



UNIVERSIDADE FEDERAL DO MARANHÃO

Curso de Ciência da Computação

Hugo Gois Santos

**Estudo de Variantes de LBP para Diagnóstico
do Glaucoma**

São Luís - MA

Janeiro - 2019

Hugo Gois Santos

Estudo de Variantes de LBP para Diagnóstico do Glaucoma

Monografia apresentada ao curso de Ciência da Computação da Universidade Federal do Maranhão, como parte dos requisitos necessários para obtenção do grau de Bacharel em Ciência da Computação.

Curso de Ciência da Computação

UFMA

Orientador: Prof. Dr. Geraldo Braz Júnior

São Luís - MA

Janeiro - 2019

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

Gois Santos, Hugo.

Estudo de Variantes de LBP para Diagnóstico do Glaucoma
/ Hugo Gois Santos. - 2019.

54 p.

Orientador(a): Prof. Dr. Geraldo Braz Junior.

Monografia (Graduação) - Curso de Ciência da
Computação, Universidade Federal do Maranhão, São Luís,
2019.

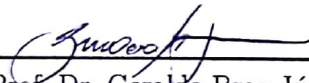
1. Aprendizado de Máquina. 2. Glaucoma. 3. LBP. 4.
Retinografia. I. Braz Junior, Prof. Dr. Geraldo. II.
Título.

Hugo Gois Santos

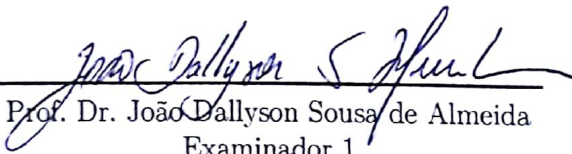
Estudo de Variantes de LBP para Diagnóstico do Glaucoma

Monografia apresentada ao curso de Ciência da Computação da Universidade Federal do Maranhão, como parte dos requisitos necessários para obtenção do grau de Bacharel em Ciência da Computação.

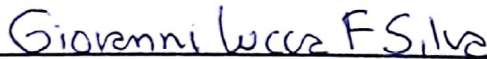
Monografia **aprovada** em São Luís, 09 de Janeiro de 2019.



Prof. Dr. Geraldo Braz Júnior
Orientador
Universidade Federal do Maranhão



Prof. Dr. João Dallyson Sousa de Almeida
Examinador 1
Universidade Federal do Maranhão



Prof. Ms. Giovanni Lucca França da Silva
Examinador 2
Universidade Federal do Maranhão

São Luís - MA

Janeiro - 2019

Agradecimentos

A Deus, que me deu forças e sabedoria durante toda minha trajetória acadêmica e permitiu que realize-se mais esse sonho.

A minha mãe e meu pai, que tanto batalharam para garantir o meu futuro/felicidade, e hoje, posso presenteá-los com essa vitória. Ambos são meus maiores exemplos de superação e fé.

Ao meu irmão, que esteve ao meu lado me apoiando nos momentos de sucesso e dificuldade.

A toda minha família, minha madrinha Luzia, minha vó Mariana, meu tio Davi, minha segunda mãe Delma, meus primos Lucas e Livia e ao meu tio Obdaldas, que tiveram, de alguma forma, não menos importante, influência na minha conquista.

Aos meu orientador, Prof. Dr. Geraldo Braz Junior, que apesar de todas as dificuldades, nunca desistiu de mim e sempre esteve presente na minha graduação, compartilhando conhecimentos e palavras de incentivo durante esta jornada.

Aos meus grandes amigos do BFFs, Lucas Gabriel, Bernardo, Rodrigo, Cláudio, Renan, Gabryel, Aguiar e Paulo Victor, que me proporcionaram momentos de descontração e me deram forças para finalizar este trabalho.

As minhas grandes amigas, Fernanda, Raquel e Lígia, pelas palavras de incentivo nos momentos de indecisão, vocês fazem parte desta vitória.

Aos meus amigos de curso, Bruno, Erick, Vitu, Tarcio, Lhucas, Garcês, Phillipe, Júlia, Alex, Jorge e André, que estiveram do meu lado durante este 4 anos e meio de graduação, me carregando em alguns momentos, mas no final todos os desafios valeram a pena.

Aos meus chefes de trabalho, Jonathan e Jamerson, que compreenderam este momento da minha vida e me ajudaram a realizar este sonho.

A todos que eu esqueci, que por motivos de pressa e nervosismo não estão aqui, sintam-se lembrados e cientes que a vitória é nossa.

A todos, novamente, muito obrigado.

"Viver é enfrentar um problema atrás do outro. O modo como você o encara é que faz a diferença."

(Benjamin Franklin)

Resumo

O glaucoma é uma doença crônica e silenciosa que causa danos ao nervo óptico e, em casos não controlados, convergem para o mesmo destino, que é a cegueira total, ocasião em que recebem o nome de glaucoma absoluto. O processo que antecipa o diagnóstico do glaucoma é composto pela análise de diversos componentes e requer bastante tempo, fator essencial para a eficácia do tratamento. Visando otimizar o custo do tempo gasto neste processo, novas técnicas de análise e processamento de imagens vêm sendo aplicadas em busca da melhoria da qualidade do diagnóstico médico. Sistemas de Detecção e Diagnóstico auxiliados por computador (Computer Aided Detection/Diagnosis) têm sido propostos com objetivo de auxiliar os profissionais de saúde, facilitando a detecção de áreas suspeitas ou anormalidades mascaradas em casos de difícil visualização. Este trabalho tem como objetivo propor uma metodologia de diagnóstico do glaucoma, utilizando descritores de textura, a partir de imagens provenientes do exame da retinografia. Para isso, os descritores de textura utilizados no trabalho, LBP (Padrão Binário Local) e suas variantes, em conjunto com algoritmos de aprendizado de máquina são combinados para a tarefa da classificação das imagens, tendo em vista auxiliar os especialistas da área com uma segunda opinião acerca do problema. O método proposto apresentou resultados promissores para o diagnóstico do glaucoma alcançando, como melhor resultado, acurácia de 87,4%, sensibilidade de 85,5%, especificidade de 91,4% e precisão de 88,5%.

Palavras-chaves: Glaucoma, LBP, Aprendizado de Máquina, Retinografia.

