Mookiah et al. (2012) apresenta uma metodologia para o diagnóstico de glaucoma baseado em características de textura extraídas a partir da transformada discreta de *wavelet* (*Discrete Wavelet Transform* - DWT) e de HOS. A base de imagens privada utilizada para análise é composta por 60 imagens, sendo 30 imagens normais e 30 com glaucoma. A classificação capaz de identificar automaticamente as imagens em normais e glaucomatosas é realizada utilizando SVM, com diferentes funções de *kernel*, alcançando como melhor resultado uma acurácia de 95%, sensibilidade de 93,33% e especificidade de 96,67%.

No trabalho de Dua et al. (2012), uma metodologia é proposta para o diagnóstico do glaucoma utilizando características extraídas com base nos coeficientes da DWT. A eficácia da metodologia é avaliada a partir dos classificadores SVM, *Sequential Minimal Optimization*, NB e *Random Forest* aplicados em uma base privada contendo 60 imagens,

sendo 30 imagens normais e 30 imagens glaucomatosas. Como melhor resultado apresenta uma acurácia de 93% com a utilização de NB.

A metodologia proposta por Noronha et al. (2014) utiliza características HOS cumulantes de 3ª ordem extraídas da transformada de Radon (*Radon Transform - RT*) aplicada em imagens de fundo do olho. Essas características foram submetidas à análise discriminante linear (*Linear Discriminant Analysis - LDA*), para selecionar as características mais significativas que posteriormente são alimentadas para os classificadores SVM e NB, para diagnóstico automático de glaucoma. O trabalho utiliza uma base privada com 272 imagens, sendo 100 imagens normais, 72 imagens com glaucoma médio e 100 com glaucoma moderado/grave. Nesta metodologia, as imagens foram classificadas em três classes: normal, glaucoma médio e glaucoma moderado/grave obtendo como melhor resultado 92,65% de acurácia, 100% de sensibilidade e especificidade de 92% com o classificador NB.

O *Local Binary Pattern* (LBP) e suas variações tem sido largamente utilizado para obtenção da análise de textura de imagens médicas, e mostra a sua eficácia em várias aplicações, em particular para análise de imagens de retinografias. Por exemplo, em (ALI et al., 2014), o LBP foi utilizado para extrair características de textura de imagens de retinografia, usando a forma clássica do LBP, mais o *Local Binary Pattern Magnitude* (LBPM) e o *Local Binary Pattern Center* (LBPC). A imagem colorida é transformada em imagem em escala de cinza a partir do cálculo da média dos canais azul e verde. As imagens foram classificadas em saudáveis ou glaucomatosas com o *K-Nearest Neighbors* (KNN). O trabalho utiliza uma base de imagens com 41 imagens, sendo 13 imagens de glaucoma e 28 normais, e atingiu um índice de acerto de 95,1%, sensibilidade de 96,4% e especificidade de 92,3% (OJALA; PIETIKÄINEN; HARWOOD, 1996).

Sakthivel e Narayanan (2015) calcularam o LBP e o algoritmo de Daugman sobre o resultado do filtro de Gabor, onde a distância euclidiana entre os vetores de características formados pelos histogramas das técnicas aplicadas é utilizada como parâmetro para classificação das imagens de retinografia. O estudo utilizou uma base de análise com 124 imagens de retinografias, onde 80 foram usadas na fase de treino e 44 na fase de testes. A proposta atingiu resultados de 95,45% para acurácia, sensibilidade e especificidade na detecção de glaucoma.

Gajbhiye e Kamthane (2015) propuseram uma metodologia para detecção de glaucoma utilizando transformada de *wavelet* para decomposição da imagem e *higher*

order moments para cálculo das características. Foram utilizados os classificadores SVM, KNN e *Error Back-Propagation Training Algorithm* (EBPTA). A metodologia alcançou uma acurácia de 86,57%. Para os testes foram utilizadas 350 imagens da base pública RIM-ONE.

Na metodologia proposta por Haleem et al. (2015) foram utilizadas características extraídas da transformada de *wavelet* regional (Regional Wavelet Features - RWF) no disco óptico. A região do disco óptico é dividida em quatro quadrantes segundo a regra ISNT (Inferior, Superior, Nasal e Temporal) e para cada quadrante é calculada a energia *wavelet* em diferentes sub-bandas de frequência. A metodologia é testada através da base pública RIM-ONE em 158 imagens (118 imagens normais and 40 glaucomatosas) e alcança uma taxa de acerto de 92,95%.

No trabalho de Salam et al. (2015) é apresentada uma metodologia para detecção de glaucoma em imagens de fundo de olho que utiliza uma fusão de CDR e características híbridas de textura e intensidade dos pixels. As características de textura são baseadas em transformadas de *wavelet* e LBP. A classificação das imagens em três classes (glaucoma, não glaucoma e suspeito) é feita com base nos resultados da SVM, obtendo acurácia de 92%, sensibilidade de 100% e especificidade de 88%. A avaliação da metodologia é feita a partir de uma base de imagens privada de 50 retinografias com 15 glaucomas e 35 imagens saudáveis.

Raja e Gangatharan (2015) utilizaram o SVM para classificar imagens de fundo de olho entre saudáveis e glaucomatosas a partir dos valores de intensidade média, entropia e energia. Para extrair características da imagem, é aplicada a *Hyper Analytic Wavelet Transformation* (HWT). A fim de melhorar as etapas de extração e classificação, foi utilizada uma abordagem híbrida de *Group Search Optimizer* (GSO) e *Particle Swarm Optimization* (PSO) para ajustar os parâmetros da HWT e da SVM. O trabalho utiliza uma amostra da base pública RIM-ONE com 158 imagens (84 imagens normais e 74 com glaucoma) alcançando uma acurácia de 95%.

No trabalho de Acharya et al. (2015) foram extraídas as características: média, variância, assimetria, curtose, energia e entropia de Shannon, Rényi e Kapoor a partir dos coeficientes da transformada de Gabor. Essas características foram submetidas à análise de componentes principais (*Principal Component Analysis* - PCA) para reduzir sua dimensionalidade. A base de imagens utilizada contém 510 imagens de fundo de olho sendo 266 imagens normais e 244 imagens com algum estágio de glaucoma. O trabalho

realiza a classificação das imagens em duas classes (normal e glaucomatosa) através de SVM e NB. No entanto, alcançou melhores resultados, acurácia de 93,1%, sensibilidade de 89.75% e especificidade de 96.20%, com SVM. O classificador NB atingiu 90,14% de acurácia.

Claro et al. (2016) realizaram a extração de características de textura usando *Gray-Level Cooccurrence Matrix* (GLCM) e entropia em imagens de fundo de olho em diferentes modelos de cor. A metodologia é aplicada em 169 imagens da base pública RIM-ONE. *Multi Layer Perceptron*, *Radial Basis Function* (RBF), *Random Committee* e *Random Forest* foram usados na classificação das imagens, em glaucomatosas ou não, obtendo como melhor resultado 93,03% de acurácia com o classificador *Multi Layer Perceptron*. O trabalho proposto por Maheshwari et al. (2017) apresenta uma metodologia para um diagnóstico automatizado de glaucoma em imagens de fundo de olho. Para tanto, utilizam decomposição de modo variacional (*Variational Mode Decomposition* - VMD) de forma iterativa para a decompor a imagem. Várias características de entropia e dimensões fractais são extraídas dos componentes VMD. O algoritmo *ReliefF* foi usado para seleção de características que foram submetidas ao classificador *Least Squares Support Vector Machine* (LS-SVM). O trabalho utiliza uma base privada com 488 imagens (244 normais e 244 glaucomatosas) e a base pública RIM-ONE com 455 imagens (255 normais e 200 glaucomatosas) para realização dos testes aplicando validação cruzada de 3 e 10 vezes e alcançando, respectivamente, precisões de 95,19% e 94,79%, sensibilidades de 93,62% e especificidades de 96,71% e 95,88%, com a base privada e, precisões de 81,22% e 81,63%, respectivamente, na base RIM-ONE.

Maheshwari, Pachori e Acharya (2017) utilizaram a transformada de *wavelet* empírica (*Empirical Wavelet Transform* - EWT) para decompor as imagens. Correntropia é utilizada para extrair características dos componentes gerados pela transformada. As características foram selecionadas utilizando teste-t. A classificação das imagens em glaucomatosas ou saudáveis é realizada com LS-SVM. Como entrada para extração de características foram utilizados os 3 canais (RGB) mais a imagem em escala de cinza. Para os testes foram utilizadas uma base privada com 60 imagens (30 normais e 30 glaucomatosas) e a base pública RIM-ONE com 455 imagens (255 normais e 200 glaucomatosas). Na base privada foi obtido como melhor resultado uma acurácia de 98,33%, sensibilidade de 100% e especificidade de 96,67%. Na base pública foi obtida uma acurácia de 81,32%, sensibilidade de 78,99% e especificidade de 83,14%.

No trabalho de Sousa et al. (2017), os autores utilizaram funções geoestatísticas (semivariograma, semimadograma, covariograma e correlograma) em conjunto com LBP, para descrever a textura da região do disco óptico, e SVM e algoritmo genético, para discriminar imagens de retinografia em glaucomatosas ou saudáveis, atingindo acurácia de 91,20%, sensibilidade de 95,00% e especificidade de 88,23% em seus resultados. Os testes foram realizados em 455 imagens da base pública RIM-ONE, sendo 255 imagens normais e 200 glaucomatosas.

A metodologia proposta por Acharya et al. (2017) utiliza um processo de convolução nas imagens a partir dos bancos de filtros Leung-Malik (LM), Schmid e máxima resposta (MR4 e MR8) para produzir microestruturas básicas chamadas *textons*. Características do padrão de configuração local (*Local Configuration Pattern* - LCP) são extraídas desses *textons*. A seleção das características significativas é realizada usando *Sequential Floating Forward Search* (SFFS) e são ranqueadas usando teste-t. Por fim, vários classificadores foram utilizados para classificação das imagens nas classes normal e glaucomatosa, são eles árvore de decisão, análise discriminante quadrática (*Quadratic Discriminant Analysis* - QDA), LDA, SVM, KNN e redes neurais probabilísticas. Para os testes, é utilizada uma base privada com 702 imagens (143 normais e 559 glaucomatosas). A maior taxa de acurácia, 95,73%, é alcançada usando seis características do filtro LM e o classificador KNN, com resultados de 96,24% para sensibilidade e 93,71%, especificidade.

Analisando os trabalhos relacionados percebe-se que grande parte é aplicada em bases de imagens privadas com uma quantidade pequena de amostras. Também é notável que todos eles são baseados apenas na região da imagem de retina que caracteriza o disco óptico por conter as informações realmente significativas para o diagnóstico do glaucoma. Seus resultados comprovam ser promissora a utilização de técnicas de análise de textura e de funções geoestatísticas submetidas ao classificador SVM em imagens de retinografia.

A contribuição deste trabalho consiste em propor a utilização de métodos de análise de textura baseados em CLBP e funções geoestatísticas (função K de Ripley e Índice de Moran) submetidos ao classificador SVM para prover o diagnóstico de glaucoma em imagens de retina dada a segmentação ou marcação do disco óptico.

3 Fundamentação Teórica

Este capítulo trata da fundamentação teórica que expõe conceitos importantes para compreensão da metodologia proposta. Aborda-se a anatomia do olho, glaucoma, imagens de retinografia, processamento de imagens digitais, modelos de cores e teoria das cores oponentes, equalização do histograma, análise de textura utilizando CLBP e abordagem estatística espacial com função K de Ripley e Índice de Moran, seleção de características usando Análise Discriminante Linear, reconhecimento de padrões utilizando Máquina de Vetores de Suporte e por fim as métricas de desempenho utilizadas para avaliar a metodologia proposta.

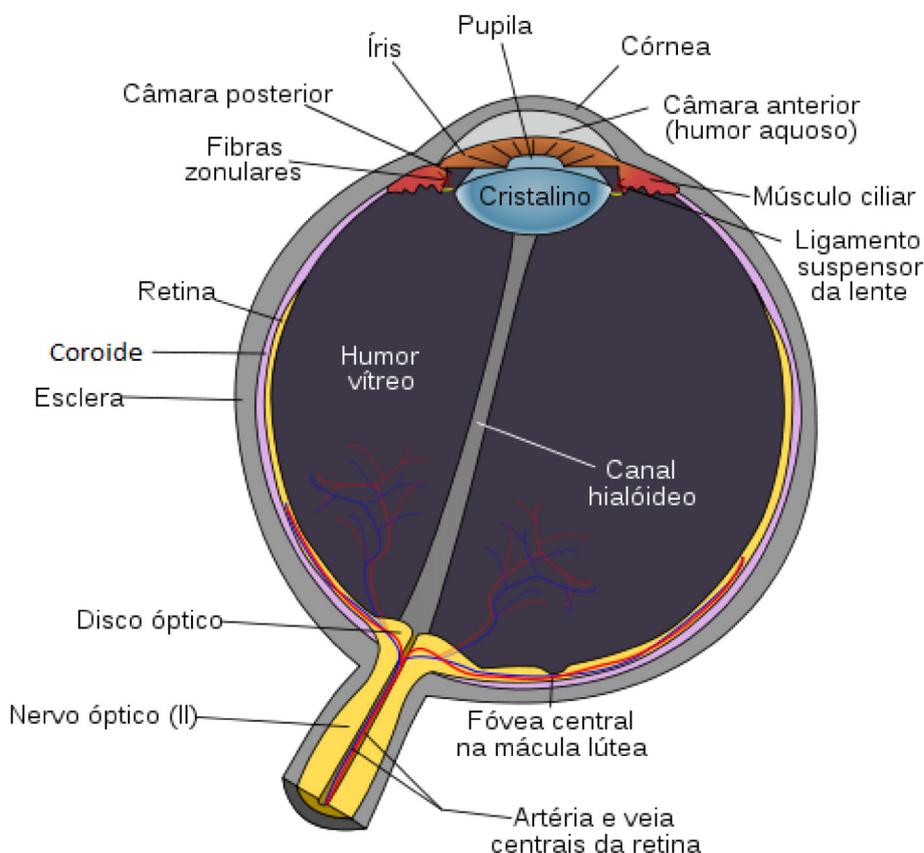
3.1 Anatomia do Olho

O olho é o responsável pela captação da luz refletida pelos objetos à nossa volta. Rotineiramente, ele é comparado a uma câmera fotográfica pois ambos usam lentes para focalizar a luz incidente. Enquanto a câmera utiliza o sensor óptico para registrar a imagem, o olho utiliza uma camada especializada de células chamada retina.

O globo ocular tem formato aproximadamente esférico e um diâmetro de cerca de 20 mm. Ele fica acondicionado dentro de uma cavidade óssea e protegido pelas pálpebras, sendo envolvido por três membranas: a camada externa formada pela córnea e pela esclera, a coroide, e a retina, que é a camada interna. Na Figura 1 é apresentada a estrutura do olho humano correspondente a uma seção horizontal do globo ocular.

A córnea é uma película transparente que cobre a parte anterior do olho. Dando continuidade à córnea, a esclera, ou esclerótica, é uma membrana opaca que reveste o globo ocular. Abaixo da esclera está a coroide, conhecida também como corioide ou corioideia. Esta é uma membrana fina e com muitos vasos sanguíneos que abastecem a retina com nutrientes e oxigênio. O revestimento da coroide é fortemente pigmentado, o que ajuda a reduzir a quantidade de luz que entra no olho. Ela é dividida em corpo ciliar e diafragma da íris, sendo este último responsável por controlar a quantidade de luz que deve penetrar no olho. O diâmetro da abertura central da íris (pupila) varia entre 2 mm e 8 mm. A parte frontal da íris contém o pigmento visível do olho, enquanto sua porção posterior possui um pigmento negro (FILHO; NETO, 1999).

Figura 1 – A anatomia do olho mostrando as três camadas principais (retina, coroide e esclera), nervo óptico, disco óptico e outras características.



Fonte: Adaptado de Mary, Rajsingh e Naik (2016).

A membrana mais interna do olho é a retina, situada na sua parede posterior. Quando o olho focaliza uma cena, a imagem correspondente é projetada sobre a retina, na qual estão distribuídos dois tipos de receptores de luz discretos: os cones e os bastonetes, os quais recebem e convertem os estímulos luminosos em estímulo elétrico, transmitindo-o ao nervo óptico. Os cones são em número de 6 a 7 milhões em cada olho e estão localizados na porção central da retina, chamada de fóvea. Eles são altamente sensíveis a cor e cada um está conectado a uma terminação nervosa dedicada. O número de bastonetes é bem maior, cerca de 75 a 150 milhões, distribuídos em toda a superfície da retina. Os bastonetes servem para dar uma visão geral da imagem captada no campo de visão. Eles não distinguem cores, mas são sensíveis a baixos níveis de iluminação (FILHO; NETO, 1999).

No fundo do olho podemos encontrar o disco óptico e a mácula lútea. O disco óptico (DO) é a porção do nervo óptico vista no fundo dos olhos, formado pelo encontro de todos os axônios das células ganglionares da retina assim que penetram no nervo óptico. O DO é uma estrutura circular que apresenta uma tonalidade rosa pálido ou esbranquiçada e bordas bem definidas, ele situa-se no lado nasal da retina e seu diâmetro físico médio é de cerca de 1,5mm. O DO não contém fotorreceptores, ele é insensível à luz. Conseqüentemente, esta parte da retina costuma ser denominada de ponto cego.

Em uma imagem de um fundo de olho normal, isto é, da retina, pode-se constatar que o disco óptico constitui a parte mais brilhante na imagem. Da mesma maneira, as propriedades de forma, tamanho e convergência dos vasos contribuem para a identificação do disco óptico (VERAS, 2014).

A mácula lútea, ponto central da retina, é a região que distingue detalhes no meio do campo visual. Constitui uma pequena área oval, com cones fotorreceptores especiais e em maior número, sendo assim, uma área especializada para acuidade visual. No centro da mácula lútea há uma pequena depressão denominada fóvea central, a área de visão mais aguda e apurada.