Abstract

Glaucoma is a chronic, silent disease that causes damage to the optic nerve and, in uncontrolled cases, converge to the same fate, which is total blindness, at which time they are called absolute glaucoma. The process that anticipates the diagnosis of glaucoma is composed of the analysis of several components and requires a lot of time, an essential factor for the effectiveness of the treatment. In order to optimize the cost of the time spent in this process, new techniques of image analysis and processing have been applied in order to improve the quality of medical diagnosis. Computer Aided Detection / Diagnosis has been proposed to assist health professionals by facilitating the detection of suspected areas or masked abnormalities in cases of difficult visualization. This work aims to propose a methodology for the diagnosis of glaucoma, using texture descriptors, based on images from the retinal examination. For this, the texture descriptors used in the work, LBP (Local Binary Pattern) and its variants, together with algorithms of learning are combined for the task of classifying the images, in order to help the experts of the area with a second opinion about the problem. The proposed method presented promising results for the diagnosis of glaucoma, achieving, as the best result, accuracy of 87.4 %, sensitivity of 85.5 %, specificity of 91.4 % and precision of 88.5 %.

Key-words: Glaucoma, LBP, Machine Learning, Retinography.

Lista de ilustrações

Figura 1 – Maiores causas de cegueira irreversível no mundo.	13
Figura 2 – Corte do globo ocular.	19
Figura 3 – Exame de retinografia.	21
Figura 4 – Representação de uma imagem em formato matricial.	22
Figura 5 – Etapas que englobam o processamento de imagens.	23
Figura 6 – Exemplo de histogramas. Em a) imagens com tonalidades escuras e b) tonalidades claras.	25
Figura 7 – Exemplificação de aplicação do operador LBP.	27
Figura 8 – Comparativo do cálculo realizado para extração do vetor descritor para LBP e CS-LBP.	28
Figura 9 – O descritor eXtended CS-LBP.	31
Figura 10 – Representação da método Random Forest ilustrando a escolha da melhor classificação.	35
Figura 11 – Representação das curvas de decisão adotadas em conjunto de treinamento binário.	36
Figura 12 – Gráfico da função sigmoide.	38
Figura 13 – Disposição das distribuições na comparação entre os resultados de um teste em pacientes com e sem a doença.	39
Figura 14 – Etapas da metodologia proposta.	41
Figura 15 – Exemplos de imagens da base RIM-ONE.	42
Figura 16 – Separação dos canais de cores na base de aquisição.	43
Figura 17 – Aplicação da equalização do histograma nas imagens de fundo de olho.	43
Figura 18 – Decomposições espaciais utilizadas na metodologia.	44

Lista de tabelas

Tabela 1 – Estimativa do número de pessoas com GPAF e GPAA combinadas, em 2020.	14
Tabela 2 – Comparação entre os resultados obtidos na literatura.	17
Tabela 3 – Tamanho do histograma para cada descritor utilizado.	45
Tabela 4 – Resultados obtidos pela metodologia sem a etapa de decomposição espacial.	47
Tabela 5 – Resultados obtidos pela metodologia incluindo a decomposição <i>Cartesian Grid</i>	48
Tabela 6 – Resultados obtidos pela metodologia incluindo a decomposição em forma de anéis.	48

Lista de abreviaturas e siglas

BG-LBP	BackGround Local Binary Pattern
CADe	Computer-Aided Detection
CADx	Computer-Aided Diagnosis
CS-LBP	Center-Symmetric Local Binary Pattern
XCS-LBP	eXtended Center-Symmetric Local Binary Pattern
E-LBP	Extend Local Binary Pattern
GPAA	Glaucoma Primário de Ângulo Aberto
GPAF	Glaucoma Primário de Ângulo Fechado
LBP	Local Binary Patterns
MVS	Máquinas de Vetores Suporte
PI	Processamento de Imagens
PIO	Pressão Intraocular
RBF	Radial Basis Function
ROI	Region of Interest
SIFT	Scale-Invariant Feature Transform
SMO	Sequential Minimal Optimization
SGB	Sociedade Brasileira de Glaucoma
OC-LBP	Opponent Colocr Local Binary Pattern
WGA	World Glaucoma Association