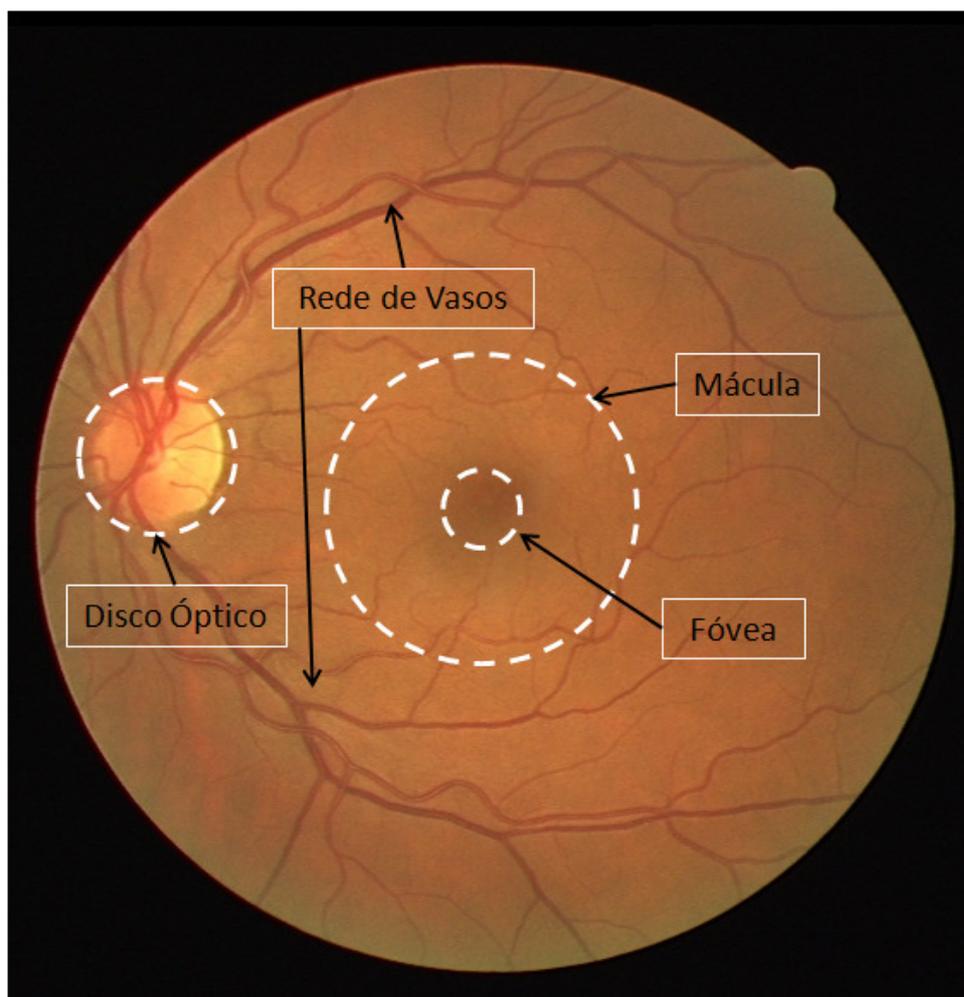
A fóvea central possui aproximadamente 1,5mm de diâmetro. De forma aproximada, pode-se considerá-la um sensor de área quadrada de 1,5mm por 1,5mm. A densidade de cones nesta área da retina é de aproximadamente 150 mil elementos por mm². Baseando-se nessas aproximações, o número de cones na região de maior acuidade do olho é de aproximadamente 337 mil elementos (FILHO; NETO, 1999).

A Figura 2 apresenta as principais estruturas fisiológicas presentes em uma retina saudável: o disco óptico, os vasos sanguíneos, a mácula e a fóvea.

3.2 Glaucoma

O glaucoma é uma doença ocular crônica que afeta os nervos ópticos levando a perdas no campo visual e eventual cegueira. Vários fatores de risco associados ao glaucoma foram identificados, dentre os quais o mais significativo é a pressão intra-ocular elevada (PIO), às vezes aumentando severamente a 60-70 mmHg. Pressões superiores a 25-30 mmHg podem causar perda de visão quando sustentada por um longo período de tempo. Na maioria dos casos de glaucoma, a pressão anormalmente alta resulta do aumento da

Figura 2 – Estruturas fisiológicas da retina.



Fonte: Veras (2014).

resistência à saída de fluidos através do sistema de drenagem dos olhos (MARY; RAJSINGH; NAIK, 2016; GUYTON; HALL, 2005).

Em olhos saudáveis, há um equilíbrio entre fluidos produzidos dentro dos olhos e aqueles que saem. Esse equilíbrio mantém a PIO dentro da constante do olho. No caso do glaucoma, esse equilíbrio não é mantido, o que, gera um aumento na PIO, prejudicando assim o nervo óptico (KANSKI; BOWLING, 2011).

Se o glaucoma não for tratado, pode causar danos permanentes nos nervos ópticos e causar cegueira. Este dano progressivo e irreversível aos nervos ópticos é frequentemente acompanhado apenas de sinais sutis ou mesmo sem sintomas, e, por isso, é apelidado de “ladrão furtivo da visão”. A Figura 3 mostra os diferentes estágios do glaucoma à medida que progride. É importante uma detecção precoce do glaucoma, que pode minimizar o

dano e a perda da visão, e garantir um tratamento rápido e adequado (MARY; RAJSINGH; NAIK, 2016).

Figura 3 – Sinais e sintomas do glaucoma. (a) Um campo visual normal. (b) O mesmo cenário com perda de visão avançada pelo glaucoma.



(a)

(b)

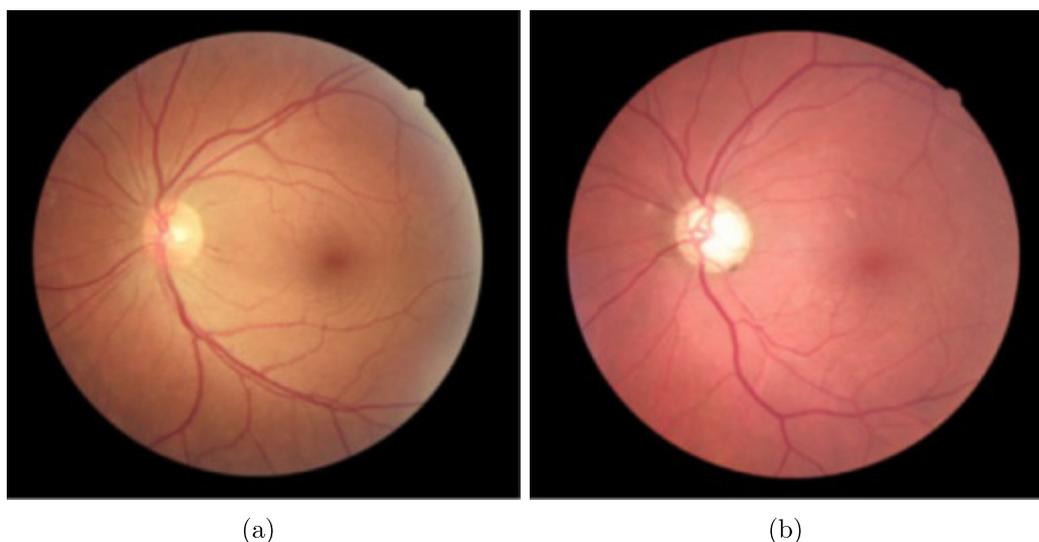
Fonte: Mary, Rajsingh e Naik (2016).

Entre os métodos disponíveis de varredura do disco óptico utilizados para diagnosticar o glaucoma estão a Tomografia Retiniana de Heidelberg (*Heidelberg Retina Tomography - HTR*), a Polarimetria de Varredura a Laser e a Tomografia de Coerência Óptica (*Optical Coherence Tomography - OCT*). Esses métodos são caros e requerem médicos experientes para usá-los. Uma alternativa para realizar a avaliação do disco óptico com precisão e baixo custo é através da fotografia de fundo de olho (retinografia), discutida na próxima seção deste capítulo.

O diagnóstico de glaucoma é tipicamente baseado no histórico médico, PIO e perda de campo visual juntamente com uma avaliação manual do disco óptico, através de oftalmoscopia. Cabeça do nervo óptico ou disco óptico é o local onde os axônios de células ganglionares saem do olho para formar o nervo óptico, através do qual a informação visual dos fotorreceptores é transmitida ao cérebro. Em imagens 2D, o caso de retinografias, o DO pode ser dividido em duas zonas distintas: uma zona central brilhante chamada escavação e uma região periférica chamada anel neuroretiniano. O glaucoma provoca um crescimento da região de escavação com relação ao DO (afinamento do anel neuroretiniano) (ZHANG et al., 2014).

A Figura 4 apresenta duas imagens representativas de fundo de olho, uma proveniente de um olho saudável e a outra de um olho glaucomatoso, evidenciando a diferença entre os tamanhos da escavação e do DO.

Figura 4 – Imagens de retina: (a) olho normal, (b) olho glaucomatoso.



Fonte: Emanuelli (2017).

A relação vertical entre a escavação e o disco óptico, CDR (*Cup-to-Disc Ratio*), é um dos primeiros e principais indicadores observados, assim como vários parâmetros relacionados à CDR, tais como a ovalidade vertical, alterações progressivas da escavação e a espessura do anel neuroretiniano, e têm sido utilizados para detectar o glaucoma precocemente pois especificam mudanças na área da escavação (ZHANG et al., 2014)(MARY; RAJSINGH; NAIK, 2016).

Nesse sentido, a CDR é calculada tomando a proporção entre os diâmetros da escavação e do disco óptico. Para ser considerado um DO normal, a CDR deve ser igual ou inferior a 0,3, quando a CDR é superior a 0,3 indica um caso suspeito de glaucoma (S.KAVITHA; S.KARTHIKEYAN; DR.K.DURAI SWAMY, 2010).

Na Figura 5 é mostrado um exemplo prático do cálculo do CDR em uma imagem de retina. A figura apresenta a marcação da medição do DO (1,0) e a escavação medida em relação ao tamanho do disco (0,4), resultando em uma CDR de 0,4 que pode ser considerada como um caso suspeito de glaucoma e sua progressividade deve ser acompanhada pelo oftalmologista.

Constam entre os outros fatores de risco do glaucoma, idade a partir de 40 anos, etnia negra, alto grau de miopia, e histórico familiar o qual aumenta em dez vezes a chance de desenvolver a doença. O tratamento da patologia é feito com o uso de colírios, laser e, em último caso, cirurgia (CBO, 2017).

Figura 5 – Exemplo de cálculo da relação entre a escavação e o disco óptico em uma imagem de retina.



Fonte: Adaptado de Santos (2017).

Existem duas formas principais de glaucoma: ângulo aberto (a forma mais comum, afetando aproximadamente 70 a 95 por cento dos indivíduos com glaucoma) e ângulo fechado. Ambos podem levar à perda de visão periférica e eventualmente culminar em cegueira (BRIGHTFOCUS, 2017).

3.3 Retinografia (Imagem de fundo de olho)

A retinografia, ou imagem de fundo de olho, é um exame oftalmológico que permite observar e fotografar a retina, o nervo óptico e o fundo do olho. Ela serve para efetuar o diagnóstico ou proceder ao acompanhamento de algumas doenças dos olhos. As principais indicações da retinografia se relacionam com o diagnóstico de algumas patologias que podem afetar a retina e o nervo óptico tais como a retinopatia diabética, o glaucoma, a degeneração macular, oclusões vasculares da retina, estudo do nervo óptico ou de outras distrofias retinianas, estudo de tumores oculares, entre outras (CARVALHO, 2010).

A retinografia é capturada por um instrumento óptico especializado. O retinógrafo, apresentado na Figura 6, é composto por lentes, espelhos, filtros e câmeras. A região da retina é iluminada de forma a possibilitar a captura de imagem ou vídeo da região. Os retinógrafos atuais permitem a obtenção de imagens digitais da retina em alta qualidade, que podem ser armazenadas e processadas por softwares (CARVALHO, 2010).

Estes equipamentos de modo geral realizam dois tipos básicos de exames: as retinografias simples e as angiografias ou retinografias fluorescentes. No primeiro caso,

Figura 6 – Exemplos de retinógrafos do mercado.

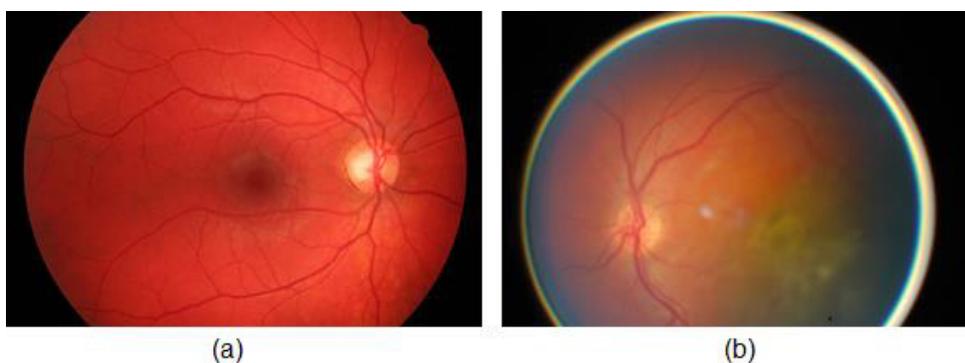


Fonte: Lencione (2013).

as imagens capturadas são formadas pelas retro-reflexões e espalhamento da luz quando esta atinge o fundo do olho (LENCIONE, 2013). Um exemplo de retinografia simples é apresentado na Figura 7(a).

As angiografias diferem devido à administração de um contraste (fluoresceína sódica) na corrente sanguínea do paciente. As imagens, neste caso, são formadas pela captação do sinal de fluorescência do contraste, o que permite observar a circulação dos vasos sanguíneos, a retina e a coroide (LENCIONE, 2013). A fluoresceína absorve a energia eletromagnética e a transforma em energia luminosa quando estimulada por luz com comprimentos de onda entre 500 e 600nm. Para a aquisição da imagem é necessário que o aparelho de retinografia possua filtros adequados para esse fim, o que permite inferir sobre a integridade funcional do fluxo sanguíneo nos vasos da retina (ARTHUR et al., 2011). Uma imagem de angiografia pode ser visualizada na Figura 7(b).

Figura 7 – Retinografias. (a) Retinografia Simples. (b) Angiografia Fluorescente Ocular.



Fonte: Arthur et al. (2011).

3.4 Processamento de Imagens Digitais

Uma imagem pode ser definida como uma função bidimensional, $f(x, y)$, em que x e y são coordenadas espaciais (plano), e a amplitude de f em qualquer par de coordenadas (x, y) é chamada de intensidade ou nível de cinza da imagem nesse ponto. Quando x , y e os valores de intensidade de f são quantidades finitas e discretas, chamamos de imagem digital. O campo do processamento digital de imagens se refere ao processamento de imagens digitais por um computador, e *pixel* é o termo mais utilizado para representar os elementos de uma imagem digital (GONZALEZ; WOODS, 2002).

O processamento de imagens consiste, portanto, em um conjunto de técnicas com o objetivo de capturar, representar e transformar imagens a fim de permitir extrair e identificar informações das imagens e melhorar a qualidade visual de certos aspectos estruturais, facilitando a percepção humana e a interpretação automática.

Em geral, os sistemas CAD/CADx utilizam-se de técnicas provenientes de duas áreas do conhecimento: visão computacional, que envolve o processamento de imagem para realce, segmentação e extração de atributos, e inteligência artificial, que inclui métodos para seleção de atributos e reconhecimento de padrões (KENNETH, 1996).

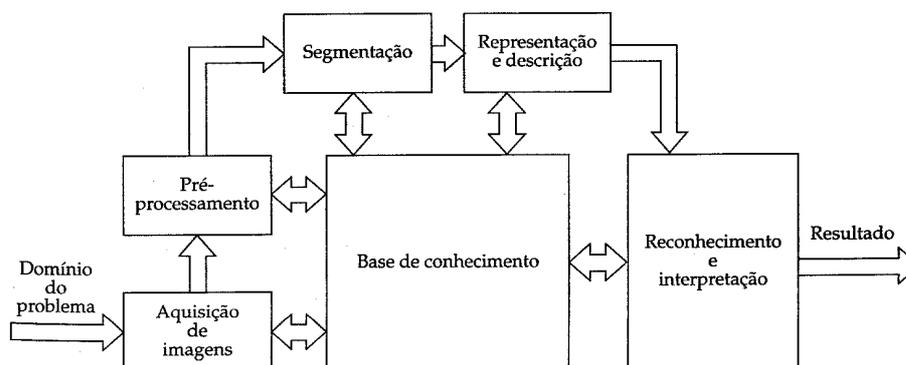
Atualmente, muitos trabalhos têm sido propostos visando à otimização da análise de imagens oftalmológicas de maneira a auxiliar o especialista na detecção e diagnóstico de patologias oculares e são organizados normalmente em duas grandes categorias: Detecção Automática de Anomalias e Segmentação Automática de Pontos de Referência (ALLAM; YOUSSEF; GHALWASH, 2015).

Na Figura 8 é apresentada a representação das etapas do processamento de imagens digitais e mostra que o objetivo global é produzir um resultado a partir da definição do domínio do problema. Estas etapas serão descritas a seguir considerando a arquitetura para processamento de imagens de fundo de olho proposta por Allam, Youssif e Ghalwash (2015) a qual apresenta os dados empregados, os passos que são seguidos e os procedimentos que são aplicados neste tipo abordagem.

A Aquisição de Imagens é a etapa responsável pela obtenção da representação digital (matriz de *pixels*) da imagem. Refere-se às bases de imagens de fundo de olho que formam os dados de entrada para serem processados.

O Pré-processamento consiste em tornar certas estruturas da imagem mais simples de serem definidas através da utilização de técnicas de realce de imagens, ou melhoramento,

Figura 8 – Etapas fundamentais do processamento de imagens digitais.



Fonte: Gonzalez e Woods (2002).

tais como diminuição de ruído, realce de contraste, filtros morfológicos e etc. É uma etapa preliminar, que abrange o processo de manipular a imagem de entrada, de forma que o resultado seja mais adequado do que o original para uma aplicação específica, tornando assim esta imagem mais apropriada ao processamento posterior.

A Segmentação divide a imagem em suas partes ou objetos constituintes. Em outras palavras, consiste no processo de isolar regiões específicas de interesse dentro da imagem. As Regiões de Interesse (ROI) nas imagens de fundo de olho podem incluir anomalias da retina, como exsudatos, hemorragias, aneurismas, etc., e podem também incluir marcações da retina tais como o disco óptico, a mácula, e os vasos sanguíneos.

A Representação e Descrição, ou extração de características, tem como objetivo determinar características básicas de cada objeto que resultem em informações importantes para discriminação entre classes distintas. Pode ser realizada com o auxílio de descritores para caracterizar fronteiras ou esqueleto interno dos objetos ou regiões que foram segmentados na imagem de fundo de olho. Nesse sentido, o conjunto destas medidas constitui um vetor de características (descritores) que definem um padrão calculado para aquela determinada área.

A etapa de Reconhecimento e Interpretação tem por finalidade atribuir um rótulo a um objeto com base nos seus descritores através de uma base de conhecimento que foi construída na etapa anterior.

Para avaliar o desempenho de uma metodologia proposta, uma etapa adicional de Validação dos Resultados é considerada. Nesta etapa, as imagens de fundo de olho resultantes são comparadas com as marcações de referência feitas por especialistas a fim de

avaliar a eficácia do trabalho. Nesse sentido, mede a precisão dos resultados encontrados pela estimativa de índices para o verdadeiro positivo, verdadeiro negativo, falso positivo e falso negativo que se referem ao número de casos em que a marcação ou anomalia está presente ou ausente.

Nas seções seguintes serão apresentadas as técnicas e algoritmos utilizados na metodologia proposta.

3.4.1 Modelos de Cores

O objetivo de um modelo de cores (também chamado de espaço de cores ou sistema de cores) é facilitar a especificação das cores em alguma forma padronizada, amplamente aceita. Essencialmente, um modelo de cores é uma especificação de um sistema de coordenadas e um subespaço dentro desse sistema no qual cada cor é representada por um único ponto (GONZALEZ; WOODS, 2010).