Sumário

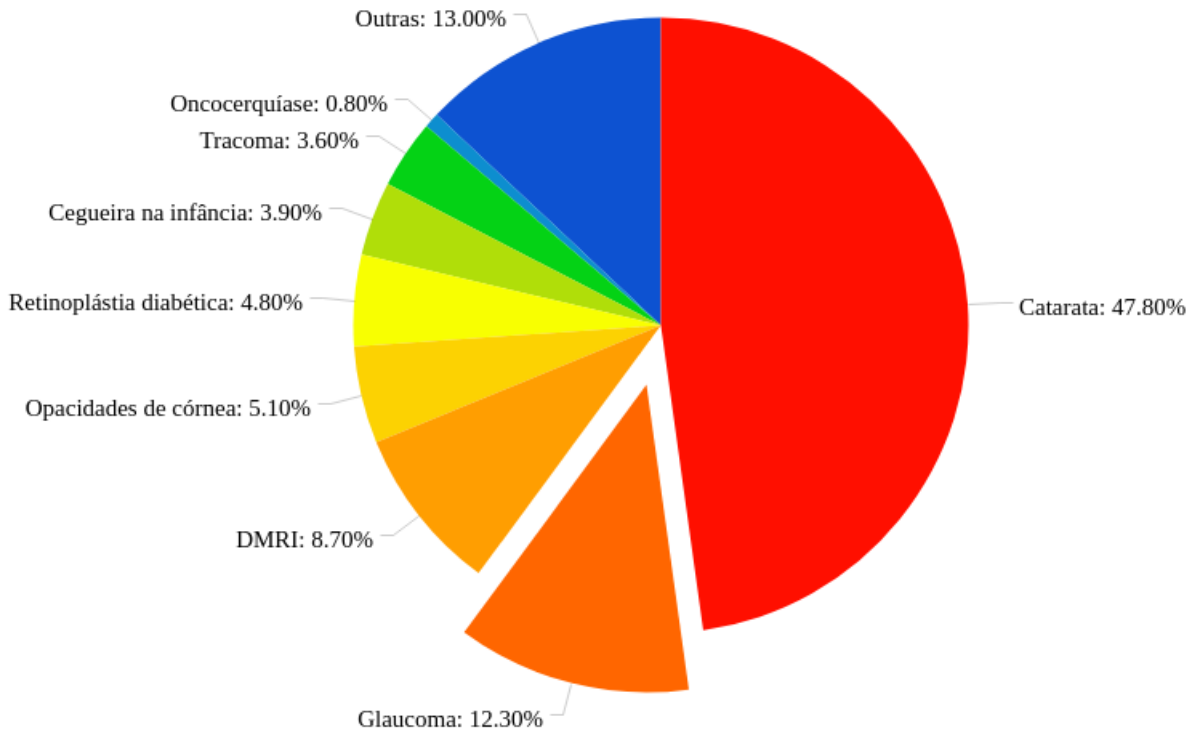
1	INTRODUÇÃO	13
1.1	Objetivo	15
1.1.1	Objetivos Específicos	15
1.2	Trabalhos Relacionados	15
1.3	Estrutura do Trabalho	18
2	FUNDAMENTAÇÃO TEÓRICA	19
2.1	Olho Humano	19
2.2	Retinografia	20
2.3	Glaucoma	21
2.4	Processamento de Imagens	22
2.4.1	Transformação de RGB para Tons de Cinza	24
2.4.2	Equalização de Histograma	25
2.5	Extração de Características	26
2.5.1	Análise de Textura	26
2.5.2	Local Binary Pattern (LBP)	27
2.5.3	Center-Symmetric Local Binary Patterns (CS-LBP)	28
2.5.4	Extend Local Binary Pattern (E-LBP)	29
2.5.5	eXtended Center-Symmetric Local Binary Pattern (XCS-LBP)	30
2.5.6	BackGround Local Binary Pattern (BG-LBP)	31
2.6	Seleção de Características	33
2.6.1	Correlation-based Feature Selection (CFS)	33
2.6.2	Best-First	33
2.7	Aprendizado de Máquina	34
2.7.1	Random Forest	35
2.7.2	Máquina de Vetores de Suporte	35
2.7.3	Regressão Logística	37
2.8	Métricas de Validação	38
3	METODOLOGIA	41
3.1	Aquisição da base	41
3.2	Pré-processamento	42
3.3	Decomposição Espacial	44
3.4	Extração de Características	44
3.5	Seleção de Características	45
3.6	Reconhecimento de Padrões	46

4	RESULTADOS	47
4.1	Discussão	48
5	CONCLUSÃO	50
5.1	Trabalhos Futuros	50
	REFERÊNCIAS	51

1 Introdução

O glaucoma é uma doença progressiva e silenciosa que provoca lesão no nervo óptico e no campo visual, podendo causar a perda irreversível da visão, caso não seja detectada precocemente (OFTALMOLOGIA, 2017). Segundo WGA (2017), o glaucoma é a segunda maior causa de cegueira no mundo (12,3%), ficando atrás apenas da catarata (47,8%), assim ilustrado na Figura 1. A estimativa é que a doença afetará aproximadamente 80 milhões de pessoas no mundo, em 2020, como ilustra a Tabela 1.

Figura 1 – Maiores causas de cegueira irreversível no mundo.



Fonte: ADAPTADO DE (WGA, 2017)

O aumento da pressão intraocular (PIO), responsável por manter a forma do olho humano, é uma das principais causas da doença. Existem quatro tipos principais do glaucoma: crônico, agudo, congênito e secundário. O primeiro, que representa cerca de 90% de todos os casos, normalmente é assintomático e leva anos para causar deficiência na visão humana. O agudo ocorre quando a saída do humor aquoso¹ é subitamente bloqueada,

¹ Líquido incolor, transparente, de consistência aquosa com papel na nutrição da córnea e do cristalino e na regulação da PIO.

causando um aumento súbito e doloroso da pressão intraocular. Já o congênito, com incidência mais rara, atinge bebês logo após seu nascimento ou nos primeiros anos de vida, herdado pela mãe durante o período de gestação. Por fim, o glaucoma secundário é desenvolvido por algumas complicações de várias condições médicas, como cirurgias, cataratas, uveítes e, além destes, o uso excessivo de medicamentos à base de corticoides (OFTALMOLOGIA, 2017).

A classificação do quadro glaucomatoso ainda pode ser feita conforme os mecanismos de obstrução da drenagem do humor aquoso: glaucoma primário de ângulo aberto (GPAA), glaucoma primário de ângulo fechado (GPAF) e glaucoma secundário (RITCH; SHIELDS; KRUPIN, 1989). Em âmbito nacional, estudos apontam que o predomínio do glaucoma é de 3,4%, sendo o GPAA, o mais prevalente (2,4%) (GUEDES, 2007). É importante destacar que a cegueira causada pela catarata é passível de procedimentos cirúrgicos para sua reversão, diferente do glaucoma, patologia com consequências visuais irreversíveis.

Tabela 1 – Estimativa do número de pessoas com GPAF e GPAA combinadas, em 2020.

Fonte: (QUIGLEY; BROMAN, 2006)

Região	Glaucoma Total
China	21.824,015
Europa	13.971,113
África	8.359,451
América Latina	8.011,575
Mundo	79.640,184

O diagnóstico da doença pode ser realizado através de diversos exames oftalmológicos: gonioscopia, tonometria, retinografia, análise de fundo de olho, entre outros. Em alguns desses exames, as imagens são analisadas manualmente pelos especialistas em busca de mudanças anatômicas na retina. Todavia, esta análise requer tempo e verificação minuciosa e, ainda assim, está sujeita a erros de interpretação. A retinografia, realizada para obtenção da fotografia colorida do fundo de olho, um dos principais exames realizados para detecção do glaucoma, foi o exame escolhido para aquisição da base de imagens digitalizadas no estudo.

A utilização de técnicas computacionais, como processamento de imagens e aprendizado de máquina, durante o processo de detecção e diagnóstico do glaucoma vêm sendo desenvolvidas com o objetivo de auxiliar os profissionais da área médica com uma segunda opinião acerca do problema. Visto que este é um processo subjetivo e sua análise possui elevado custo de tempo, tais técnicas têm se mostrado eficientes, de modo a otimizar os procedimentos realizados, descartando operações desnecessárias no processo do diagnóstico.

É importante ressaltar que durante o processo de avaliação de casos suspeitos de glaucoma, quanto mais informações disponíveis ao especialista, maior será a acurácia do

seu diagnóstico. Com esta finalidade, a utilização de ferramentas computacionais auxiliares, os Sistemas de Detecção e Diagnóstico auxiliados por computador (CAD - Computer-Aided Detecton, CADx - Computer-Aided Diagnosis), ganham notoriedade a medida que proporcionam a comunidade médica melhorias no fluxo de trabalho durante a avaliação e qualidade do diagnóstico.

A principal finalidade da utilização dos sistemas CAdE/CADx encontra-se na necessidade de coletar o maior nível de informações possíveis referentes a imagem analisada. Desta forma, mediante a manipulação da base de aquisição, estas ferramentas complementares auxiliam no processo de detecção e diagnóstico, tendo como resultado novas imagens com destaques em regiões de interesse (ROI)², caracterizada pela área de análise mais significativa da lesão, com melhorias no aspecto visual e predições a respeito da magnitude da patologia.

Esse estudo tem como finalidade a construção de uma metodologia para diagnóstico do glaucoma a partir da análise de imagens provenientes do exame da retinografia utilizando descritores de textura e técnicas de aprendizado de máquina para o reconhecimento de padrões.

1.1 Objetivo

Com base no que foi exposto, o objetivo deste estudo tem como enfoque analisar a utilização de descritores de textura como LBP (OJALA T.; PIETIKÄINEN, 1996) e seus variantes, aplicado à técnicas de aprendizado de máquina e reconhecimento de padrões para o diagnóstico do glaucoma.

1.1.1 Objetivos Específicos

- Implementar de descritores de textura LBP e suas variantes;
- Analisar e aplicar algoritmos de aprendizado de máquina no âmbito do problema;
- Construir e avaliar de uma metodologia de diagnóstico de glaucoma através de experimentos utilizando uma base de imagens pública.

1.2 Trabalhos Relacionados

A utilização de métodos computacionais para construção de metodologias visando o diagnóstico de glaucoma em imagens oriundas do exame da retinografia têm como intuito gerar uma segunda opinião acerca do problema, auxiliando assim, a análise do especialista

² Região de interesse da imagem.

médico com um conjunto de informações adicionais, fator essencial para a eficácia da detecção e diagnóstico da patologia. Na maioria dos casos, estes estudos têm aspectos em comum nas suas propostas metodológicas, das quais podem ser destacadas três etapas: (1) a segmentação do disco óptico, (2) seguida da extração de características dos mesmos, (3) combinado com técnicas de classificação.

Nesta seção será realizada uma breve análise da literatura a respeito dos trabalhos que apresentam estudos com linhas de pesquisa similares às produzidas neste estudo.

Dua et al. (2012) propõe a aplicação de técnicas de extração de características baseadas na transformada discreta de *wavelet* aplicado ao diagnóstico do glaucoma. Neste estudo, após realizada a etapa de extração das características, estas foram submetidas a diferentes estratégias de seleção de atributos, como os algoritmos *Random Search*, *Genetic First* e *Greedy Stepwise*, todos implementados junto ao pacote WEKA (HALL et al., 2009). A base utilizada na pesquisa foi a Kasturba Medical College, contendo a seguinte disposição: em um total de 60 imagens de fundo de olho, 30 amostras eram correspondentes a casos normais e os 30 restantes, a casos com GPAA. Na etapa de classificação foram utilizados quatro tipo de classificadores: MVS, Random Forests, Naive Bayes e SMO (*sequential minimal optimization*). Após a realização da validação cruzada, dividida em 10 subconjuntos de dados, o classificador Naive Bayes apresentou o melhor resultado nos testes, com 93% de acurácia.

No estudo realizado por Araujo et al. (2017), é proposta uma metodologia para diagnóstico do glaucoma com as seguintes etapas: (1) melhoria da base de aquisição mediante a aplicação de algoritmos de pré-processamento, como o Retinex (LAND; MCCANN, 1971), filtro homomórfico (BURGISS, 2001) e equalização de histograma; (2) As imagens resultantes passam pelo processo de divisão espacial. Esta etapa tem como finalidade aprimorar a descrição das partes que compõem a região de interesse; (3) Para a etapa de extração de características, o autor utilizou os índices de diversidade de *Shannon*, *McIntosh* e *Diversidade Total* (MAGURRAN, 2013). Estes conceitos, provenientes da biologia, são utilizados para avaliar a disposição de espécies em uma determinada região analisada. Abstraindo aos métodos computacionais, esta disposição é organizada em histogramas da região de interesse, que por sua vez, geram vetores descritores de textura. (4) Com as características extraídas, é realizada a etapa de reconhecimento de padrões. Com o classificador MVS (máquina de vetores de suporte), os resultados foram considerados satisfatórios, alcançando acurácia de 93,41%.

Cabe ressaltar o método proposto por Silva et al. (2018), o qual também são analisadas diferentes variantes de *Padrões de Locais Binários* (LBP) para análise de magnitude do glaucoma. Utilizando três abordagens de decomposição espacial (*Cartesian Grid*, *Grid X* e *Circular*), o autor realizou a extração de características aplicando o descritor LBP original e 3 variantes (LQP, CS-LBP, CLBP). A metodologia tem como

etapa final, o reconhecimento de padrões. Para isso, os testes foram realizados utilizando o classificador MVS, para cada configuração de decomposição/descriptor escolhida pelo autor. A base utilizada foi a RIM-ONE (TRUCCO E.; RUGGERI, 2013), sendo utilizadas 455 imagens da mesma. Após os testes realizados, a seguinte configuração apresentou os melhores resultados: Cartesian Grid, como abordagem de decomposição espacial, com a variante CLBP, alcançando acurácia de 89%. Com o melhor configuração detectada, o autor ainda realizou mais testes na ferramenta AUTOWEKA (THORNTON et al., 2013), onde o mesmo sinalizou o Voted Perceptron como melhor classificador, atingindo 90.5% de acurácia.