A maioria dos modelos de cores utilizados atualmente é orientada ou em direção ao hardware (como no caso de monitores e impressoras coloridas) ou em direção a aplicações envolvendo a manipulação de cores (como a criação de imagens coloridas para uma animação). Em termos de processamento digital de imagens, os modelos orientados para hardware mais utilizados na prática são o modelo RGB (*Red, Green, Blue* — vermelho, verde, azul) para monitores coloridos e uma ampla classe de câmeras de vídeo em cores; o modelo CMY (*cyan, magenta, yellow* — ciano, magenta, amarelo), o modelo CMYK (*cyan, magenta, yellow, black* — ciano, magenta, amarelo, preto) para a impressão colorida, e o modelo HSI (*hue, saturation, intensity* — matiz, saturação, intensidade), que corresponde estreitamente à forma como os seres humanos descrevem e interpretam as cores (GONZALEZ; WOODS, 2010).

No modelo RGB (SANGWINE; HORNE, 1998), cada cor aparece em seus componentes espectrais primários de vermelho, verde e azul. Nesse modelo, baseado em um sistema de coordenadas cartesianas, a escala de cinza (pontos de valores RGB iguais) estende-se do preto até o branco ao longo do segmento de reta que une esses dois pontos. Por conveniência, assume-se que todos os valores de cor foram normalizados. Isto é, assume-se que todos os valores de R, G e B estejam no intervalo $[0, 1]$. Imagens representadas no modelo de cores RGB consistem de três componentes de imagens, uma para cada cor primária (GONZALEZ; WOODS, 2010).

3.4.2 Cores Oponentes

O modelo de cores RGB, embora muito utilizado no processamento de imagens, não é perceptualmente uniforme e por esta razão foi proposta a teoria do processo oponente da visão de cor humana (HERING, 1964). Essa teoria define que há três pares de cores que nunca são vistos juntos no mesmo lugar ao mesmo tempo. Estes pares, chamados de cores oponentes (*opponent colors*), são vermelho *versus* verde, verde *versus* vermelho, e azul *versus* amarelo (PENEDO et al., 2014).

Usar as cores oponentes para analisar a textura consiste em calcular os três canais oponentes da imagem em RGB, que são definidos pelas equações (1),

$$\begin{aligned} R_G &= R - p \times G \\ G_R &= G - p \times R \\ B_Y &= B - p \times (R + G) \end{aligned} \tag{1}$$

onde p é o filtro de passa baixa.

3.4.3 Equalização do Histograma

Histogramas são a base para várias técnicas de processamento no domínio espacial. Sua manipulação pode ser utilizada de maneira consistente e significativa em técnicas de pré-processamento para o realce de imagens.

Explicitamente, o histograma de uma imagem digital com níveis de intensidade no intervalo $[0, L - 1]$ é uma função discreta $H(r_k) = n_k$, onde r_k é o k -ésimo valor de intensidade e n_k é o número de *pixels* da imagem com intensidade r_k . De modo geral, o histograma fornece uma estimativa da probabilidade de ocorrência do nível de intensidade r_k em uma imagem.

A equalização do histograma é uma técnica de realce de características baseada no histograma a partir da qual se procura redistribuir os níveis de intensidade dos *pixels* em uma imagem, de modo a obter um histograma uniforme no qual o número (percentual) de *pixels* de qualquer nível de intensidade é praticamente o mesmo, de forma que os níveis de intensidade da imagem equalizada cubram um intervalo maior da escala de intensidade. O resultado final é o realce do contraste (FILHO; NETO, 1999; GONZALEZ; WOODS, 2010).

Sendo $H(r_k)$ o histograma da imagem, o histograma acumulado de $H(r_k)$ pode ser calculado por:

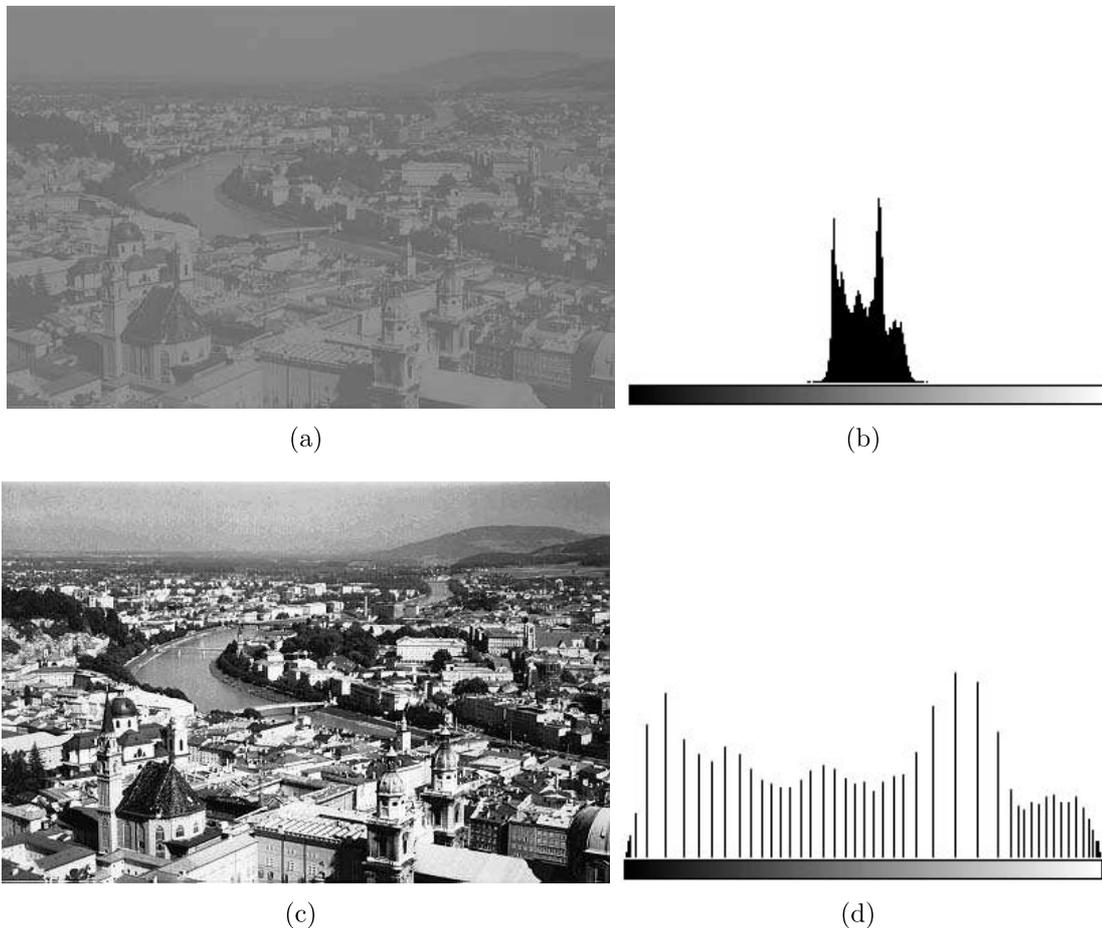
$$H(0) = h(0); H(1) = H(0) + h(1); H(r_k) = H(r_k - 1) + h(r_k) \quad (2)$$

onde r_k varia de 1 a $L - 1$. O novo histograma é obtido por:

$$T(r_k) = \frac{L - 1}{MN} H(r_k) \quad (3)$$

onde MN são as dimensões de linha e coluna da imagem. A imagem equalizada é obtida por $pixel$ por $I = T(r_k)$.

Figura 9 – Aplicação da equalização de histograma a imagem com baixo contraste. Imagem original (a) com seu histograma (b). Imagem equalizada (c) com seu histograma (d).



Fonte: Filho e Neto (1999).

A Figura 9 apresenta um exemplo de aplicação da técnica de equalização de histograma para aumentar o contraste de uma imagem em nível de cinza. A Figura 10(a) apresenta a imagem original, cujo histograma é plotado na Figura 10(b). A Figura 10(d) mostra o histograma equalizado, correspondente à imagem da Figura 10(c).

3.5 Análise de Textura

Uma abordagem importante para a descrição de regiões é quantificar seu conteúdo de textura. Embora não haja uma definição formal de textura, intuitivamente esse descritor fornece medidas de propriedades como suavidade, rugosidade e regularidade (GONZALEZ; WOODS, 2010).

Textura é uma propriedade importante na percepção de regiões e superfícies, contendo informações sobre a distribuição espacial das variações de tonalidade locais em valores de *pixels* que se repetem de maneira regular ou aleatória ao longo do objeto ou imagem (BRAZ JUNIOR, 2008).

A textura também pode ser caracterizada como um conceito bidimensional, onde uma dimensão contém as propriedades primitivas da tonalidade e a outra corresponde aos relacionamentos espaciais entre elas (HARALICK; SHANMUGAM; DINSTEN, 1973)(GUPTA; UNDRILL, 1995).

As medidas resultantes da aplicação de métodos de análise de textura podem ser obtidas através de processos de extração e seleção de características. A extração de características é responsável por executar transformações nos dados de entrada, de modo a descrevê-los de forma simplificada, porém, representativa, enquanto a seleção visa reduzir o número de medidas, eliminando aquelas que apresentam redundância (PEDRINI; SCHWARTZ, 2008).

As três principais abordagens utilizadas no processamento de imagens para descrever a textura de uma região são a abordagem estatística, a estrutural e a espectral (GONZALEZ; WOODS, 2010):

- Abordagem Estatística: produz caracterizações das texturas como suave, rugosa, granulada, entre outras. Considera o relacionamento, a distribuição das intensidades do pixel e o inter-relacionamento entre eles, tratando texturas como fenômenos estatísticos;
- Abordagem Estrutural: baseada nos conceitos estruturais representando a textura como sendo formada pela repetição de padrões que obedecem alguma regra de posicionamento para a sua geração. Lida com arranjos de primitivas de imagens como a descrição de textura baseada em linhas paralelas espaçadas regularmente;

- Abordagem Espectral: é baseada em propriedades do espectro de Fourier e são usadas principalmente para detectar a periodicidade global em uma imagem pela identificação de picos de alta energia no espectro.

Neste trabalho utiliza-se a análise de textura combinando as abordagens estrutural e estatística para descrição de características do disco óptico e reconhecimento de padrões para classificar as imagens de retinografia em saudáveis ou glaucomatosas. A abordagem estrutural será aplicada com base no processo de codificação de padrões de pontos em CLBP. A abordagem estatística espacial é empregada através de índices geoestatísticos, função K de Ripley local e Índice de Moran local, para a formação de um padrão de textura a partir das características. Esta metodologia será fundamentada nas próximas seções.

3.5.1 *Compound Local Binary Pattern (CLBP)*

O *Local Binary Pattern* (LBP) proposto por Ojala, Pietikäinen e Harwood (1996) é uma abordagem simples e eficiente para descrever a estrutura espacial de textura local de uma imagem. Contudo, o operador LBP considera P bits para codificar apenas o sinal da diferença entre a intensidade do *pixel* central e as intensidades dos P *pixels* vizinhos em uma vizinhança local. Dessa forma, o LBP descarta a outra propriedade importante da textura da imagem local, isto é, o contraste, uma vez que este depende da intensidade. Sendo assim, o LBP frequentemente falha na geração de uma codificação binária consistente. Motivados por essa limitação, Ahmed et al. (2011) propuseram o *Compound Local Binary Pattern* (CLBP), uma extensão do LBP original que aloca um código de $2P$ bits com a finalidade de aumentar a robustez da representação de características por incorporar informações locais adicionais. O CLBP além de utilizar os P bits do LBP original, também gera P bits adicionais na sua codificação baseados na informação de magnitude da diferença entre as intensidades do *pixel* central e dos seus vizinhos.

Assim sendo, o primeiro *bit* representa o sinal da diferença entre as intensidades do *pixel* central e dos *pixels* da sua vizinhança local, da mesma maneira que a codificação básica do LBP. O segundo *bit* é usado para codificar a magnitude da diferença em relação a um valor limiar, a magnitude média (M_{avg}) da diferença entre as intensidades do *pixel* central e as intensidades dos seus vizinhos na vizinhança local da área de interesse. O

operador CLBP define esse *bit* em 1 se a magnitude da diferença entre o *pixel* central e seu vizinho for superior ao limiar M_{avg} . Caso contrário, será definido como 0.

O código CLBP de 2-*bits* é obtido usando a Equação 4,

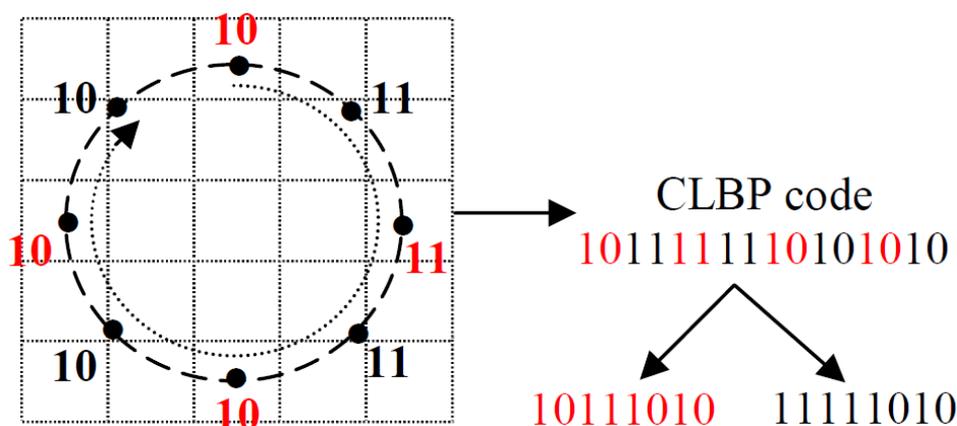
$$CLBP_{P,R}(x_c, y_c) = \sum_{p=0}^{P-1} s(i_p - i_c) 2^p \quad (4)$$

obedecendo a função da Equação 5,

$$s(i_p - i_c) = \begin{cases} 00 & \text{se } i_p - i_c < 0 \text{ e } |i_p - i_c| \leq M_{avg} \\ 01 & \text{se } i_p - i_c < 0 \text{ e } |i_p - i_c| > M_{avg} \\ 10 & \text{se } i_p - i_c \geq 0 \text{ e } |i_p - i_c| \leq M_{avg} \\ 11 & \text{caso contrário} \end{cases} \quad (5)$$

onde i_c representa o valor da intensidade do *pixel* central, i_p representa a intensidade de um *pixel* p vizinho, e M_{avg} a magnitude média da diferença entre i_p e i_c na vizinhança local.

Figura 10 – Geração dos dois padrões sub-CLBP 10111010 e 11111010 a partir do código CLBP original 1011111110101010.



Fonte: Ahmed et al. (2011).

Em uma vizinhança 3×3 , o CLBP opera nos 8 vizinhos em torno do *pixel* central, atribuindo um código de 16 *bits* para rotular esse *pixel*, sendo o número de padrões binários possíveis de 216. Para reduzir a complexidade, todo o código binário do CLBP é dividido em dois padrões sub-CLBP de 8 *bits*. Cada padrão sub-CLBP é obtido concatenando os valores de *bits* correspondentes a $P/2$ vizinhos, onde P é o número de vizinhos. Sendo que o primeiro sub-CLBP é obtido concatenando os valores de bits correspondentes aos vizinhos nas direções norte, leste, sul e oeste, respectivamente. O segundo padrão sub-CLBP é

obtido concatenando os valores de *bits* correspondentes aos vizinhos nas direções nordeste, sudeste, sul-oeste e noroeste, respectivamente. Formalmente, em uma vizinhança local, os dois padrões sub-CLBP são formados concatenando os valores correspondentes da sequência de *bits* $(1, 2, 5, 6, \dots, 2P - 3, 2P - 2)$ e $(3, 4, 7, 8, \dots, 2P - 1, 2P)$, respectivamente, do código CLBP original de $2P$ *bits*. Assim, este método reduz significativamente o número de padrões possíveis, o que resulta em um total de 28 padrões de sub-CLBP distintos.

O processo é ilustrado na Figura 10. Os dois padrões sub-CLBP são tratados como códigos binários separados e combinados durante a geração do vetor de características.

3.5.2 Estatística Espacial

Denomina-se estatística espacial, ou geoestatística, o ramo da estatística que permite analisar a localização espacial de eventos, ou seja, além de identificar, localizar e visualizar a ocorrência de fenômenos que se materializam no espaço, através do uso de um SIG (Sistema de Informações Geográficas), é possível modelar a ocorrência destes fenômenos, incorporando, por exemplo, os fatores determinantes, a estrutura de distribuição espacial ou a identificação de padrões. As principais áreas de aplicação da estatística espacial são o mapeamento de doenças, os estudos ecológicos, a identificação de agrupamentos espaciais (*clusters*) e o monitoramento de problemas ambientais (SANTOS; SOUZA, 2007).

A característica fundamental da estatística espacial que a diferencia da estatística clássica é o uso explícito da referência espacial no modelo, isto é, o uso explícito das coordenadas espaciais no processo de coleta, descrição e análise dos dados. Assim sendo, o interesse está centrado nos processos que ocorrem no espaço e os métodos empregados buscam descrever e analisar o comportamento destes processos (KREMPI, 2004).

Expressamente a análise estatística pode ser realizada tanto em relação à localização absoluta (coordenadas em um espaço), quanto em termos de localização relativa (disposição espacial, topologia) dos dados espaciais. Nesse contexto, as dimensões de área, topologia, arranjo espacial, distância e interações espaciais se tornam o foco de atenção (ANSELIN, 1996).

O processo de análise de pontos pode ser descrito em termos dos efeitos de primeira e segunda ordem. Os efeitos de primeira ordem, considerados globais ou de grande escala, correspondem a variações no valor médio do processo no espaço. Indicadores globais de autocorrelação espacial constituem uma aproximação mais tradicional do efeito da

dependência espacial e são utilizados para conhecer o grau de interação do conjunto de dados espaciais. Efeitos de segunda ordem, denominados locais ou de pequena escala, representam a dependência espacial no processo proveniente da estrutura de correlação espacial. Os indicadores locais fornecem portanto informação acerca da relevância de um agrupamento espacial de valores ao redor de cada área da região de interesse, a soma destes valores é proporcional ao indicador global (BRAZ JUNIOR, 2014)(ANSELIN, 1996).

Os indicadores globais de autocorrelação espacial fornecem um único valor como medida de associação espacial para todo o conjunto de dados, que é útil para caracterização de toda região de estudo. Muitas vezes é necessário, no entanto, examinar os padrões com maior nível de detalhes. Para tal, é necessária a utilização de indicadores que possam ser associados a diferentes localizações de uma variável distribuída espacialmente. Quando a área de estudo possui várias divisões, provavelmente aparecerão diferentes regimes de associações espaciais. Os indicadores de associações espaciais locais produzem um valor específico para cada objeto (área), permitindo assim, a identificação de agrupamentos de objetos com valores de atributos semelhantes (*clusters*), objetos anômalos (*outliers*) e de regimes espaciais, que não são identificados através do cálculo do indicador de associação espacial global (KREMPI, 2004).

As estatísticas usadas para descrição na análise de segunda ordem podem ser subdivididas em três categorias gerais (LEVINE, 1996):

- Medidas de distribuição espacial: descrevem o centro, a dispersão, direção e forma da distribuição de uma variável;
- Medidas de autocorrelação espacial: descrevem a relação entre as diferentes localizações para uma variável simples, indicando o grau de concentração ou dispersão (por exemplo, análise de agrupamentos);
- Medidas de associação espacial entre duas ou mais variáveis: descrevem a correlação ou associação entre variáveis distribuídas no espaço, por exemplo, a correlação entre a localização de lojas de bebidas com pontos onde ocorrem muitos acidentes de trânsito.