Por fim, Sousa et al. (2017) propõe um novo método de diagnóstico do glaucoma baseado em Padrões de Locais Binários e funções geoestatísticas para extração de características na região do disco óptico, algoritmos genéticos e máquina de vetores de suporte para a classificação das imagens de exames de retinografia. Nesta abordagem, diferente dos trabalhos citados acima, o autor utiliza os *LBP*s na transformação da representação das imagens, em padrões de textura. Com esta nova representação, são utilizados as funções geoestatísticas para gerar os vetores descritores. As funções escolhidas pelo autor foram a semivariograma, semimadograma, covariograma e correlograma. Na etapa de classificação, as características foram sujeitas ao algoritmo genético, mais especificamente à Metodologia de Evolução α , para escolha do melhor conjunto de treino mediante ao problema e como entrada para o aprendizado supervisionado usando MVS. Os resultados foram baseados em dois tipos de experimentos: resultados obtidos com a seleção do melhor modelo de classificação pelo algoritmo genético e resultados sem a utilização do mesmo. O autor conclui que a utilização da abordagem genética é essencial para a etapa de reconhecimento, visto que a escolha de um modelo adequado dentro da base de treinamento é fundamental para gerar uma boa classificação. Os resultados alcançaram média de 91,2% de acurácia, considerado satisfatório pelo autor.

A Tabela ?? ilustra com mais detalhes os resultados obtidos na literatura reforçando a importância dos métodos propostos e as contribuições que os mesmos proporcionam à comunidade acadêmica e médica.

Tabela 2 – Comparação entre os resultados obtidos na literatura.

Fonte: Elaborado pelo autor.

Autor	ACU	SEN	ESPEC	Base	Quantidade de Imagens
(DUA et al., 2012)	93%			Kasturba Medical College	60
(ARAUJO et al., 2017)	93,41%	92,36%	95,05%	RIM-ONE	455
(SILVA et al., 2018)	89,4	85,5%	92,5%	RIM-ONE	455
(SOUSA et al., 2017)	91,2%	95%	88,2%	RIM-ONE	455

1.3 Estrutura do Trabalho

Após esta breve discussão introdutória, os próximos tópicos abordados estão dispostos em quatro capítulos.

No Capítulo 2 serão discutidos aspectos referentes a fundamentação teórica que embasou a implementação da metodologia proposta, que vão de noções básicas a respeito do olho humano até as principais técnicas de extração de características e reconhecimento de padrões utilizados no âmbito do trabalho.

O Capítulo 3 aborda todos os passos do processo metodológico escolhidos para desenvolvimento deste trabalho, onde serão explanadas e justificadas, minuciosamente, a escolha das técnicas e etapas designadas no trabalho proposto.

O Capítulo 4 ilustra os resultados obtidos com a implementação da metodologia de diagnóstico e, em seguida, a análise dos mesmos.

O Capítulo 5 apresenta as conclusões a respeito do método implementado.


2 Fundamentação Teórica

Com enfoque no embasamento teórico do trabalho proposto, neste capítulo serão abordados os principais conceitos aplicados na metodologia desenvolvida. No primeiro momento serão analisados assuntos referentes ao tema da pesquisa, como o olho humano, o glaucoma e o exame da retinografia. Em seguida, são apresentados os conceitos de processamento de imagens, como os métodos de pré-processamento e extração de características utilizados. Por fim, são abordados conceitos das duas últimas fases do trabalho, o aprendizado de máquina e o reconhecimento de padrões.

2.1 Olho Humano

Principal responsável pelo registro e captura das imagens, o olho humano é fator chave no processo da visão. A sua principal função é a interpretação do espaço visual, convertendo a luz capturada pelo globo ocular em sinais elétricos processados no cérebro. Por ser um órgão composto por tecidos sensíveis com funções cognitivas essenciais, qualquer dano ocorrido no mesmo pode acarretar em reduções significativas na clareza da visão, limitando assim, o ser humano à diversas ações realizadas no cotidiano (RODRIGUES, 2016).

Figura 2 – Corte do globo ocular.



Fonte: ADAPTADO DE (GONZALEZ; WOODS, 2010).

A Figura 2 ilustra as partes do olho humano a partir de uma secção horizontal. O olho possui um formato aproximado de uma esfera, com diâmetro médio de 20 mm. Três membranas o envolvem: a córnea e a esclerótica, responsáveis pela cobertura externa, a retina e a coróide. A córnea é um tecido transparente com alta capacidade resistiva que envolve a superfície anterior do olho. A sua continuidade é denominada de esclera, membrana opaca responsável pela cobertura restante do globo óptico (GONZALEZ; WOODS, 2010).

A retina encontra-se na superfície mais interna do olho. É a principal responsável pela formação das imagens, ou seja, pelo sentido da visão. Além de ser composta por milhares de células sensíveis à luz, a retina possui uma parte interna de tecido nervoso e uma externa pigmentada. O processo de formação da imagem é composto pela projeção da mesma na região da retina, seguida do envio da informação para o cérebro, por meio de impulsos elétricos.

Por fim, a coróide encontra-se entre retina e a esclera e tem como função principal o envio de vasos sanguíneos para nutrir a retina (GONZALEZ; WOODS, 2010).

Outra parte que compõe o olho humano a se destacar é o nervo óptico, local onde se encontram as lesões ocasionadas pelo glaucoma. Nele estão presentes os agrupamentos das fibras fotorreceptoras que conecta cada globo ocular ao cérebro, enviando a informação visual para ser processada (GONZALEZ; WOODS, 2010).

O entendimento das funções do membro ocular e suas formações são essenciais para o desenvolvimento de uma metodologia para diagnóstico do glaucoma, visto que, o embasamento eficaz proporciona a imersão no meio do problema, papel fundamental na busca pela solução do mesmo.

2.2 Retinografia

A retinografia é um exame oftalmológico que fotografa as áreas do fundo do olho como a retina, a coróide, o nervo óptico e os vasos sanguíneos. Este exame serve para constatação ou acompanhamento de anormalidades que ponham em risco a acuidade visual do paciente, como o glaucoma, retinopatia diabética, degeneração macular e oclusões vasculares da retinas (WGA, 2017).

O exame é realizado da seguinte forma: com a pupila dilatada, o paciente assenta-se em frente ao retinógrafo, aparelho responsável pela captura das imagens, o olho é iluminado por uma fonte de luz interna, permitindo a observação médica (WGA, 2017).

A retinografia pode ser dividida em dois tipos: a retinografia simples e a panorâmica. A principal diferença entre as duas encontra-se no fato de que uma (simples) refere-se ao procedimento citado no parágrafo anterior. O segundo (panorâmico) é realizado com

aparelhos mais modernos, com recursos que permitem a captura de imagens panorâmicas, possibilitando uma visão com maior amplitude, facilitando a detecção de doenças em um maior campo do globo óptico (WGA, 2017).

As imagens analisadas na metodologia de diagnóstico proposta são provenientes de capturas de fundo de olho no exame da retinografia. A Figura 3 ilustra o processo realizado no mesmo.

Figura 3 – Exame de retinografia.



Fonte: (BUCAR, 2018).

2.3 Glaucoma

O glaucoma é uma doença crônica, ocular e silenciosa causada por inúmeros fatores. Por não apresentar sintomas imediatos, as lesões no nervo óptico evoluem de forma gradual até que a visão apresente graves prejuízos, causando em inúmeros casos, a cegueira total (ABRIL, 2018).

Em pesquisa realizada pela (SBG, 2012), dados comprovam que 40% dos participantes entrevistados acreditavam que o quadro glaucomatoso é curável. Entre os indivíduos acima de 40 anos de idade, um terço não sabiam da existência da doença. A pesquisa ainda revela que cerca de 50 milhões de brasileiros nunca foram a um oftalmologista.

Entre os fatores de risco, ter um histórico familiar aumenta em 6% as chances de desenvolver a patologia. Além disso, a pressão intraocular elevada, indivíduos com mais de 40 anos de idade, e doenças como diabetes e pressão alta também são listados como aspectos que influenciam no desenvolvimento do glaucoma (CLINIC, 2015).

A doença pode ser classificada de acordo com diversos critérios, porém, os dois tipos mais comuns são o glaucoma primário de ângulo aberto (GPAA) e o glaucoma

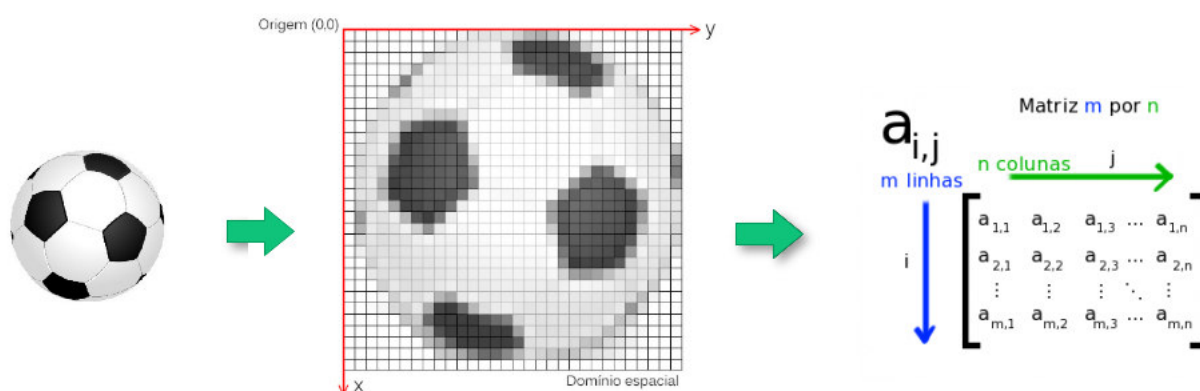
primário de ângulo fechado (GPAF). O primeiro, que representa cerca de 90% das pessoas afetadas, é caracterizado pelo comportamento assintomático e pela obstrução da drenagem do humor aquoso do olho. Por outro lado, o GPAF tem como principal característica o aumento súbito da pressão intraocular (PIO). Este comportamento pode ser estimulado por ingestão de medicamentos que dilatam a pupila ou ser apenas um fator secundário proveniente de outras doenças (WGA, 2017).

2.4 Processamento de Imagens

As técnicas de processamento de imagens, em linhas gerais, têm o intuito de realizar procedimentos na imagem de aquisição a fim de obter melhorias no aspecto visual, características que influem diretamente na eficiência dos processos seguintes de uma metodologia de diagnóstico, como a extração de características e o reconhecimento de padrões.

Para Gonzalez e Woods (2010), este campo de estudo refere-se ao processamento de imagens por um computador digital onde cada imagem tem a seguinte composição: um número finito de elementos, com locais e valores específicos, denominados *pixels*. Este ainda afirma que as imagens são denotadas por uma função bidimensional na forma de $f(x,y)$ onde esta pode ser caracterizada por dois componentes: (1) A quantidade de fonte luminosa incidente na cena vista e (2) a quantidade de iluminação refletida pelos objetos da cena. A Figura 4 ilustra a representação de uma imagem digital por meio de uma matriz bidimensional.

Figura 4 – Representação de uma imagem em formato matricial.

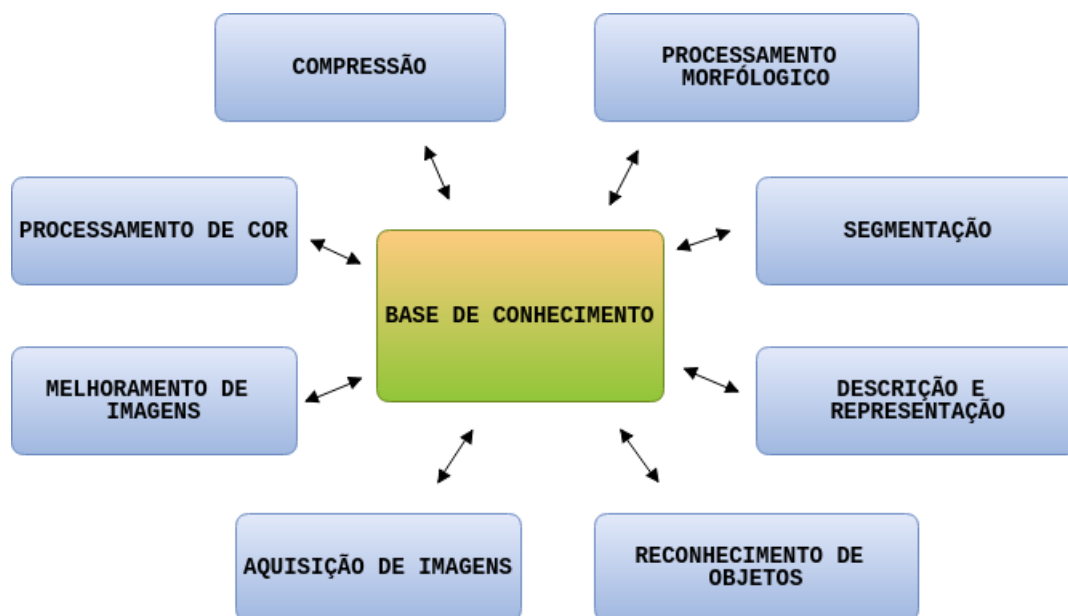


Fonte: Elaborado pelo Autor.