Medidas de autocorrelação espacial surgem sempre que o valor de uma variável em um lugar do espaço está relacionado com seu valor em outros lugares no espaço. Nessa situação, observações separadas no espaço por certa distância espacial d possuem valores similares (correlação). O objetivo da estatística é medir o grau de associação espacial entre

as observações de uma ou mais variáveis. A autocorrelação espacial pode ser negativa ou positiva. Será positiva quando o fato observado em um lugar também é observado em seus vizinhos separados a certa distância. A medida também pode assumir valores nulos, nos quais se comprova a inexistência de correlação espacial (BRAZ JUNIOR, 2008).

No contexto da estatística, a textura pode ser descrita em termos dos dois principais componentes associados a *pixels* (ou outra unidade): variabilidade e autocorrelação espacial. Assim, a vantagem da estatística espacial é que esses dois aspectos podem ser medidos em conjunto. A correlação organizacional dos *pixels*, analisados como pontos independentes, pode ser realizada a partir de vários indicadores. Neste trabalho, são utilizadas as medidas resultantes da aplicação da função K de Ripley local e Índice de Moran local, descritas nas seções seguintes, para analisar a textura das estruturas internas de discos ópticos amostrados em retinografias.

3.5.3 Função K de Ripley

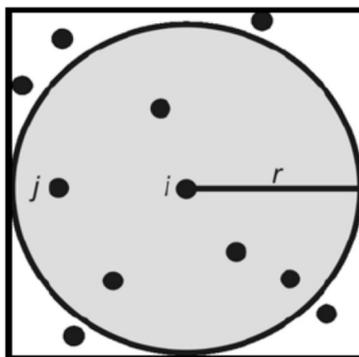
A função K de Ripley é um método de análise de segunda ordem comumente utilizado em análise de dados espaciais. A função é uma ferramenta para realizar a análise de uma região espacial completamente mapeada em forma de pontos discretizados, onde cada ponto traz consigo uma relação do evento ocorrido. Normalmente é calculada em duas dimensões, ou seja, a localização contém uma referência no plano. Mas também pode versar sobre localizações em uma linha ou em três dimensões (BRAZ JUNIOR, 2008).

Esta função pode ser utilizada para resumir um padrão de pontos, testar hipóteses sobre o padrão, estimar parâmetros e ajustar modelos (RIPLEY, 1977). Em sua forma local, definida pela Equação 6, é usada para descrever a textura de uma região em uma imagem, e é calculada ao escolher um centro i , onde é examinada a ocorrência de *pixels* j com mesma intensidade, para diferentes valores de raio r , com $i \neq j$. A é a área da amostra, n é o número total de pontos na amostra e d é uma função que retorna 1 se a distância d_{ij} entre os pontos i e j é menor do que o raio r ou 0, caso contrário. A Figura 11 exemplifica o funcionamento desta abordagem.

$$K_i(r) = \frac{A}{n} \sum_{i \neq j} \delta(d_{ijr}) \quad (6)$$

Cada intensidade ou nível de cinza (padrão espacial) é analisada de forma independente das demais para determinar se um evento ocorre ou não dentro da distância especificada de r . Assim, o número de elementos no vetor de característica obtido através de $K(r)$ é dado pelo número de níveis de cinza presentes na imagem multiplicado pelo número desejado de raios.

Figura 11 – Funcionamento da Função K de Ripley.



Fonte: Rocha (2014).

3.5.4 Índice de Moran

O Índice de Moran local foi proposto por Anselin (1994) como um indicador estatístico para explorar a autocorrelação local e para detectar objetos espaciais com influência no indicador Moran global. Este indicador trabalha a partir da estimativa de segunda ordem do comportamento dos seus dados, ou seja, a partir da análise das covariâncias entre as diferentes unidades de área. Enquanto o Índice de Moran global informa o nível de interdependência espacial entre todas as áreas da região em estudo, o Índice de Moran local avalia a covariância entre uma determinada área e uma certa vizinhança definida em função de uma distância d .

Este índice, cujo valor varia no intervalo $[-1, +1]$, fornece uma medida geral da associação espacial. Valores próximos de zero indicam a inexistência de autocorrelação espacial significativa entre os valores dos objetos e seus vizinhos significando então uma independência espacial (aleatoriedade). Valores positivos para o índice indicam autocorrelação espacial direta, ou seja, o valor do atributo de um objeto tende a ser semelhante aos valores dos seus vizinhos. Valores negativos para o índice indicam

autocorrelação espacial negativa ou inversa, em outras palavras, indicam que valores de uma variável em áreas próximas tendem a serem diferentes (KREMPI, 2004).

O Índice de Moran local (I_i), se for calculado a partir do produto dos desvios das variáveis de interesse em relação à média, pode ser obtido através da Equação 7. Esta forma computa o índice local do objeto I_i , através da multiplicação do desvio correspondente, z_i , pela média dos desvios de seus vizinhos.

$$I_i = \frac{z_i \sum_j w_{ij} z_j}{\sum_{i=1}^n z_i^2} \quad (7)$$

onde:

z_i : valor da variável normalizada na região i ;

$w_{ij} z_j$: elementos da matriz de proximidade espacial.

3.6 Seleção de Características

Um problema comum em aplicações de visão computacional é a utilização de grande número de características. Mesmo que, intuitivamente, quanto maior for este número, maior o poder discriminatório do classificador. Porém, nem todas as características podem ser necessárias para discriminar as classes de maneira precisa. Assim, incluí-las no modelo de classificação pode até mesmo gerar resultados inferiores aos que seriam obtidos se elas fossem removidas (HAND; MANNILA; SMYTH, 2000).

A seleção de características pode ser vista como um processo de busca, onde o algoritmo utilizado deve encontrar, em um conjunto de características, um subconjunto com a melhor eficiência no processo de classificação, ou seja, esta etapa visa reduzir o número de características, eliminando aquelas que apresentam redundância. Em outras palavras, o objetivo desta fase é encontrar um subconjunto de características significativas, de modo a aumentar a precisão e diminuir a dimensionalidade, sem implicar na perda significativa do resultado da classificação, obtida apenas pelas medidas selecionadas (PEDRINI; SCHWARTZ, 2008).

Quando a dimensionalidade de um conjunto de dados cresce significativamente, há uma dificuldade crescente em provar o resultado estatisticamente significativo devido à escassez de dados significativos no conjunto em questão. Grandes conjuntos de dados com

o problema chamado “grande p , pequeno n ” (onde p é o número de características e n é o número de amostras) tendem a ser propensos a overfitting. Um modelo com overfit pode confundir pequenas flutuações aleatórias nos dados como sendo uma variação importante do modelo e levar a erros de classificação. Esta dificuldade também pode aumentar devido a características ruidosas. O ruído em um conjunto de dados é definido como “o erro na variância de uma variável medida”, que pode resultar de erros nas medições ou de variância natural. Os algoritmos de aprendizagem de máquinas tendem a ser afetados por dados ruidosos. Portanto, o ruído deve ser reduzido tanto quanto possível a fim de evitar a complexidade desnecessária nos modelos inferidos e melhorar a eficiência do algoritmo de reconhecimento de padrões (HIRA; GILLIES, 2015).

3.6.1 Análise Discriminante Linear

Análise Discriminante Linear (*Linear Discriminant Analysis* - LDA) é uma técnica de transformação linear comumente usada para seleção de características. Nela as informações das classes associadas a cada padrão são utilizadas para extrair linearmente os atributos mais discriminantes através do cálculo de uma combinação linear de m variáveis quantitativas, as quais mais eficientemente separam grupos de amostras em um espaço m -dimensional, fazendo com que a razão da variância intra e interclasses seja maximizada (LACHENBRUCH; GOLDSTEIN, 1979).

Nesse sentido, o problema é então reduzido a achar um vetor adequado β , conforme a Equação 8:

$$y = \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n = \beta' x \quad (8)$$

A ideia básica da LDA é determinar o quanto as classes são diferentes em relação à média de uma variável e, depois, usar essa variável para adequar um grupo para a nova amostra (LACHENBRUCH; GOLDSTEIN, 1979).

Dois métodos computacionais podem ser utilizados para determinar uma função discriminante: o método simultâneo (direto) e o método *stepwise* (HAIR et al., 2005).

A estimação simultânea envolve a computação da função discriminante, de modo que todas as variáveis independentes são consideradas juntas. Assim, a função discriminante é computada com base no conjunto inteiro de variáveis independentes, sem consideração do poder discriminatório de cada variável independente.

A estimação *stepwise* envolve a inclusão das variáveis independentes na função discriminante, uma por vez, com base em seu poder discriminatório. A abordagem *stepwise* começa escolhendo-se a melhor variável discriminatória. A variável inicial faz par então com uma das outras variáveis independentes, uma de cada vez, e a variável mais adequada para melhorar o poder discriminatório da função em combinação com a primeira variável é escolhida. As demais variáveis são escolhidas de maneira análoga. Após cada etapa de incorporação de uma variável, tem-se uma etapa em que variáveis previamente selecionadas podem ser descartadas. O procedimento chega ao final quando nenhuma variável é incluída ou descartada.

Segundo Hair et al. (2005), o conjunto reduzido de variáveis é geralmente melhor do que o conjunto completo. Diante disso, neste trabalho, as funções discriminantes são aplicadas a partir do método *stepwise* para determinar as variáveis que melhor discriminam as regiões das escavações e as regiões dos discos ópticos, criando um modelo de seleção que especifica quais são as variáveis mais significantes que devem ser utilizadas para obter o melhor resultado durante os testes.

3.7 Reconhecimento de Padrões

Um padrão é definido como tudo aquilo para o qual existe uma entidade nomeável representante, geralmente criada através do conhecimento cultural humano (LOONEY, 1997). Para Gonzalez e Woods (2002), um padrão é um arranjo de vetores de características (descritores), sendo uma classe de padrões uma família de padrões que compartilham algumas propriedades comuns. O reconhecimento de padrões por máquina envolve técnicas de atribuição de padrões às suas respectivas classes de forma automática e com a menor intervenção humana possível.

Para Pedrini e Schwartz (2008), o termo reconhecimento de padrões é empregado para determinar um mapeamento que relacione as propriedades extraídas de amostras com um conjunto de rótulos (entidade nomeável representante), apresentando a restrição de que amostras com características semelhantes devem ser mapeadas ao mesmo rótulo. Os algoritmos que estabelecem este mapeamento são denotados como algoritmos de classificação ou classificadores.

O reconhecimento de padrões envolve dois processos: classificação, onde uma amostra de uma população qualquer é particionada em grupos chamados classes; e reconhecimento,

onde uma amostra desconhecida da mesma população é reconhecida como pertencente a uma das classes criadas (LOONEY, 1997).

O processo de classificação pode ser feito de duas formas: supervisionada e não-supervisionada (PEDRINI; SCHWARTZ, 2008).

- Supervisionada: quando o classificador considera classes pré-definidas e uma etapa de treinamento deve ser executada antes da aplicação do algoritmo de classificação para que os parâmetros que caracterizam cada classe sejam obtidos;
- Não-supervisionada: quando não se dispõe de parâmetros ou informações coletadas previamente à aplicação do algoritmo de classificação e todas as informações de interesse devem ser obtidas a partir das próprias amostras a serem rotuladas. No entanto, assim como na classificação supervisionada, as amostras que compartilhem propriedades semelhantes devem receber o mesmo rótulo.

Um passo importante de um sistema de reconhecimento de padrões é pré-processar os vetores de características a fim de retirar todas as características desnecessárias. Se duas características são extremamente correlatas, elas são redundantes. Este tipo de característica pode sobrecarregar o classificador e induzi-lo a erros. Após a seleção de características de cada objeto da população, a próxima etapa é atribuir um rótulo a cada vetor de características. Os objetos são rotulados a partir do conhecimento humano. Um conjunto de amostras, com seus rótulos e características, será usado no classificador no processo de treinamento. Neste processo, o classificador busca gerar uma assinatura única para cada rótulo contido dentro do conjunto de amostras. Essa assinatura será especialmente útil no processo de reconhecimento determinando o padrão identificado e representa as características que melhor desempenham distinção entre as classes (BRAZ JUNIOR, 2014).

Finalmente, com o classificador devidamente treinado, é possível fazer o reconhecimento do padrão de um objeto que inicialmente pertence à mesma população, mas completamente desconhecido do classificador no processo de treinamento. A técnica atribuirá um rótulo a cada objeto, a partir do conhecimento prévio obtido na etapa de treinamento mesmo que o objeto não pertença a nenhuma das classes.

Este trabalho utiliza a Máquina de Vetores de Suporte, um método de classificação supervisionada, para realizar o reconhecimento de padrões de discos ópticos amostrados em imagens de fundo de olho e classificá-las em normais e glaucomatosas.

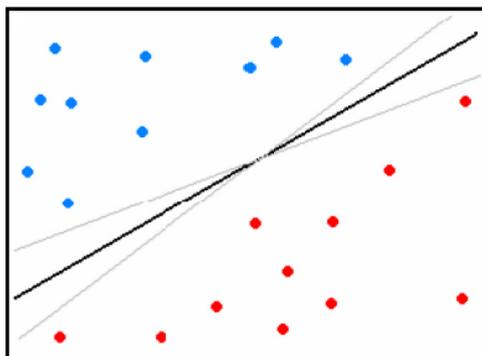
3.7.1 Máquina de Vetores de Suporte

A Máquina de Vetores de Suporte (*Support Vector Machine* - SVM) é um método de aprendizagem supervisionada usado para estimar uma função que classifique dados de entrada em duas classes. O princípio básico da SVM é a construção de um hiperplano que sirva como superfície de decisão e que maximize a margem de separação entre as classes ao mesmo tempo que otimiza os limites de generalização. Um hiperplano pode ser compreendido como uma superfície de separação de duas regiões em um espaço multidimensional, no qual o número de dimensões possíveis pode ser muito grande ou, até mesmo, infinito. Quando o conjunto de amostras é composto por duas classes separáveis, um classificador SVM é capaz de encontrar um hiperplano baseado em um conjunto de pontos, denominados vetores de suporte, o qual maximiza a margem de separação entre as classes (VAPNIK, 1998).

As SVMs são consideradas sistemas de aprendizagem que empregam um espaço de hipóteses de funções lineares em um espaço de muitas dimensões. Seus algoritmos de treinamento possuem forte influência da teoria de otimização e de aprendizagem estatística. Nos últimos anos, as SVMs vêm demonstrando sua superioridade frente a outros classificadores em uma grande variedade de aplicações (CRISTIANINI; SHAW-TAYLOR, 2000).

Na Figura 12 são mostrados, em duas dimensões, hiperplanos de separação entre duas classes linearmente separáveis. A linha central representa o hiperplano ótimo, pois separa as duas classes e mantém a maior distância possível com relação aos pontos da amostra.

Figura 12 – Separação entre duas classes através de hiperplanos.



Fonte: Rocha (2014).

Dado um conjunto de amostras de treinamento (x_i, y_i) , sendo $x_i \in \mathfrak{R}^n$ o vetor de entrada, y_i a classificação correta das amostras e $i = 1, \dots, n$ o índice de cada ponto amostral, a natureza dos dados determina como o método prossegue. Os dados podem ser linearmente separáveis, não linearmente separáveis e não separáveis.

O objetivo da classificação é estimar a função $f : \mathfrak{R}^n \rightarrow \pm 1$ que separe corretamente os exemplos de teste em classes distintas, isto é, construir o hiperplano ótimo. A etapa de treinamento estima a função $f(x) = (w * x) + b$, procurando por valores de w e b que satisfaçam a relação dada pela Equação 9,

$$y_i((w * x_i) + b) \geq 1 \quad (9)$$

onde w é o vetor normal ao hiperplano de decisão e b o corte ou distância da função em relação à origem. Os valores ótimos de w e b serão encontrados ao minimizar a Equação 10 de acordo com as restrições mostradas na equação anterior (CHAVES, 2006).

$$\Phi(w) = \frac{w^2}{2} \quad (10)$$

A SVM possibilita ainda encontrar um hiperplano que minimize a ocorrência de erros de classificação nos casos em que uma perfeita separação entre as duas classes não seja possível. Para tal, pode-se fazer a inclusão de variáveis de folga que permitem que as restrições presentes na Equação 9 sejam quebradas.

Dessa forma, de acordo com a restrição imposta na Equação 9, o problema de otimização passa a ser então de minimização da Equação 11. C é um parâmetro de treinamento que estabelece um equilíbrio entre a complexidade do modelo e o erro de treinamento e deve ser selecionado pelo usuário, isto é, C é uma penalidade para a função Φ , ξ é a variável de folga, com $\xi \geq 0$, que suaviza as restrições dadas pela Equação 12 e N é o número de amostras de entrada.

$$\Phi(w, \xi) = \frac{w^2}{2} + C \sum_{i=1}^N \xi_i \quad (11)$$

segundo

$$y_i((w * x_i) + b) + \xi_i \geq 1 \quad (12)$$

Através da teoria dos multiplicadores de Lagrange, chega-se à Equação 13, cujo objetivo passa a ser encontrar os multiplicadores de Lagrange α_i ótimos que satisfaçam a Equação 14 (CHAVES, 2006).

$$w(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j=1}^N \alpha_i \alpha_j y_i y_j (x_i, x_j) \quad (13)$$

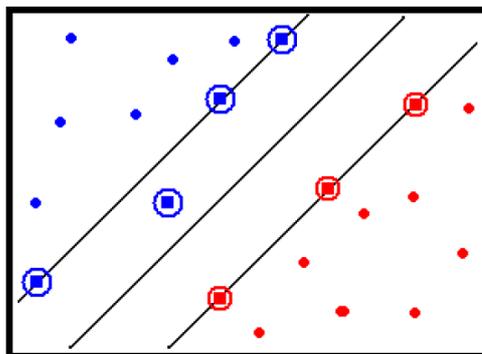
para

$$\sum_{i=1}^N \alpha_i y_i = 0, 0 \leq \alpha_i \leq C \quad (14)$$

Apenas os pontos onde a restrição dada pela Equação 9 seja exatamente igual à unidade têm correspondentes $\alpha \neq 0$. Esses pontos são chamados de vetores de suporte, pois se localizam geometricamente sobre as margens. Tais pontos têm fundamental importância na definição do hiperplano ótimo, pois os mesmos delimitam a margem do conjunto de treinamento.

Na Figura 13 são destacados os pontos que representam os vetores de suporte. Os pontos além da margem não influenciam decisivamente na determinação do hiperplano, enquanto que os vetores de suporte, por terem pesos não nulos, são decisivos.

Figura 13 – Vetores de Suporte (destacados por círculos).



Fonte: Rocha (2014).

Para que a SVM possa classificar amostras que não são linearmente separáveis, é necessária uma transformação não-linear que transforme o espaço de entrada (dados) para um novo espaço (espaço de características). Esse espaço deve apresentar dimensão suficientemente grande para que a amostra possa ser linearmente separável. Desta maneira, o hiperplano de separação é definido como uma função linear de vetores retirados do espaço de características ao invés do espaço de entrada original. Essa construção depende do cálculo de uma função K de *kernel* de um produto interno. A função K pode realizar o

mapeamento das amostras para um espaço de dimensão muito elevada sem aumentar a complexidade dos cálculos (VAPNIK, 1998).

A Equação 15 mostra o resultado da Equação 13 com a utilização de um *kernel* K .

$$w(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j=1}^N \alpha_i \alpha_j y_i y_j K(x_i, x_j) \quad (15)$$

As SVMs utilizam diferentes *kernels* para resolver problemas de espaços não-lineares. Neste trabalho é utilizada a função de base radial (*Radial Basis Function* - RBF), que é a mais comumente usada para problemas de reconhecimento de padrão desta classe. A função RBF pode ser definida pela Equação 16,

$$K(x_i, y_i) = \exp(-\gamma \|x_i - y_i\|^2) \quad (16)$$

onde $\gamma = \frac{1}{\sigma^2}$ e σ a variância.

3.8 Validação de Resultados

Esta etapa visa avaliar os resultados obtidos por uma metodologia proposta durante a etapa de classificação a partir do cálculo de métricas de desempenho.

Segundo Filho (1999), em problemas relacionados a diagnósticos da área da saúde, a estrutura básica dos testes de classificação é para determinar a efetividade do teste ao discriminar a presença ou ausência de uma doença. Neste tipo de problema existe a presença de uma variável preditora (resultado do teste) e uma variável resultante (presença ou ausência da doença).

A variável preditora do teste é geralmente analisada a partir da divisão do espaço de hipóteses em dois, definindo os critérios que confirmam ou refutam a presença da doença. A variável resultante do teste é a presença ou ausência da doença, confirmada por um teste considerado *gold standard*². Quando se avalia um teste diagnóstico, quatro situações são possíveis:

1. O teste é positivo e o paciente tem a doença - Verdadeiro Positivo (VP);
2. O teste é positivo mas o paciente não tem a doença - Falso Positivo (FP);
3. O teste é negativo e o paciente tem a doença - Falso Negativo (FN);

² Teste considerado padrão de referência da verdade com a maior exatidão na determinação de um diagnóstico.

4. O teste é negativo e o paciente não tem a doença - Verdadeiro Negativo (VN).

Na análise de imagens médicas, geralmente utilizam-se algumas estatísticas descritivas sobre os resultados dos testes para avaliar o desempenho do classificador. Neste trabalho são usadas a Sensibilidade (*SEN*), Especificidade (*ESP*) e Acurácia (*AC*) (BLAND, 2015).

A sensibilidade é definida pela proporção de pessoas com a doença de interesse que têm o resultado do teste positivo. Indica quão bom é o teste para identificar os indivíduos doentes, sendo dada pela Equação 17,

$$SEN = \frac{VP}{VP + FN} \quad (17)$$

A especificidade de um teste é a proporção de pessoas sem a doença que têm o teste negativo. Indica quão bom é o teste para identificar os indivíduos saudáveis, obtida pela Equação 18,

$$ESP = \frac{VN}{VN + FP} \quad (18)$$

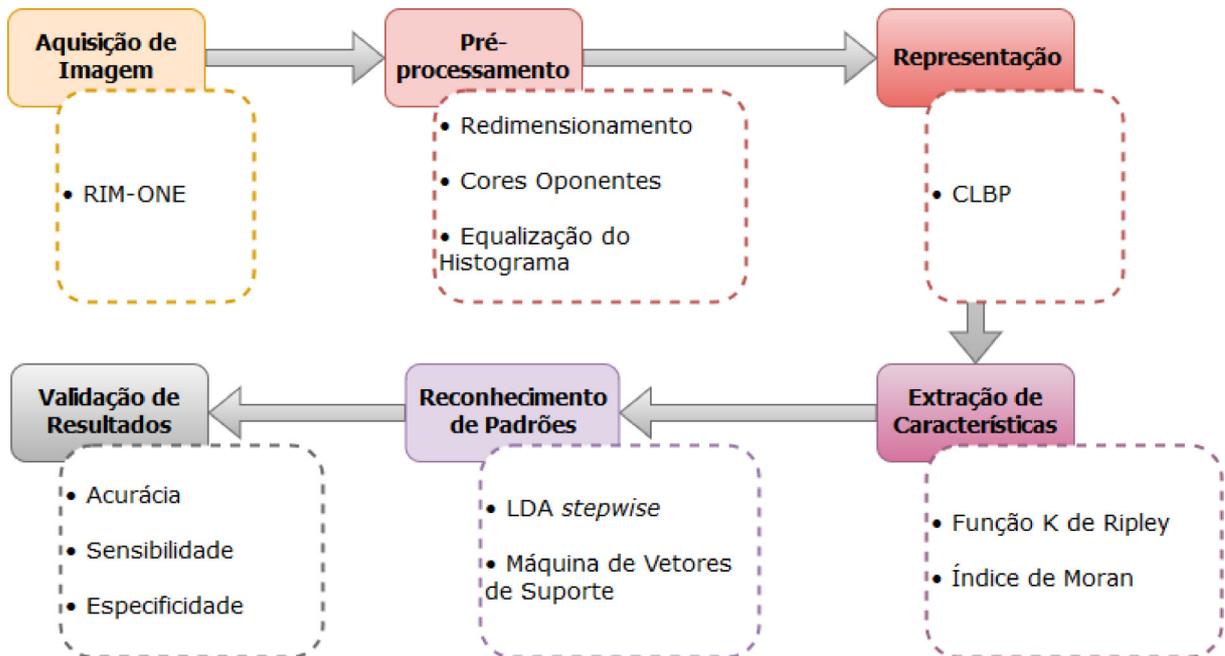
A acurácia (ou precisão) é a taxa de classificação correta de um teste, sendo definida pela razão entre o número de casos da amostra em estudo que foram classificados corretamente e o número total de casos na amostra em estudo, dada pela Equação 19,

$$AC = \frac{VP + VN}{VP + FP + VN + FN} \quad (19)$$

4 Materiais e Métodos

Este capítulo descreve as ferramentas e procedimentos utilizados na metodologia proposta para o diagnóstico de glaucoma a partir de imagens de fundo de olho. Nas seções seguintes apresenta-se de forma detalhada a metodologia que foi dividida em seis etapas principais obedecendo a sequência mostrada na Figura 14.

Figura 14 – Etapas da metodologia proposta.



A primeira etapa consiste na aquisição de imagens. Neste trabalho utilizou-se a base de imagens pública RIM-ONE juntamente com a marcação de referência do disco óptico. A segunda etapa consiste no realce da imagem a fim de aumentar o contraste de estruturas do disco óptico a partir dos métodos das cores oponentes e equalização do histograma, explicados nas Seções 3.4.2 e 3.4.3, respectivamente. A terceira etapa consiste no processo de transformação para representação e descrição da imagem, utilizando o método Compound Local Binary Pattern (CLBP) (Seção 3.5.1). A quarta etapa consiste na extração de características de textura a partir da nova representação gerada na etapa anterior utilizando a abordagem de estatística espacial (Seção 3.5.2). Na quinta etapa, de reconhecimento de padrões, a seleção de características, quando aplicada, é realizada usando a Análise Discriminante Linear *stepwise*. A classificação supervisionada das amostras no padrão saudável ou glaucomatoso é realizada utilizando a Máquina de Vetores de Suporte

(Seção 3.7.1). E na última etapa, é realizada a validação dos resultados de acordo com as métricas de desempenho apresentadas na Seção 3.8.

4.1 Base de Imagens

Neste trabalho foi utilizada a base de imagens RIM-ONE (FUMERO et al., 2011) na sua versão 2. Esta base foi fornecida por três hospitais: Hospital Universitário de Canarias, Hospital Clínico San Carlos e Hospital Universitário Miguel Servet. Ela contém imagens de fundo de olho no formato JPEG, modelo de cor RGB, com a marcação de referência da segmentação do disco óptico fornecida por diferentes especialistas. A versão 2 da base RIM-ONE é composta por 455 imagens de retinografia separadas em duas classes (*normal* e *glaucoma and glaucoma suspicious*). A classe *normal* possui 255 imagens de olhos saudáveis. A classe *glaucoma and glaucoma suspicious* possui 200 imagens de olhos com glaucoma ou suspeitas.

A Figura 16(a) apresenta uma imagem da classe *normal* enquanto a Figura 16(b) apresenta uma imagem da classe *glaucoma and glaucoma suspicious*, ambas com a marcação do DO feita por especialista.

4.2 Extração da Região de Interesse

Visto que o objetivo deste trabalho é a caracterização da textura das estruturas do disco óptico usando CLBP e geostatística e, posteriormente, sua classificação quanto a presença ou não do glaucoma, não é utilizada a imagem completa obtida pela base, partindo-se do pressuposto que as ROIs foram extraídas (segmentadas) anteriormente. Dessa maneira, dado que o glaucoma causa alterações principalmente nas estruturas internas do DO, conforme exposto na Seção 3.2, os experimentos da metodologia proposta são aplicados somente na região do DO.

Para seleção das amostras, adota-se a seguinte abordagem: a partir das marcações realizadas por especialistas nas retinografias, são extraídos os *bounding boxes* (retângulo envolvente mínimo) tendo apenas as regiões que contêm os disco ópticos. A Figura 16 apresenta um exemplo de ROI produzida por essa abordagem.

Figura 15 – Imagens de retina contidas na base RIM-ONE com marcação do disco óptico: (a) classe *normal*, (b) classe *glaucoma and glaucoma suspicious*.

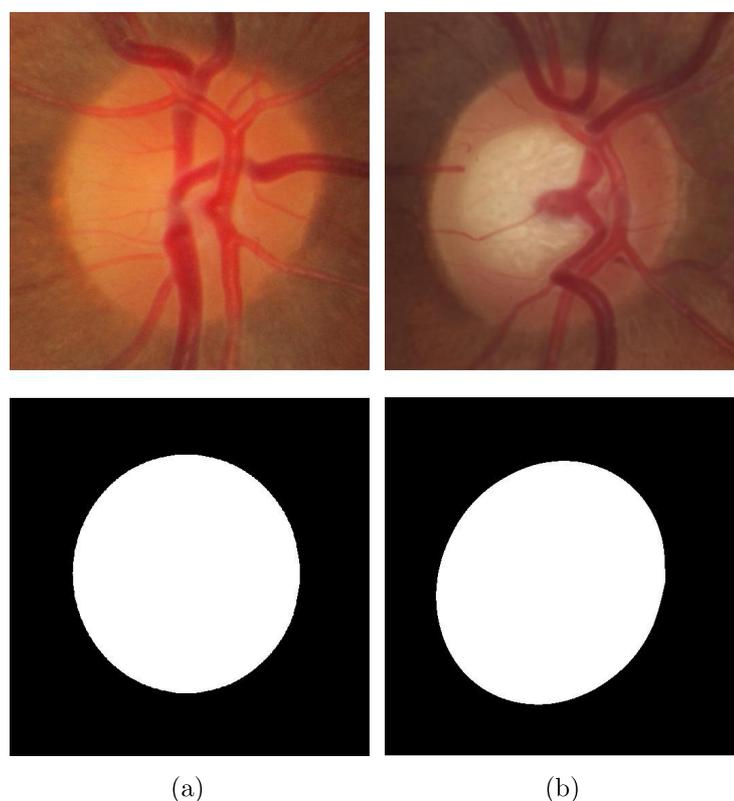
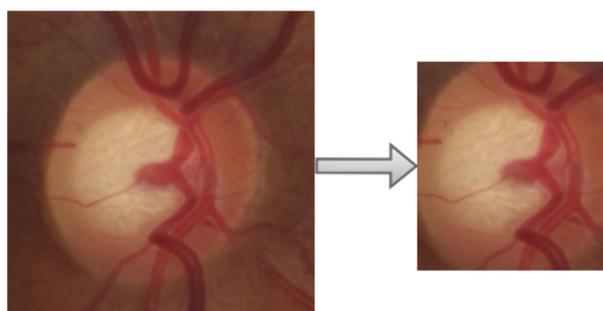


Figura 16 – Exemplo de ROI extraída da base RIM-ONE a partir da marcação feita por especialistas.



4.3 Pré-Processamento

A etapa de pré-processamento tem o objetivo de melhorar o contraste da imagem de fundo de olho na estrutura do disco óptico em relação ao fundo para promover uma melhor descrição da textura nessa região aumentando a capacidade de acerto geral da metodologia.

A imagem colorida obtida da base no modelo de cores RGB é inicialmente redimensionada para uma resolução de 240×240 *pixels* visando minimizar o custo

computacional do processamento da imagem. Em seguida, um processo de realce de estruturas é utilizado a partir do método das cores oponentes (Seção 3.4.2) gerando 3 imagens, uma para cada canal oponente que, na sequência, são submetidas à equalização do histograma (Seção 3.4.3), separadamente, para garantir um contraste uniforme em toda imagem.

Ao fim desta etapa obtêm-se 3 imagens que apresentam um considerável aumento da distinção visual de características realçadas. Na Figura 17 é exemplificada a aplicação do pré-processamento em cada canal R, G e B. Sendo apresentada em cada parte: a imagem (ROI) do canal em nível de cinza antes do pré-processamento, a imagem resultante do método das cores oponentes e a imagem equalizada com seus respectivos histogramas.

A Figura 18, por sua vez, exemplifica o resultado final da etapa de pré-processamento.

4.4 Representação da Imagem

A metodologia proposta compreende uma etapa de representação da ROI através da qual é realizada a descrição das características de textura a partir do método CLBP, conforme descrito na Seção 3.5.1, objetivando alcançar melhores resultados na etapa seguinte de extração de características.

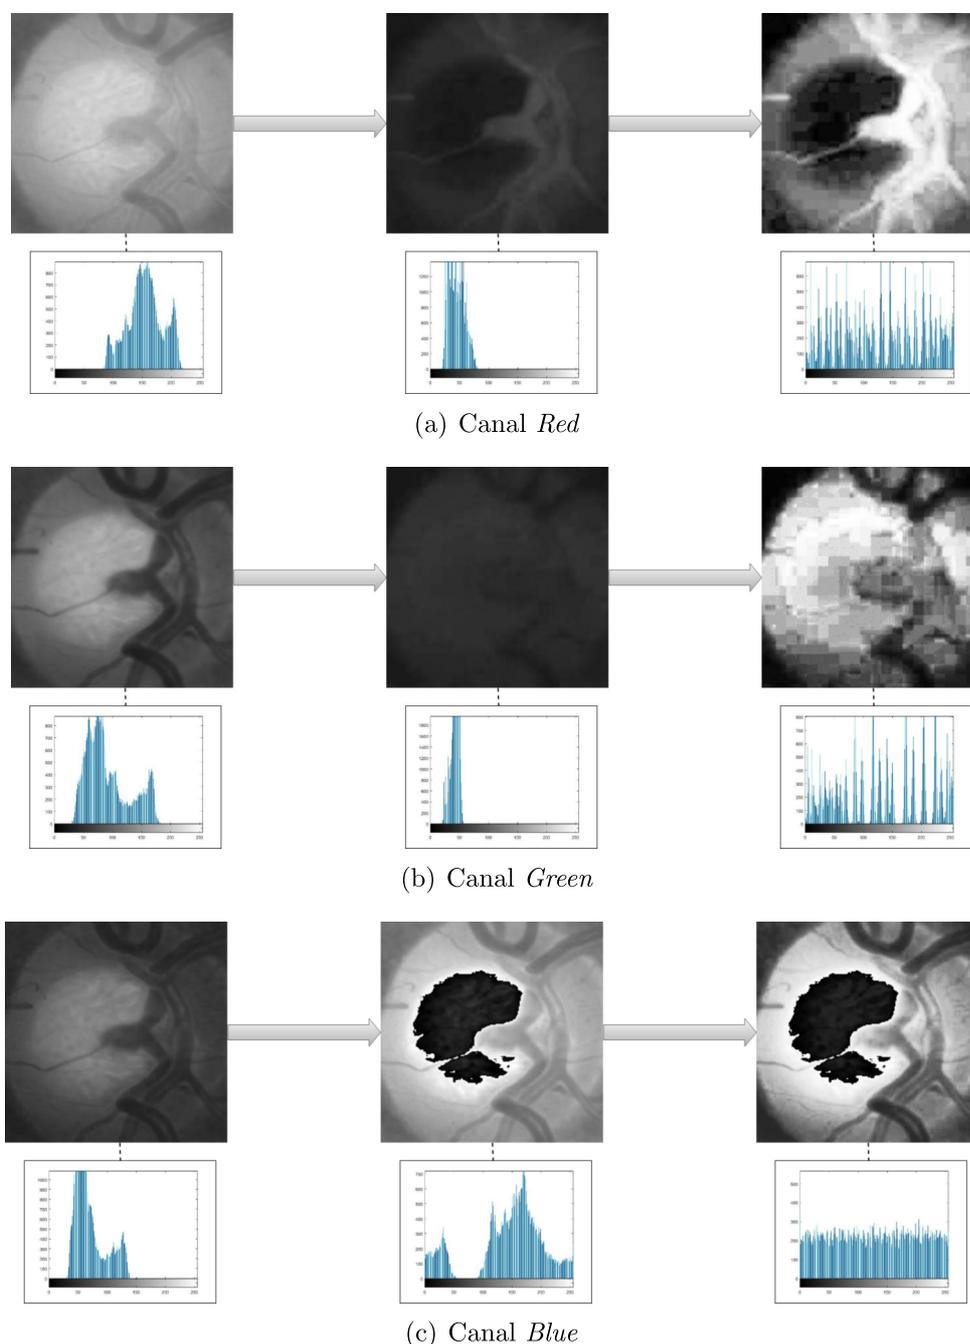
Neste trabalho utiliza-se o CLPB para representar as estruturas do disco óptico para encontrar a distribuição espacial de padrões locais de textura existentes nessa região. Após o pré-processamento, calcula-se o CLBP correspondente para a ROI de cada canal separadamente utilizando-se uma janela de tamanho 3×3 .

Esta etapa da metodologia gera duas novas representações da ROI por canal sendo uma para cada padrão sub-CLBP. A Figura 19 apresenta um exemplo do resultado da aplicação do CLBP sobre uma ROI pré-processada relativa ao canal *Red*.

4.5 Extração de Características

A etapa de extração de características da metodologia visa produzir medidas descritivas das imagens, as quais formarão os vetores de características que serão utilizados na etapa de classificação.

Figura 17 – Etapas do pré-processamento em cada canal de uma imagem glaucomatosa com seus respectivos histogramas: (a) canal *Red*, (b) canal *Green*, (c) canal *Blue*.



Este trabalho utiliza uma abordagem baseada em estatística espacial, apresentada na Seção 3.5.2, para descrever as características de textura sobre as imagens codificadas em CLBP. Para isso são aplicadas funções geoestatísticas analisadas a partir de decomposição espacial realizada sobre a ROI. As funções utilizadas são: função K de Ripley local (Seção 3.5.3) e Índice de Moran local (Seção 3.5.4).

Figura 18 – Resultado do pré-processamento na ROI.