Diversos passos podem ser aplicados no âmbito do processamento de imagens digitais. A Figura 5 ilustra as diversas possibilidades que englobam as técnicas de PI. O primeiro processo a se destacar é a aquisição de imagens. Este é o primeiro processo realizado na maioria das aplicações envolvendo processamento em imagens digitais. Esta

etapa pode ser caracterizada pela simples coleta de imagens no formato digital onde, na maioria das metodologias, é submetida a operações de pré-processamento.

Figura 5 – Etapas que englobam o processamento de imagens.



Fonte: ADAPTADO DE (GONZALEZ; WOODS, 2010).

Outro fundamento passível de análise é o melhoramento de imagens, uma das áreas mais importantes no fluxo de manipulação de imagens. Basicamente, a ideia por trás das técnicas de melhorias encontra-se na máxima extração de detalhes, antes obscuros na imagem, ou no realce de determinadas características, denominadas regiões de interesse. É importante ressaltar que as técnicas utilizadas durante essa fase são subjetivas, ou seja, sua aplicabilidade é definida de acordo com a metodologia escolhida.

O processamento de cor é uma área que tem ganhado importância devido ao aumento significativo do uso de imagens digitais provenientes da Internet. A compressão diz respeito às técnicas para redução do espaço de armazenamento ou da largura de banda requerida para transmiti-lá.

As três áreas seguintes possuem um nível de relacionamento alto, pois a saída de uma etapa é utilizada na entrada da próxima. A primeira a ser destacada é a segmentação, processo caracterizado pela captura de uma imagem e separação de uma determinada parte da mesma. Em geral, segmentação automática é uma das tarefas com maior nível de dificuldade no fluxo do processamento de imagens digitais, interferindo diretamente no sucesso ou fracasso das etapas posteriores. Uma segmentação eficaz significa, na maioria dos casos, o direcionamento a metodologias robustas com altas taxas de acurácia, como a identificação individual de objetos. Em conjunto com a segmentação podem ser aplicadas técnicas de processamento morfológico que têm como finalidade a extração de componentes da imagem que serão úteis na terceira etapa, a representação e descrição. Esta recebe as

saídas do processos citados anteriormente, geralmente um conjunto de dados brutos (pixels), e realiza a conversão para uma forma adequada para o processamento computacional. Um fato a ser analisado durante esta fase é como os dados devem ser representados: como um conjunto de pixels segmentado ou todos os pontos da região analisada. A primeira abordagem é mais apropriada quando o foco do estudo é direcionado a análise de bordas, cantos e inflexões da imagem. Por outro lado, a abordagem regional está relacionada a avaliação de características internas como textura.

A escolha de uma representação é apenas uma parte da solução para transformação dos dados em uma forma adequada para o processamento do computador. Um método de descrição deve ser especificado para determinar as características de interesse. O processo de descrição atua na coleta de características que resultam em um determinado quantitativo de informações de interesse.

Por fim, a etapa de reconhecimento é caracterizada pela classificação de objetos dentro de um número de categorias ou classes baseada nos seus descritores. Esses objetos de estudo variam de acordo com a abordagem metodológica escolhida, podendo ser imagens, sinais em formas de ondas ou qualquer medida passível de classificação.

2.4.1 Transformação de RGB para Tons de Cinza

A conversão dos canais de cores para escala de cinza é um artifício comumente utilizado em metodologias de processamento de imagens. A principal razão por esta escolha encontra-se no fato de que operar em tons de cinza simplifica a complexidade do algoritmo e reduz de maneira considerável o custo computacional (KANAN; COTTRELL, 2012).

O canal RGB é a abreviatura para o sistema de cores aditivas em que o Vermelho (*Red*), o Verde (*Green*) e o Azul (*Blue*) são dispostos em diversas combinações de modo a reproduzir um largo espectro cromático. Este modelo é baseado na teoria de visão colorida tricômica (YOUNG, 1802) combinado com os estudos do triângulo de cores (MAXWELL; NIVEN, 1890).

Entre os métodos propostos na literatura, destacam-se três: o $G_{Intensity}$, considera o mais simples deles, resultante do cálculo da média dos três canais, representado pela Equação 2.1 (KANAN; COTTRELL, 2012).

$$G_{Intensity} \leftarrow \frac{1}{3}(R + G + B) \quad (2.1)$$

Ao contrário da *Intensity* é projetado para combinar a percepção de brilho humano usando a combinação ponderada dos canais RGB, operação ilustrada pela Expressão 2.2

(KANAN; COTTRELL, 2012).

$$G_{Luminance} \leftarrow 0.3R + 0.59G + 0.11B. \quad (2.2)$$

Por último, o G_{Value} é o canal V presente no sistema de cores HSV (*Hue*, *Saturation* e *Value*) e prover a informação de brilho. É computado tomando o máximo dos canais RGB. Esta conversão é expressa pela Equação 2.3 (KANAN; COTTRELL, 2012).


$$G_{Value} = \max(R, G, B). \quad (2.3)$$

Dentre as três operações descritas acima, foi optado para utilização no trabalho a abordagem da conversão $G_{Luminance}$, devido a definição do maior peso nos canais Vermelho e Verde, mais presentes em imagens de exames retinográficos.

2.4.2 Equalização de Histograma

O histograma de uma imagem digital com níveis de intensidade entre $[0, L-1]$ é uma função discreta $h(r_k) = n_k$, onde r_k é o k -ésimo valor de intensidade e n_k corresponde ao número de *pixels* na imagem com intensidade r_k . Histogramas são a base para inúmeras técnicas de processamento de domínio espacial. Estas técnicas podem ser usadas para aprimoramento de imagens, como funções de realce e *matching*.

Figura 6 – Exemplo de histogramas. Em a) imagens com tonalidades escuras e b) tonalidades claras.