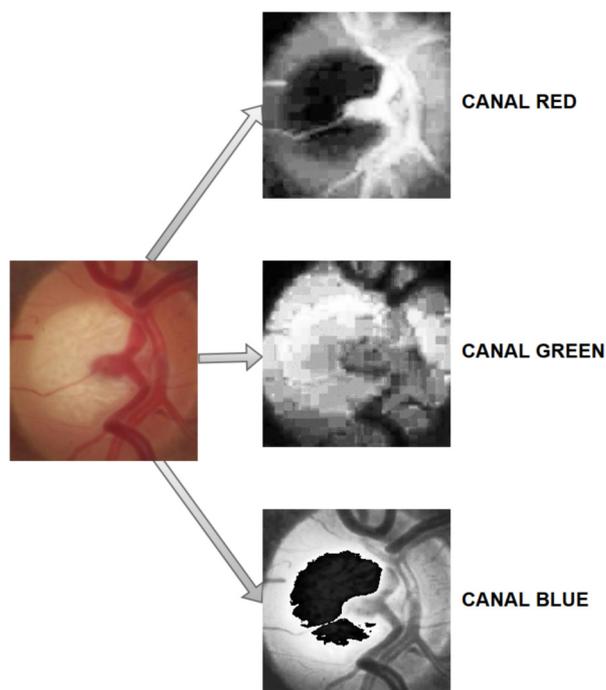
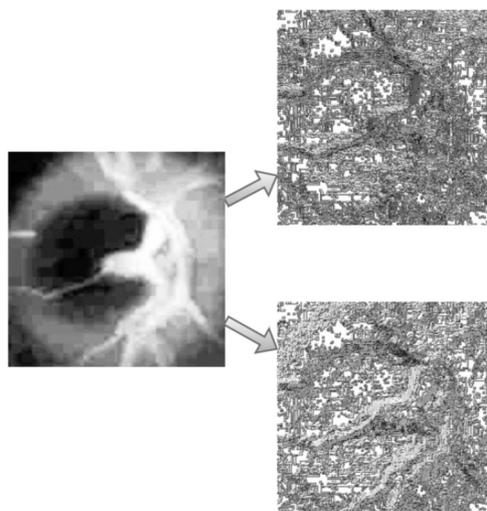


Figura 19 – Resultado da aplicação do CLBP.



Na sequência, são detalhados os procedimentos e técnicas utilizadas para extração de características de regiões do DO (ROI) amostradas em imagen de fundo de olho.

4.5.1 Decomposição Espacial

Neste trabalho, após a etapa de representação das amostras, aplica-se um processo de agrupamento de características locais, similar ao utilizado em BRAZ JUNIOR (2014). Este processo objetiva melhorar a última etapa e, dessa forma, aumentar o desempenho

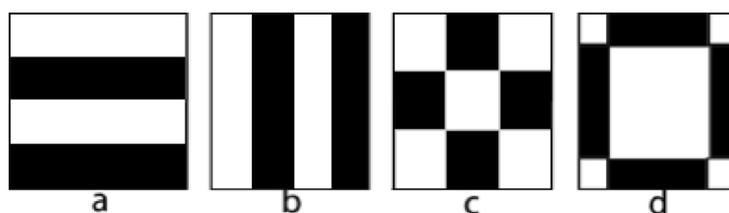
da etapa de reconhecimento. Assim, a análise é conduzida realizando-se uma divisão espacial da ROI para quantificar os descritores da etapa seguinte associando-os a recortes delimitados dentro da área como um todo, preservando associações espaciais de vizinhança e concentração.

A região original é decomposta em recortes: retangular (Horizontal, Vertical, Janelas e Janelas Centralizadas), Circular, Anel e Diagonais. Na decomposição retangular são utilizados quatro padrões específicos onde cada um representa uma divisão distinta da região original da seguinte forma:

- Horizontal: a região é subdividida em recortes horizontais de mesma área;
- Vertical: a região é subdividida em recortes verticais de mesma área;
- Janelas: união das divisões Horizontal e Vertical, provocando a subdivisão da região em janelas de mesma área;
- Janelas Centralizadas: alteração da divisão em janelas para preservar uma área maior central em detrimento das bordas.

A Figura 20 exemplifica cada uma das abordagens de decomposição retangular. As quantidades de recortes horizontais, verticais e de janelas são configuráveis. Neste trabalho são utilizados 4 recortes horizontais e verticais, e ainda 9 janelas. A quantidade de recortes da abordagem de janelas centralizadas é fixa e igual a 9, sendo que o recorte central representa 50% da área total da região. O objetivo dos recortes retangulares é de capturar características distribuídas diferenciadamente em posições horizontais e verticais da imagem.

Figura 20 – Divisões retangulares aplicadas à região para preservar associações locais antes da aplicação de métodos para extração de características: (a) horizontal, (b) vertical, (c) janelas e em (d) janelas centralizadas.

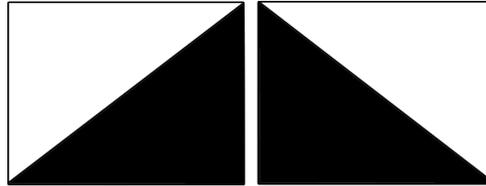


Fonte: Adaptado de BRAZ JUNIOR (2014).

A decomposição em diagonais gera sempre 4 recortes contendo cada um dos lados da matriz resultante da divisão pelas diagonais principal e secundária. O objetivo é capturar

características de contraste entre as quatro regiões de canto originais. Esse processo é ilustrado pela Figura 21.

Figura 21 – Representação da decomposição em diagonais.



Fonte: BRAZ JUNIOR (2014).

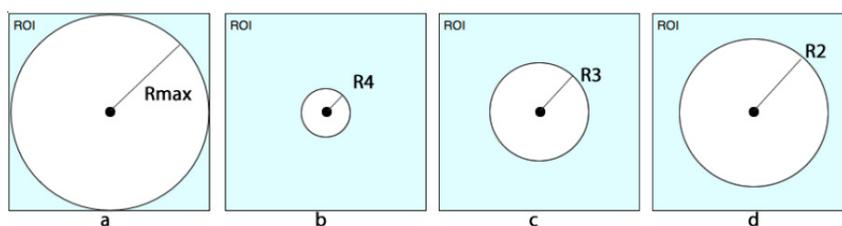
A decomposição circular cria novas representações de regiões circulares e concêntricas da região. O objetivo é analisar o crescimento da distinção de regiões concêntricas tendo em vista que o disco óptico e sua escavação possuem formato circular. A Figura 22 exemplifica a representação dessa decomposição.

O raio de cada círculo é calculado baseado em um raio máximo (R_{max}), sendo este determinado pela dimensão da ROI, isto é, pela menor distância do centro em relação às bordas da ROI. A partir do raio máximo, calculam-se os demais raios através de alteração de proporção em relação ao primeiro e são definidos por:

$$R_i = \frac{R_{max}}{i} \quad (20)$$

onde $i = 1, 2, 3, \dots, n$ e n é quantidade de raios escolhidos pela aplicação. Neste trabalho, adota-se $n = 5$. A escolha deste parâmetro foi realizada através de testes empíricos onde valores menores normalmente reduziam o desempenho da decomposição e valores maiores não incluíam características suficientes para serem adotados. Portanto, tal quantidade de raios provê uma divisão das ROIs em círculos de tamanhos que crescem gradativamente em variação relativamente pequena de raio, mas não unitária.

Figura 22 – Representação da decomposição em círculos.



Fonte: BRAZ JUNIOR (2014).

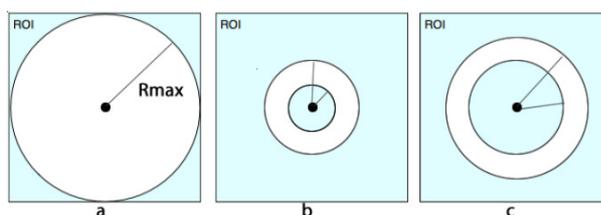
A decomposição em anéis segue o mesmo princípio da decomposição em círculos. A diferença básica é que, por estarem em formato de anéis, as regiões não possuem intersecção de área embora compartilhem o mesmo centro. Assim, o raio máximo do anel interno é utilizado como um raio mínimo para o próximo anel. Seguindo o mesmo cálculo do raio máximo realizado na decomposição em círculos expresso na Equação 20, as Equações 21 e 22 obtêm os raios mínimos e máximos dos anéis, respectivamente,

$$R_{min}(i) = \frac{R_{max}}{n}i, \text{ e} \quad (21)$$

$$R_{max}(i) = \frac{R_{max}}{n}(i + 1), \quad (22)$$

onde $i = 1, 2, 3, \dots, n$ e n é a quantidade de raios escolhidos pela aplicação. Para esta metodologia adota-se $n = 5$, seguindo o mesmo princípio utilizado na decomposição em círculos. A Figura 23 apresenta a representação desta decomposição em anéis.

Figura 23 – Representação da decomposição em anéis.



Fonte: BRAZ JUNIOR (2014).

Cada decomposição gera recortes individualizados que serão submetidos à extração de características através da análise de textura realizada pelas funções geostatísticas, descrita na seção seguinte.

Por se tratar de muitos recortes, foi utilizada a mesma convenção de agrupamento das decomposições sugerida em (BRAZ JUNIOR, 2014) objetivando-se diminuir a quantidade de bases de características geradas. Definida por:

- ANEL: contendo as extrações em anéis;
- CIRC: contendo as extrações circulares;
- HVDJ: contendo as extrações resultantes dos processos retangulares e diagonais em conjunto.

4.5.2 Índices Geoestatísticos

Após a etapa de decomposição, cada região é individualmente descrita usando os índices de geostatística fundamentados na Seção 3.5.2 de forma independente e também em conjunto. Nesse contexto, a análise geostatística é aplicada sobre o padrão local binário codificado através de CLBP seguindo uma das abordagens de decomposição espacial.

Os índices geoestatísticos analisam a textura da imagem/canal. Esta análise é realizada através da quantificação da autocorrelação espacial entre os valores dos *pixels* individuais obtidos em pares. Estes pares de *pixels* são formados de tal maneira que o primeiro representa o ponto de referência e o outro é o ponto analisado. A maioria dos *pixels* eventualmente é tomada como ponto de referência.

Nesse sentido, a análise de padrões de pontos espaciais é uma ferramenta importante para examinar em detalhes a distribuição de pontos discretos, como *pixels* em uma imagem, mapeados para coordenadas cartesianas (x, y) em uma região de interesse.

Os índices geoestatísticos utilizados para a análise são: função K de Ripley Local (Seção 3.5.3) e Índice de Moran Local (Seção 3.5.4). Nesta metodologia, o aspecto local do índice é tratado como sendo a intensidade de cinza de referência a ser quantificado nas amostras. Assim, a análise é realizada para um conjunto de pontos de uma determinada intensidade de cinza (padrão especial) independente dos demais.

O procedimento adotado é semelhante para os dois índices utilizados. Para a análise, assume-se que cada intensidade de cinza possui pontos distribuídos ao longo da imagem. Aqueles pontos que possuem distribuição igual a zero são desconsiderados para o cálculo.

O primeiro passo, portanto, é escolher entre os pontos que pertencem a uma determinada intensidade aquele que será o ponto de referência. Isto é realizado através do cálculo do centro geométrico, ou centro de gravidade, da distribuição dos pontos. O centro geométrico é estimado através das médias aritméticas das coordenadas espaciais dos pontos referentes aos eixos de x e y . Após isso, este ponto central é materializado para um ponto existente na imagem a partir do ponto que esteja mais próximo do ponto central. Para este cálculo é utilizada a distância euclidiana.

Para a criação do Vetor de Características (VC), que representa a assinatura da amostra, foram extraídas quantidades variadas de características por amostra/canal de acordo com a abordagem de decomposição local espacial.

Durante a análise dos índices geoestatísticos, cada recorte de amostragem — seja ele retangular, circular ou em anéis — gera uma observação para cada nível de cinza presente na ROI codificada em CLBP. Nas abordagens de decomposição retangular, utiliza-se 4 recortes horizontais e verticais, 9 recortes em janelas e 9 recortes em janelas centralizadas. Assim, o modelo gera para cada decomposição retangular 1024 características (4 recortes \times 256 níveis de cinza), para as abordagens de decomposição em janelas e janelas centralizadas 2304 características (9 recortes \times 256 níveis de cinza). Na decomposição diagonal são utilizados 4 recortes, gerando 1024 características (4 recortes \times 256 níveis de cinza). A decomposição HVDJ, como explicado na seção anterior, faz a união das abordagens retangulares e diagonais e, portanto, gera 7680 características (1024 + 1024 + 2304 + 2304 + 1024). E, por fim, nas abordagens de decomposição espacial em círculos e em anéis são utilizados 5 raios. Sendo assim, o modelo gera 1280 características (5 raios \times 256 níveis de cinza).

Tendo em vista que este processo é realizado 2 vezes, uma para cada um dos códigos CLBPs da amostra, explicados na Seção 3.5.1, é seguido pela concatenação de ambas as análises resultantes para gerar a base de características. A dimensão desta é, portanto, duplicada antes de ser submetida à próxima etapa de reconhecimento de padrões. A tabela 1 apresenta o quantitativo total — multiplicado pelos 2 CLBPs — de características extraídas por abordagem de decomposição para cada imagem de retinografia da base.

Tabela 1 – Quantidade total de características extraídas por abordagem de decomposição.

Abordagem	Nº total de características
ANEL	$2 \times (5 \times 256) = 2560$
CIRC	$2 \times (5 \times 256) = 2560$
HVDJ	$2 \times ((4 + 4 + 4 + 9 + 9) \times 256) = 15360$

Além disso, por se tratarem de funções geoestatísticas relacionadas, a metodologia proposta também estuda o desempenho do uso conjunto dessas funções para realizar a extração de características de textura. A abordagem utilizada é a mesma já descrita. A única diferença para a abordagem conjunta das medidas geoestatísticas é a concatenação mais uma vez dos VCs.

4.6 Seleção de Características

Define-se por base de características o conjunto de vetores de características resultantes de cada análise de textura produzido na etapa de extração de características, descrita na seção anterior.

As bases de características geradas a partir de análises geoestatísticas baseadas em decomposição espacial possuem alta dimensionalidade. Por esta razão, a técnica Análise Discriminante é aplicada para reduzir o número de variáveis incluídas no estudo de modo a determinar aquelas variáveis significantes que melhor discriminam as classes saudável e glaucomatosa.

Neste trabalho, a seleção de características é realizada utilizando o algoritmo de ascendência de Hill, através da interface *Greedy Stepwise* (VAFAIE; IMAM, 1994) contida no WEKA (FRANK; HALL; WITTEN, 2016). O método *stepwise*, descrito na Seção 3.6.1, faz a inclusão das variáveis independentes na função discriminante, uma por vez, com base em seu poder discriminatório. Dessa forma, este método pretende fornecer um conjunto reduzido de variáveis para o modelo. Tal procedimento objetiva, portanto, eliminar as variáveis redundantes e, assim, obter um melhor desempenho do classificador na próxima etapa.

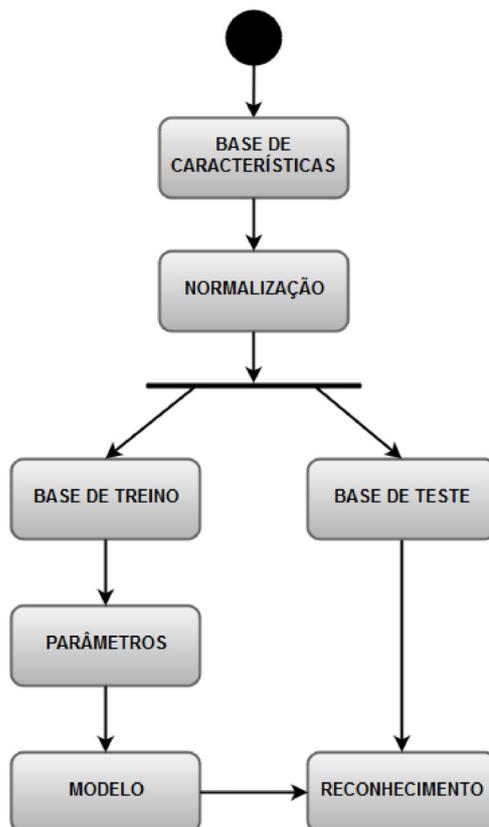
4.7 Reconhecimento de Padrões

A etapa de reconhecimento de padrões visa analisar se as características produzidas na etapa de extração de características são capazes de diferenciar os padrões saudável e glaucomatoso das imagens de fundo de olho.

Esta etapa consiste em classificar as amostras quanto a presença ou não do glaucoma utilizando técnicas de reconhecimento de padrões (Seção 3.7). Para atingir este objetivo a Máquina de Vetores de Suporte (Seção 3.7.1) é utilizada submetendo-se as características de textura obtidas pelas funções geoestatísticas (Seção 3.5.2) após a etapa de seleção de características feita pela Análise Discriminante *stepwise* (Seção 3.6.1). O fluxo de atividades seguido durante a realização dos experimentos durante esta fase é ilustrado na Figura 24.

De posse da base de características recomenda-se fazer uma normalização das diferentes características para uma faixa de valores comuns, como -1 a 1, para facilitar

Figura 24 – Fluxo de atividades da etapa de reconhecimento de padrões.



a convergência do classificador SVM durante o treinamento e também para evitar que alguma característica se sobressaia em relação às demais (FACELI et al., 2011). Para esse fim, foi utilizado *svm-scale* presente no pacote LIBSVM.

Em seguida, para efeito de validação dos resultados, a base de características é dividida em dois grupos: base treino e base de teste. Neste trabalho, foram adotados vários critérios de configuração da divisão das bases de treino e teste nos experimentos realizados. Conforme mostra a Tabela 2, as proporções utilizadas foram: 50/50, 60/40, 70/30 e 80/20. Para cada configuração, o teste foi repetido 5 vezes de forma aleatória, objetivando verificar se o desempenho do método de classificação sofre variações significativas à medida que as amostras para treinamento aumentam gradativamente e as amostras para teste diminuem.

O SVM é utilizado com a função de base radial (RBF). Existem dois parâmetros que devem ser configurados quando se utiliza esta função nos experimentos: C e γ , que representam o custo e o grau de complexidade da função de mapeamento, respectivamente. Os parâmetros foram estimados em cada experimento sobre os dados de treinamento utilizando o *script* em *python grid.py* presente no pacote LIBSVM. Este *script* busca, através de validação cruzada, a melhor combinação destes parâmetros para a base que

retorne como resposta o melhor percentual de acerto total sobre as amostras de treino e teste.

Tabela 2 – Critério de divisão treino/teste utilizado na etapa de classificação.

Configuração	Treino	Teste
1 (50/50)	50	50
2 (60/40)	60	40
3 (70/30)	70	30
4 (80/20)	80	20

Ao final da etapa de treinamento é produzido o modelo de vetores de suporte utilizados pela SVM para classificar as amostras de teste. Sendo a base de testes completamente desconhecida do modelo de classificação gerado, é possível simular condições reais de diagnóstico da doença em que as amostras de teste representariam amostras novas.

Dessa maneira, com o modelo gerado, é possível realizar a etapa de reconhecimento de padrões com as amostras de teste separadas. Como resultado, a SVM gera uma base de predições contendo apenas os rótulos (classes) das amostras de teste.

4.8 Validação

Após o reconhecimento de padrões para o diagnóstico do glaucoma baseado na análise de textura através da SVM, é necessário validar os resultados produzidos nos experimentos a partir da metodologia proposta e discutir possíveis melhorias.

Neste trabalho, são utilizadas medidas estatísticas comumente relacionadas a problemas de processamento de imagens e reconhecimento de padrões na área médica (ACHARYA et al., 2015)(ALI et al., 2014). As estatísticas, descritas na Seção 3.8, são: acurácia, sensibilidade e especificidade. O uso dessas métricas visa medir o desempenho da metodologia e também destacar os pontos positivos e negativos para que se possa alcançar melhorias em trabalhos futuros.

5 Resultados e Discussão

Neste capítulo são apresentados e discutidos os resultados obtidos pela metodologia proposta para diagnóstico de glaucoma por meio de imagens de retinografias. Primeiramente, é apresentada a infraestrutura computacional utilizada para obtenção dos resultados. E no final do capítulo, é feita uma comparação dos resultados produzidos com outros trabalhos publicados, visando contextualizar a relevância da pesquisa desenvolvida neste trabalho.

Para a implementação dos métodos utilizados nas fases de pré-processamento e representação da imagem baseada em análise de textura, descritos na Seção 4.3 e na Seção 4.4, respectivamente, foi utilizada a linguagem C++, através do ambiente de desenvolvimento Microsoft Visual Studio 2013. A manipulação das imagens foi realizada através da biblioteca OpenCV (BRADSKI, 2000), disponível gratuitamente na Internet. A biblioteca pode ser usada por várias linguagens, entre elas a linguagem C++, fornecendo classes e funções para carregar, salvar, processar e exibir imagens possuindo grande portabilidade, passível de ser utilizada em ambientes Unix, Windows e MacOS.

Os algoritmos das funções geoestatísticas utilizadas neste trabalho na fase de extração de características (Seção 4.5) foram implementados utilizando a linguagem Java, que se caracteriza pela sua simplicidade, disponibilidade de recursos e independência de plataforma, através do ambiente de desenvolvimento NetBeans 8.2.

O classificador SVM, utilizado para o reconhecimento de padrões (Seção 4.7) foi obtido através da biblioteca LIBSVM (CHANG; LIN, 2011), disponível gratuitamente na Internet. Para selecionar as características mais significantes (Seção 4.6) foi utilizado o pacote de *software* WEKA (FRANK; HALL; WITTEN, 2016).

Durante o desenvolvimento e testes da pesquisa foram utilizados computadores com as configurações: Intel Core i5, 8GB de memória, 1TB de HD, Windows 10; Intel Core i7, 4GB de memória, 1TB de HD, Windows 7.

5.1 Resultados Obtidos

Os experimentos foram realizados usando a base de imagens pública RIM-ONE constituída por 455 imagens (255 da classe *normal* e 200 da classe *glaucoma and glaucoma suspicious*).

Inicialmente as imagens coloridas foram decompostas através do modelo de cores RGB gerando três imagens, uma para cada canal (*Red*, *Green* e *Blue*). Em seguida, essas imagens foram submetidas, separadamente, aos processos de realce de contraste, são elas cores oponentes e equalização do histograma, descritos na Seção 4.3, a fim de dar ênfase às estruturas internas do disco óptico. Na sequência, as imagens resultantes foram representadas pelo padrão de textura CLBP (Seção 4.4). As características foram extraídas por meio de funções geoestatísticas (Seção 4.5), analisadas de forma independente e também em conjunto através de diferentes abordagens de decomposição espacial. Para classificação foi utilizada a máquina de vetores de suporte. Conforme descrito anteriormente na Seção 4.7, em cada proporção de treino/teste foram realizadas 5 repetições. Os parâmetros utilizados para cada teste foram estimados através de validação cruzada.

Foram extraídas pelos índices geoestatísticos um total de 2560 características através das abordagens circular (CIRC) e em anéis (ANEL) de decomposição espacial por cada imagem de retinografia. A partir da abordagem retangular (HVDJ), por sua vez, são extraídas um total de 15360 características pelos índices, assim como explicado na Seção 4.5.2.

Os resultados estão organizados em seções de acordo com a técnica de extração de característica utilizada. São apresentados para todos os experimentos as médias de acurácia, sensibilidade e especificidade.

5.1.1 Função K de Ripley

Foram realizados dois experimentos com a função K de Ripley. No primeiro, foi utilizada a classificação sem seleção de características e, no segundo, foi aplicado o algoritmo de análise discriminante *stepwise* para selecionar as características mais significantes extraídas pelo índice com base na abordagem de decomposição espacial retangular.

Os resultados produzidos pelo experimento utilizando a função K de Ripley sem a etapa de seleção de características estão listados na Tabela 3. Para este experimento, observa-se que a abordagem de decomposição espacial que apresentou melhor desempenho foi a retangular (HVDJ), alcançando médias de acurácia de 86,86%, sensibilidade de 81,66% e especificidade de 90,90% para a imagem do canal oponente *Green*. Os outros canais, *Red* e *Blue* alcançaram resultados similares.

Tabela 3 – Resultados produzidos pela Função K de Ripley a partir de diferentes abordagens de decomposição espacial

Canal/Imagem	Abordagem	Acurácia (%)	Sensibilidade (%)	Especificidade (%)
<i>Red</i>	ANEL	74,72	67,50	80,39
	CIRC	76,55	75,41	77,45
	HVDJ	85,08	81,00	88,28
<i>Green</i>	ANEL	80,21	80,00	80,39
	CIRC	75,82	71,25	79,41
	HVDJ	86,86	81,66	90,90
<i>Blue</i>	ANEL	86,86	75,00	96,10
	CIRC	83,51	77,50	88,23
	HVDJ	86,86	80,00	92,20

O experimento realizado com a utilização da função K de Ripley a partir da abordagem de decomposição espacial retangular com seleção de características *stepwise* produziu resultados com maiores taxas de acerto em comparação com o experimento anterior, sem seleção de características, como pode ser observado na Tabela 4. A abordagem de decomposição retangular foi escolhida devido a alta dimensionalidade dos vetores de características produzidos, bem como devido ao seu promissor desempenho durante a aplicação do referido índice geostatístico sem seleção das características significativas.

Tabela 4 – Resultados produzidos pela Função K de Ripley a partir da abordagem de decomposição retangular com seleção de características

Canal/Imagem	Treino/Teste	Acurácia (%)	Sensibilidade (%)	Especificidade (%)
<i>Red</i>	50/50	91,84±1,77	88,40±2,95	94,53±2,11
	60/40	90,98±2,07	87,75±3,95	93,52±1,75
	70/30	92,40±0,90	91,33±1,53	93,24±1,17
	80/20	90,54±1,09	90,50±3,60	90,58±4,44
<i>Green</i>	50/50	89,73±1,18	87,60±3,75	91,40±2,09
	60/40	88,90±2,07	85,00±4,88	91,96±2,96
	70/30	91,67±4,16	89,33±6,80	93,50±3,40
	80/20	90,98±3,95	90,50±7,15	91,37±2,88
<i>Blue</i>	50/50	89,64±2,39	86,00±2,18	92,50±3,71
	60/40	90,87±1,46	89,75±3,47	91,76±2,79
	70/30	92,11±1,72	85,66±4,03	97,14±0,60
	80/20	94,28±1,92	90,50±5,31	97,25±1,10

O melhor resultado obtido neste experimento alcançou médias de acurácia de 94,28%, sensibilidade de 90,50% e especificidade de 97,25% com desvios padrão de 1,92%, 5,31% e 1,10%, respectivamente, para a imagem do canal oponente *Blue*, usando 80% das

amostras para treinamento e o restante para teste. A seleção de características resultou em 70 variáveis nesta abordagem.

Em relação aos outros canais, os melhores resultados foram obtidos utilizando a proporção de treino/teste 70%/30%. No canal *Red*, onde a seleção de características resultou em 135 variáveis, foram atingidas médias de acurácia de 92,40%, sensibilidade de 91,33% e especificidade de 93,24% com desvios padrão de 0,90%, 1,53% e 1,17%, respectivamente. Para o canal *Green*, foram alcançadas médias de acurácia de 91,67%, sensibilidade de 89,33% e especificidade de 93,50%, com desvios padrão de 4,16%, 6,80% e 3,40%, respectivamente, a partir de 130 características selecionadas.

5.1.2 Índice de Moran

Nesta seção são apresentados os resultados obtidos utilizando o Índice de Moran. Foram realizados dois experimentos com este índice geoestatístico. Um deles utiliza toda a base de características geradas para classificação, isto é, não faz uso de seleção de características. O outro experimento é realizado a partir da aplicação do algoritmo de análise discriminante *stepwise*, para seleção de características, com base na decomposição espacial retangular.

A Tabela 5 apresenta os resultados produzidos pelo experimento utilizando o Índice de Moran sem seleção de características. A abordagem que obteve melhor desempenho utilizou o canal oponente *Green* e decomposição espacial retangular, atingindo médias de acurácia de 87,59%, sensibilidade de 86,67% e especificidade de 88,31%. Para as imagens dos demais canais, o desempenho manteve-se similar com destaque também para a decomposição retangular.

No outro experimento realizado com o Índice de Moran, utilizou-se a abordagem de decomposição espacial retangular, a base de características obtida foi submetida à seleção *stepwise* das características mais discriminantes antes de ser classificada pelo SVM. A Tabela 6 contém os resultados deste experimento. O melhor resultado foi obtido através da execução sobre a imagem do canal oponente *Red* na proporção 50%/50%, sendo as médias atingidas para acurácia de 95,08%, sensibilidade de 93,40% e especificidade de 96,40% com desvios padrão de 0,39%, 2,99% e 1,95%, respectivamente. A seleção de características resultou em 188 variáveis.

Tabela 5 – Resultados produzidos pelo Índice de Moran a partir de diferentes abordagens de decomposição espacial

Canal/Imagem	Abordagem	Acurácia (%)	Sensibilidade (%)	Especificidade (%)
Red	ANEL	80,54	80,25	80,78
	CIRC	74,68	72,00	76,77
	HVDJ	86,92	84,00	89,22
Green	ANEL	78,90	77,50	80,00
	CIRC	72,09	70,25	73,53
	HVDJ	87,59	86,67	88,31
Blue	ANEL	85,98	81,66	89,35
	CIRC	75,82	74,50	76,86
	HVDJ	86,56	83,66	88,83

Na aplicação do experimento no canal *Green*, fez-se a seleção de características resultando em 203 variáveis. O melhor resultado deste canal foi obtido na proporção 80%/20% com médias de acurácia de 92,74%, sensibilidade de 88%, especificidade de 96,47% com desvios padrão de 3,20%, 8,85% e 3,64%, respectivamente. Para o canal *Blue*, que apresentou desempenho superior ao canal *Green*, fez-se a seleção de características resultando em 84 variáveis e o melhor resultado foi obtido na proporção 70%/30% para médias de acurácia de 93,86%, sensibilidade de 90,33%, especificidade de 96,62% com desvios padrão de 1,79%, 4,40% e 2,44%, respectivamente.

Tabela 6 – Resultados produzidos pelo Índice de Moran a partir da abordagem de decomposição retangular com seleção de características

Canal/Imagem	Treino/Teste	Acurácia (%)	Sensibilidade (%)	Especificidade (%)
Red	50/50	95,08±0,39	93,40±2,99	96,40±1,95
	60/40	93,84±1,13	90,75±1,85	96,27±1,33
	70/30	92,99±1,05	92,00±1,52	93,76±1,81
	80/20	92,30±1,19	92,00±2,27	92,54±0,95
Green	50/50	91,31±1,53	85,80±4,15	95,62±0,45
	60/40	90,98±2,62	85,50±4,46	95,29±2,56
	70/30	91,82±2,48	87,33±6,42	95,32±0,75
	80/20	92,74±3,20	88,00±8,85	96,47±3,64
Blue	50/50	90,52±2,04	85,20±5,47	94,68±1,08
	60/40	93,29±1,93	88,00±3,27	97,45±1,68
	70/30	93,86±1,79	90,33±4,40	96,62±2,44
	80/20	93,62±3,36	89,00±6,76	97,25±1,80

5.1.3 Função K de Ripley em conjunto com Índice de Moran

Nesta seção são apresentados os resultados obtidos pelo cálculo dos índices geostatísticos K de Ripley e Moran em conjunto. Estes experimentos foram realizados sem a etapa de seleção de características. A Tabela 7 demonstra os resultados obtidos pelo experimento que tem como objetivo avaliar a influência entre as duas medidas quando aplicadas simultaneamente.

Como pode ser observado, pela Tabela 7, o melhor resultado obtido pelo experimento obteve 87,25% de acurácia, 89,5% de sensibilidade e 85,49% de especificidade usando a decomposição retangular sobre o canal *Blue*. Este resultado evidencia mais uma vez a superioridade desta abordagem de decomposição espacial na discriminação das características de textura das imagens de retina.

Tabela 7 – Resultados produzidos pela Função K de Ripley em conjunto com Índice de Moran a partir de diferentes abordagens de decomposição espacial

Canal/Imagem	Abordagem	Acurácia (%)	Sensibilidade (%)	Especificidade (%)
<i>Red</i>	ANEL	80,76	85,00	77,45
	CIRC	77,47	76,25	78,43
	HVDJ	84,64	76,00	91,40
<i>Green</i>	ANEL	79,12	77,50	80,39
	CIRC	76,92	73,75	79,41
	HVDJ	85,40	81,66	88,31
<i>Blue</i>	ANEL	85,40	73,33	94,80
	CIRC	81,31	72,50	88,23
	HVDJ	87,25	89,50	85,49

5.2 Discussão

Analisando todos os resultados obtidos com os índices geostatísticos nos experimentos sobre os três canais oponentes RGB, observa-se que a abordagem de decomposição espacial retangular (HVDJ) se mostrou mais eficiente que os outros tipos de abordagens testadas para discriminar corretamente as características de textura a partir de estatística espacial em retinografias. Acredita-se que a superioridade desta abordagem de decomposição seja pela razão da análise de textura levar em consideração um número maior de variáveis significantes do que a circular e em anéis.

É possível observar que embora as duas medidas geoestatísticas estudadas tenham produzido bons resultados, sem seleção de características, os experimentos com o Índice de Moran obtiveram um melhor desempenho alcançando uma taxa de acerto de 87% sobre o canal *Green* a partir da decomposição espacial retangular (Tabela 5). No entanto, a seleção de características aplicada sobre a base de características gerada pelos índices geoestatísticos, utilizados separadamente, foi decisiva para o desempenho da metodologia proposta, com destaque para o Índice de Moran, apresentando melhores resultados em todas as abordagens de decomposição espacial se comparadas com a aplicação da metodologia sem seleção de características. Neste contexto, a proporção 50%/50% atingiu os melhores desempenhos com médias de 95% de acurácia, 93% de sensibilidade e 96% de especificidade (Tabela 6). Desta forma, os índices geoestatísticos, mais especificamente o Índice de Moran, em conjunto com SVM, podem ser então considerados eficientes na diferenciação dos padrões glaucoma e saudável.

Também é necessário destacar que houveram diferenças entre as médias de sensibilidade e especificidade, que embora pequenas, significam que as características produzidas discriminam melhor o padrão saudável nas imagens. Essa performance pode ser justificada devido a uma particularidade da base RIM-ONE. Uma vez que a base de teste é escolhida aleatoriamente, ela pode ser composta por imagens que confundam o classificador, devida a natureza da classe *Glaucoma and Glaucoma Suspicious* possuir imagens de casos de pacientes em vários estágios distintos de glaucoma, inicial ou suspeito a avançado, assim algumas imagens com leve quadro da patologia possuem características semelhantes com as imagens contidas na classe *Normal*. Tais fatores podem ser determinantes para uma melhor discriminação entre as classe saudável e glaucoma, conforme ficou evidenciado pelo desempenho superior da especificidade nos experimentos.

Ainda em relação ao experimento de melhor desempenho, observa-se que apesar de ser incomum a ocorrência do melhor resultado se apresentar na configuração 50%/50% para treino/teste, pode-se considerar como possível interpretação que na divisão aleatória para as proporções que usam menos casos de testes há uma maior probabilidade da base de teste ser formada com mais casos suspeitos de glaucoma e assim obter menor desempenho na classificação. Em contrapartida, para as proporções com mais testes esta base pode se tornar mais heterogênea em todas as cinco divisões e desta forma o desempenho se torna mais uniforme como mostra o desvio padrão (ver Tabela 6).

Entre os experimentos realizados com a combinação dos índices geoestatísticos observa-se que apesar de terem produzido o dobro de características, esse aumento dimensional não refletiu nos resultados encontrados que se apresentaram abaixo do esperado. Dado esse que pode ter como possível explicação a concatenação de variáveis que se mostraram redundantes prejudicando assim a tarefa do classificador para discriminar as características de textura das imagens.

5.3 Comparação com outros trabalhos

Nesta seção é apresentada uma análise comparativa entre os resultados produzidos pela metodologia proposta e os resultados apresentados por outros trabalhos relacionados, mencionados no Capítulo 2. Esta comparação não é uma tarefa simples, devido os trabalhos utilizarem diferentes metodologias, base de imagens e número de amostras empregadas nos testes. Contudo, como pode ser verificada na Tabela 8, a metodologia proposta apresenta resultados mais elevados ou quase equivalentes em comparação com os outros trabalhos. Entretanto, é possível estabelecer algumas conclusões, listadas em seguida.

Entre os trabalhos que utilizam a mesma base pública de imagens, RIM-ONE, é importante destacar que nenhum deles alcançou desempenho superior ao desta dissertação. Observa-se ainda que o trabalho de Raja e Gangatharan (2015) alcançou um resultado semelhante de 95% de taxa de acerto, no entanto não utilizou a base completa (455 imagens), apenas 158 imagens.

Sobre os trabalhos que utilizaram bases privadas nos experimentos destaca-se que embora alguns deles tenham atingido melhores resultados que os obtidos neste trabalho, a maioria utilizou um menor número de amostras. O trabalho de Maheshwari, Pachori e Acharya (2017) obteve o resultado mais significativo entre todos, 98,33% de acurácia, utilizando 60 imagens de uma base privada, em contrapartida quando a mesma metodologia é aplicada à base RIM-ONE atingiu somente 81,33%. Entre os demais trabalhos que utilizaram essa categoria de base de imagens figuram Mookiah et al. (2012), que utilizaram igualmente 60 imagens, Sakthivel e Narayanan (2015), 124 imagens, e Ali et al. (2014), 41 imagens. Os trabalhos de (MAHESHWARI et al., 2017) e Acharya et al. (2017) atingiram resultados superiores, estes porém testaram seus métodos em um número maior de amostras que o alcançado pela metodologia proposta neste trabalho, sendo 488 e 702 imagens, respectivamente.

Diante disso, é possível interpretar que a metodologia proposta ocupa posição de destaque na literatura, utilizando o Índice de Moran, obtendo um expressivo resultado para acurácia de 95,08%, sensibilidade de 93,4% e especificidade de 96,4%. Sobre a função K de Ripley, ainda que tenha alcançado desempenho menor em relação ao Índice de Moran, a diferença de resultados foi muito pequena, e se comparado com os trabalhos que utilizaram a mesma base e quantidade de amostras, nota-se que alcançou melhor resultado no diagnóstico de glaucoma.

Por fim, outro ponto que merece ênfase, é que neste trabalho é realizada uma análise detalhada dos resultados por meio das médias obtidas de acurácia, sensibilidade e especificidade, isto é, não são considerados apenas os testes isolados o que garante verificar a consistência dos resultados produzidos para discriminação de padrões em imagens de retinografias.

Tabela 8 – Comparação dos trabalhos relacionados.

Trabalho	Base	Amostra	AC(%)	SEN(%)	ESP(%)
Maheshwari, Pachori e Acharya (2017)	Privada	60	98,33	100	96,67
	RIM-ONE	455	81,32	78,99	83,14
Acharya et al. (2017)	Privada	702	95,73	96,24	93,71
Sakthivel e Narayanan (2015)	Privada	124	95,45	95,45	95,45
	Privada	488	95,19	93,62	96,71
Maheshwari et al. (2017)	Privada	60	98,33	100	96,67
	RIM-ONE	455	81,63	—	—
Ali et al. (2014)	Privada	41	95,1	96,4	92,3
Mookiah et al. (2012)	Privada	60	95	93,33	96,67
Raja e Gangatharan (2015)	RIM-ONE	158	95	—	—
Acharya et al. (2015)	Privada	510	93,1	89,7	96,2
Claro et al. (2016)	RIM-ONE	169	93,03	—	—
Dua et al. (2012)	Privada	60	93	—	—
Haleem et al. (2015)	RIM-ONE	158	92,95	—	—
Noronha et al. (2014)	Privada	272	92,65	100	92
Salam et al. (2015)	Privada	50	92	100	88
Acharya et al. (2011)	Privada	60	91,7	—	—
Sousa et al. (2017)	RIM-ONE	455	91,2	95	88,23
Gajbhiye e Kamthane (2015)	RIM-ONE	350	86,57	—	—
Metodologia Proposta (Índice de Moran)	RIM-ONE	455	95,08	93,4	96,4
Metodologia Proposta (Função K de Ripley)	RIM-ONE	455	94,28	90,5	97,25

6 Conclusão

O glaucoma é a segunda maior causa de cegueira em todo o mundo. A degeneração progressiva e irreversível no disco óptico causada pela doença, ressalta a importância do desenvolvimento de sistemas CAD e CADx de auxílio ao diagnóstico para conferir um tratamento precoce e adequado.

O diagnóstico de glaucoma em imagens de fundo de olho exclusivamente através de análise de textura, e portanto sem necessidade de realizar medidas precisas no interior do disco óptico, tem se mostrado uma tarefa difícil principalmente pelo fato frequente das imagens de pacientes que estão em fases iniciais de glaucoma possuírem características de textura similares às de imagens de pacientes saudáveis. Em contrapartida, nas abordagens que não utilizam características de textura, se não houver uma segmentação perfeita do disco óptico e escavação, os cálculos gerados não serão confiáveis e, conseqüentemente, podem levar a falso diagnóstico da doença.

Assim sendo, este trabalho apresenta uma metodologia de diagnóstico de glaucoma a partir da análise exclusiva de características de textura a fim de identificar alterações estruturais do disco óptico de forma a dispensar uma segmentação precisa e permitir prover uma segunda opinião aos especialistas para todos os casos.

Para alcançar este objetivo utilizou-se técnicas de processamento de imagens, funções geoestatísticas e máquina de vetores de suporte. A análise de textura foi realizada através da combinação das abordagens estrutural e estatística. A abordagem estrutural foi realizada por meio do método CLBP e a abordagem estatística, através dos indicadores de função K de Ripley e de Índice de Moran, ambos aplicados na forma local.

A metodologia proposta foi validada através de vários experimentos sobre a base pública RIM-ONE a fim de analisar a aplicação de cada técnica utilizada e comprovar sua eficiência. O experimento que apresentou melhor resultado utilizou a imagem do canal *Red* transformada pelo método das cores oponentes seguida da equalização do histograma e CLBP para gerar uma representação dos padrões de textura. Das técnicas utilizadas, as características de textura extraídas a partir da utilização do Índice de Moran alcançou os melhores resultados sendo aplicado com base na abordagem de decomposição espacial retangular. As características obtidas foram submetidas ao processo de seleção pela análise discriminante *stepwise* e classificadas através do método SVM. Foi alcançada uma acurácia de 95,08%, sensibilidade de 93,4%, e especificidade de 96,4%.

Os resultados obtidos foram comparados com as pesquisas descritas no estado da arte e foi possível observar que se mostraram muito promissores se destacando entre os melhores. Além disso, o uso de uma base pública de imagens muito heterogênea e o número superior de amostras utilizadas nos testes, em comparação com outros trabalhos, possibilitou comprovar a robustez da metodologia proposta.

Finalmente, esta dissertação apresenta como principais contribuições ao meio científico:

- Implementação de uma nova metodologia de diagnóstico de glaucoma baseada exclusivamente em análise de textura;
- Adaptação da aplicação das funções geoestatísticas K de Ripley e Índice de Moran com natureza local para a análise de textura de regiões do disco óptico extraídas em retinografias, bem como a capacidade para discriminação dos padrões saudáveis e glaucomatosos atingindo resultados consistentes e visando auxiliar o especialista com um maior suporte ao diagnóstico;
- Elaboração de diretrizes para diagnósticos de glaucoma a partir de discos ópticos amostrados em retinografias testada na base RIM-ONE, como passo inicial para a estruturação de um método CADx, provendo ao especialista uma segunda opinião.

6.1 Trabalhos futuros

Dada a relevância do tema, existe um grande interesse da comunidade acadêmica em pesquisas na área, conforme apresentado no Capítulo 2. É importante ressaltar também que ainda que a metodologia proposta tenha alcançado bons resultados, são necessárias algumas tarefas para que sejam sanadas algumas de suas limitações a fim de explorar possibilidades que não puderam ser incluídas. Assim, espera-se que outros trabalhos possam ser desenvolvidos com base na pesquisa realizada de forma a ampliar sua validação. Como sugestão para melhorias e trabalhos futuros apontam-se:

- Analisar o uso de outros índices geoestatísticos para extrair características locais de textura, como o coeficiente de Geary com o Índice de Moran por aparecerem em conjunto na literatura;
- Testar a metodologia proposta em outras bases de imagens;

- Investigar e comparar outros métodos de seleção de características como, por exemplo, Análise de Componentes Principais, para redução de dimensionalidade das bases de características geradas a partir do uso de índices geoestatísticos;
- Avaliar a utilização de métodos alternativos de aprendizagem de máquina na tarefa de reconhecimento dos padrões saudável e glaucomatoso, tais como *Multi Layer Perceptron*, *Random Forest* e *K-Nearest Neighbors*.

Referências

- 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, p. 72–83, 2017.
- 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, 2011.
- ACHARYA, U. R.; NG, E.; 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*, Elsevier, v. 15, p. 18–26, 2015.
- AHMED, F.; HOSSAIN, E.; BARI, A. S. M. H.; SHIHAVUDDIN, A. Compound local binary pattern (CLBP) for robust facial expression recognition. In: *2011 IEEE 12th International Symposium on Computational Intelligence and Informatics (CINTI)*. 2011. p. 391–395.
- ALI, M. A.; HURTUT, T.; FAUCON, T.; CHERIET, F. Glaucoma Detection based on Local Binary Patterns in Fundus Photographs. In: *SPIE Medical Imaging*. 2014. p. 903531–903531–7.
- ALLAM, A.; YOUSSEF, A.; GHALWASH, A. Automatic Segmentation of Optic Disc in Eye Fundus Images: A Survey. *ELCVIA Electronic Letters on Computer Vision and Image Analysis*, v. 14, n. 1, 2015.
- ANSELIN, L. The Moran scatterplot as an ESDA tool to assess local instability in spatial association. In: FISCHER, M.; SCHOLTEN, H.; UNWIN, D. (Ed.). *Spatial analytical perspectives on GIS*. : London, Taylor Francis, 1996.
- ARTHUR, A. M.; IANO, Y.; TURUDA, P. D.; LARICO, R. F.; ARTHUR, R. Técnicas de análise da retina humana: Revisão breve sobre os recursos e as renovações propedêuticas disponíveis a prevenção e o diagnóstico precoce das complicações vasculares da retina associadas as doenças sistêmicas. *Ensaio e Ciência: Ciências Biológicas, Agrárias e da Saúde*, v. 15, n. 4, p. 131–145, 2011.
- BRADSKI, G. The OpenCV Library. *Dr. Dobb's Journal of Software Tools*, 2000.
- BRAZ JUNIOR, G. *Classificação de Regiões de Mamografias em Massa e Não Massa usando Estatística Espacial e Máquina de Vetores de Suporte*. Dissertação (Mestrado) — Universidade Federal do Maranhão, 2008.
- BRAZ JUNIOR, G. *Deteção 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.
- BRIGHTFOCUS. National Glaucoma Research Program. BrightFocus Foundation, 2017. Acessado em: 4 de outubro de 2017. Disponível em: <<https://www.brightfocus.org/research/national-glaucoma-research-program>>.

CARVALHO, T. J. d. *Aplicação de técnicas de visão computacional e aprendizado de máquina para a detecção de exsudatos duros em imagens de fundo de olho*. Dissertação (Mestrado) — Universidade Estadual de Campinas, 2010.

CBO. Tudo sobre o glaucoma. Conselho Brasileiro de Oftalmologia, 2017. Acessado em: 3 de outubro de 2017. Disponível em: <<http://www.cbo.net.br/novo/publico-geral/tudo-sobre-o-glaucoma.php>>.

CHANG, C.; LIN, C. LIBSVM: A Library for Support Vector Machines. *ACM Transactions on Intelligent Systems and Technology*, v. 2, n. 3, p. 27–27, 2011. Acessado em: 31 de março de 2017, *Software* Disponível em: <https://www.csie.ntu.edu.tw/~cjlin/libsvm/>.

CHAVES, A. da C. F. *Extração de Regras Fuzzy para Máquinas de Vetores Suporte (SVM) para Classificação em Múltiplas Classes*. Tese (Doutorado) — Pontifícia Universidade Católica do Rio de Janeiro, 2006.

CLARO, M.; SANTOS, L.; SILVA, W.; ARAÚJO, F.; MOURA, N.; MACEDO, A. Automatic Glaucoma Detection Based on Optic Disc Segmentation and Texture Feature Extraction. *CLEI Electronic Journal*, v. 19, n. 2, p. 5–5, 2016.

CRISTIANINI, N.; SHAWE-TAYLOR, J. *An Introduction to Support Vector Machines and other Kernel-Based Learning Methods*. Cambridge University Press, Cambridge, 2000.

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, 2012.

EMANUELLI, L. Studio Oculistico Dr. Emanuelli, 2017. Acessado em: 3 de outubro de 2017. Disponível em: <<http://www.studiooculisticoemanuelli.com/patologie/glaucoma/>>.

FACELI, K. et al. *Inteligência artificial: Uma abordagem de aprendizado de máquina*. LTC, Rio de Janeiro, 2011.

FILHO, B. L. Utilização Racional de Exames Diagnósticos em Cardiologia. *Arquivos Brasileiros de Cardiologia*, v. 72, n. 1, p. 39–44, 1999. Acessado em: 18 de setembro de 2017. Disponível em: <<http://publicacoes.cardiol.br/abc/1999/7201/72010003.pdf>>.

FILHO, O. M.; NETO, H. V. *Processamento Digital de Imagens*. Brasport, Rio de Janeiro, 1999.

FRANK, E.; HALL, M. A.; WITTEN, I. H. The WEKA Workbench. Online Appendix for Data Mining: Practical Machine Learning Tools and Techniques. Morgan Kaufmann, 2016.

FUMERO, F.; ALAYON, S.; SANCHEZ, J.; SIGUT, J.; GONZALEZ-HERNANDEZ, M. RIM-ONE: An open retinal image database for optic nerve evaluation. In: IEEE. *2011 24th International Symposium on Computer-Based Medical Systems*. 2011. (CBMS '11), p. 1–6.

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

GONZALEZ, R. C.; WOODS, R. E. *Digital image processing*. : Prentice hall Upper Saddle River, 2002.

- GONZALEZ, R. C.; WOODS, R. E. *Pocessamento digital de imagens*. Pearson Prentice Hall, 2010.
- GUPTA, R.; UNDRILL, P. E. Textural features for image classification. *Physics in Medicine & Biology*, v. 40, n. 5, p. 835–855, 1995.
- GUYTON, A.; HALL, J. *Textbook of Medical Physiology*. Saunders, 2005.
- HAIR, J. F.; ANDERSON, R. E.; L., T. R.; BLACK, W. C. *Análise Multivariada de Dados*. Bookman, 2005.
- HALEEM, M. S.; HAN, L.; HEMERT, J. van; FLEMING, A. Glaucoma classification using regional wavelet features of the onh and its surroundings. In: *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. 2015. p. 4318–4321.
- HAND, D.; MANNILA, H.; SMYTH, P. *Principles of Data Mining*. A Bradford Book, Cambridge, 2000.
- HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, I. H. Textural features for image classification. *Systems, Man and Cybernetics, IEEE Transactions on, IEEE*, n. 6, p. 610–621, 1973.
- HERING, E. *Outlines of a Theory of the Light Sense*. Harvard University Press, 1964.
- HIRA, Z. M.; GILLIES, D. F. A Review of Feature Selection and Feature Extraction Methods Applied on Microarray Data. *Advances in Bioinformatics*, v. 2015, n. 5, p. 835–855, 2015.
- KANSKI, J. J.; BOWLING, B. *Clinical Ophthalmology: A Systematic Approach*. Saunders, 2011.
- KENNETH, R. C. *Digital image processing*. Prentice Hall Press, Upper Saddle River, NJ, 1996.
- KREMPI, A. P. *Explorando recursos de estatística espacial para análise da acessibilidade na cidade de Bauru*. Dissertação (Mestrado) — Universidade de São Paulo, 2004.
- LACHENBRUCH, P. A.; GOLDSTEIN, M. Discriminant analysis. *Biometrics*, [Wiley, International Biometric Society], v. 35, n. 1, p. 69–85, 1979.
- LENCIONE, D. *Desenvolvimento de sistemas ópticos e modelos radiométricos para otimização sistêmica em retinógrafos de alta resolução*. Dissertação (Mestrado) — Universidade de São Paulo, 2013.
- LEVINE, N. *Análise Estatística de Dados Geográficos*. Editora Unsep, São Paulo, 1996.
- LOONEY, C. G. *Pattern recognition using neural networks: theory and algorithms for engineers and scientists*. Oxford University Press, Inc., New York, NY, USA, 1997.
- 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, 2017.

- 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.
- 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.
- 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*, Elsevier Science Publishers B. V., v. 33, p. 73–82, 2012.
- NAITHANI, P.; SIHOTA, R.; SONY, P.; DADA, T.; GUPTA, V.; KONDAL, D.; PANDEY, R. M. Evaluation of optical coherence tomography and heidelberg retinal tomography parameters in detecting early and moderate glaucoma. *Investigative Ophthalmology & Visual Science*, v. 48, n. 7, p. 3138–3145, 2007.
- 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.
- OJALA, T.; PIETIKÄINEN, M.; HARWOOD, D. A comparative study of texture measures with classification based on featured distributions. *Pattern recognition*, v. 29, n. 1, p. 51–59, 1996.
- PATTON, N.; ASLAM, T. M.; MACGILLIVRAY, T.; DEARY, I. J.; DHILLON, B.; EIKELBOOM, R. H.; YOGESAN, K.; CONSTABLE, I. J. Retinal image analysis: Concepts, applications and potential. *Progress in Retinal and Eye Research*, Elsevier, v. 25, n. 1, p. 99–127, 2006.
- PEDRINI, H.; SCHWARTZ, W. R. *Análise de Imagens Digitais: Princípios, Algoritmos e Aplicações*. Thomson Learning, 2008.
- PENEDO, M. G.; REMESEIRO, B.; RAMOS, L.; BARREIRA, N.; GARCÍA-RESÚA, C.; YEBRA-PIMENTEL, E.; MOSQUERA, A. *Automatization of Dry Eye Syndrome Tests*. CRC Press (Taylor & Francis), 2014. 293–320 p.
- QUIGLEY, H. A.; BROMAN, A. T. The number of people with glaucoma worldwide in 2010 and 2020. *The British Journal of Ophthalmology*, v. 90, p. 262–267, 2006.
- RAJA, C.; GANGATHARAN, N. A hybrid swarm algorithm for optimizing glaucoma diagnosis. *Computers in Biology and Medicine*, Elsevier, v. 63, p. 196–207, 2015.
- RESNIKOFF, D. P. S.; ETYA’ALE, D.; KOCUR, I.; PARARAJASEGARAM, R.; POKHAREL, G. P.; MARIOTTI, S. P. Global data on visual impairment in the year 2002. *Bulletin of the World Health Organization*, v. 82, n. 11, p. 844–851, 2004.
- RIPLEY, B. D. Modelling Spatial Patterns. *J. Roy. Statist. Soc.*, p. 172–212, 1977.
- ROCHA, S. V. d. *Diferenciação do padrão de malignidade e benignidade de massas em imagens de mamografias usando padrões locais binários, geoestatística e índice de diversidade*. Tese (Doutorado) — Universidade Federal do Maranhão, 2014.

- SAKTHIVEL, K.; NARAYANAN, R. An automated detection of glaucoma using histogram features. *International Journal of Ophthalmology*, v. 8, n. 1, p. 194–200, 2015.
- SALAM, A. A.; AKRAM, M. U.; WAZIR, K.; ANWAR, S. M.; MAJID, M. Autonomous glaucoma detection from fundus image using cup to disc ratio and hybrid features. *2015 IEEE International Symposium on Signal Processing and Information Technology (ISSPIT)*, p. 370–374, 2015.
- SANGWINE, S. J.; HORNE, R. E. N. *The Color Image Processing Handbook*. Chapman & Hall, 1998.
- SANTOS, P. R. dos. Oftalmoscopia, 2017. Acessado em: 3 de outubro de 2017. Disponível em: <<https://pt.slideshare.net/PauloRoberto122/oftalmoscopia-44191155>>.
- SANTOS, S. M.; SOUZA, W. V. Introdução a estatística espacial para a saúde pública. Ministério da Saúde, Fundação Oswaldo Cruz, 2007.
- SBG. *Sociedade Brasileira de Glaucoma*. 2017. Acessado em: 30 de março de 2017, Disponível em: <https://www.sbgglaucoma.com.br/>.
- S.KAVITHA; S.KARTHIKEYAN; DR.K.DURAI SWAMY. Neuroretinal rim quantification in fundus images to detect glaucoma. *IJCSNS International Journal of Computer Science and Network Security*, v. 10, n. 6, 2010.
- 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, 2017.
- 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*, Elsevier, v. 121, n. 11, p. 2081–2090, 2014.
- VAFSAIE, H.; IMAM, I. F. Feature selection methods: genetic algorithms vs. greedy-like search. In: *In Proceedings of the International Conference on Fuzzy and Intelligent Control Systems*. 1994.
- VAPNIK, V. N. *Statistical Learning Theory*. Wiley, New York, 1998.
- VERAS, R. d. M. S. *Detecção e segmentação de estruturas em imagens médicas de retina*. Tese (Doutorado) — Universidade Federal do Ceará, Fortaleza, 2014.
- 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, 2014.