Fonte: ADAPTADO DE (GONZALEZ; WOODS, 2010).

Uma das técnicas de realce de características comumente utilizada é a equalização de histograma. Esta visa redistribuir os valores de tons de cinza dispostos em uma imagem, com o intuito de gerar um histograma uniforme e o número de *pixels* para qualquer nível de cinza seja o mesmo. Como consequência, uma imagem com melhor contraste é obtida.

Considerando $h(r_k)$ um histograma calculado em uma imagem I , o cálculo do histograma acumulado de $h(r_k)$ pode ser descrito na Equação 2.4:

$$H(0) = h(0); H(1) = H(0) + h(1); H(r_k) = H(r_k - 1) + h(r_k) \quad (2.4)$$

para $r_k = 1, \dots, L - 1$. O novo histograma é definido por 2.5:

$$T(r_k) = \text{round}\left(\frac{L-1}{MN} H(r_k)\right) \quad (2.5)$$

onde M e N representam as dimensões da imagem analisada. A imagem equalizada é obtida por pixel $I = T(r_k)$.

2.5 Extração de Características

2.5.1 Análise de Textura

Uma importante abordagem na descrição de características baseado em regiões é a quantificação quanto ao seu conteúdo de textura. Apesar de não existir uma definição formal para este aspecto, este descritor fornece medidas de propriedades da imagem como suavidade, grossura e regularidade (GONZALEZ; WOODS, 2010).

Haralick et al. (1973) definem textura a partir de medidas de uniformidade, densidade, aspereza, regularidade e intensidade, entre outras características da imagem.

As três principais abordagens para descrição de textura mais utilizadas no contexto do processamento de imagens são:

- Estatística: abordagens estatísticas produzem caracterização de texturas como suave, grossa, granulosa e assim por diante.
- Estrutural: técnicas estruturais lidam com o arranjo primitivo da imagem, como a descrição da textura baseada em linhas paralelas espaçadas.
- Espectral: técnicas espectrais são baseadas nas propriedades dos espectros e são usadas principalmente para detectar a periodicidade global em uma imagem identificando picos estreitos de alta energia.

A textura também pode ser entendida como uma característica 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 da imagem (BRAZ, 2008).

2.5.2 Local Binary Pattern (LBP)

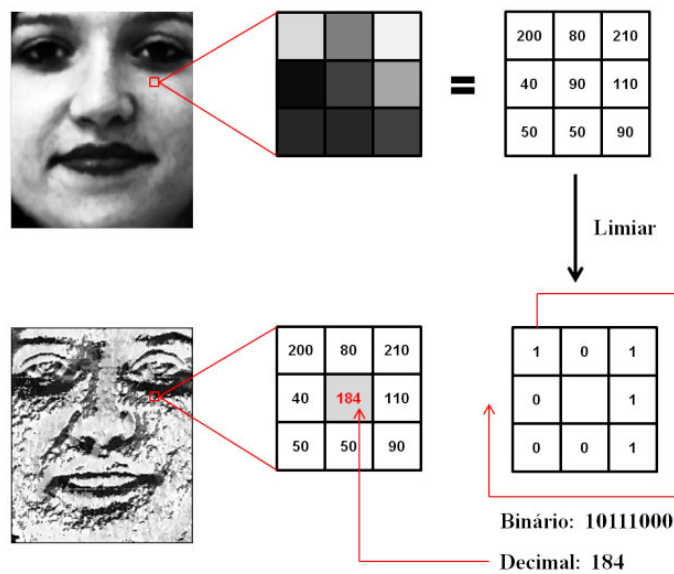
O *Local Binary Pattern*, originalmente proposto por OJALA T.; PIETIKÄINEN (1996), surgiu como uma maneira eficiente e simples de descrever textura, podendo ser combinado com outros descritores (WANG et al., 2015). Em termos gerais, o LBP é considerado um operador não paramétrico para descrever a estrutura espacial local da imagem, caracterizado por sua alta capacidade de distinguir características de textura.

O método é baseado na extração de informações de textura local a partir da estipulação de um limiar para um número P de vizinhos, no valor do *pixel* central em uma vizinhança local. A Função 2.10 descreve o cálculo do LBP,

$$LBP(x_c, y_c) = \sum_{n=0}^{n-1} S(i_n - i_c) 2^n \quad (2.6)$$

onde n é o número de vizinhos do pixel localizado no centro (x_c, y_c) considerados no cálculo, i_c é o valor de nível do *pixel* central, i_n corresponde ao valor de nível de cinza de cada *pixel* vizinho e S(x) uma função que tem como retorno 1 se $x \geq 0$ e 0, no caso oposto.

Figura 7 – Exemplificação de aplicação do operador LBP.



Fonte: (AMARAL; THOMAZ, 2011).

A Figura 7 exemplifica o processo do descritor binário. Dada uma janela de tamanho 3x3 sobreposta ao *pixel* central, tomando este como referência, é realizada a comparação com os *pixels* vizinhos. Os valores obtidos para cada posição vizinha são concatenados e o número binário é convertido na base decimal para substituir o valor central. Geralmente, a imagem analisada é dividida em *grids* e são extraídos os resultados de cada região isoladamente, por meio do cálculo do histograma de intensidade dos *pixel*. No final do

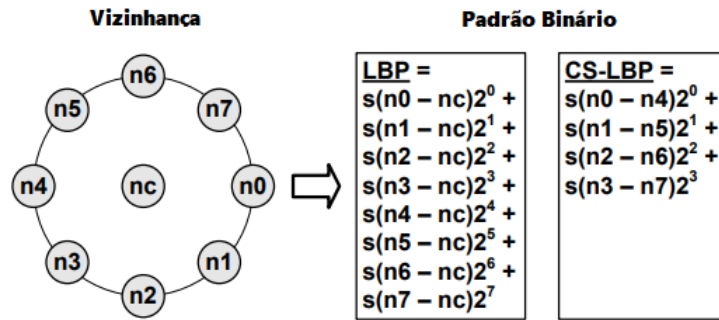
processo, os vetores resultantes são construídos a partir da concatenação em uma única matriz para utilização em etapas futuras, como por exemplo, na classificação.

2.5.3 Center-Symmetric Local Binary Patterns (CS-LBP)

Proposto por Heikkilä, Pietikäinen e Schmid (2006), o Center-Symmetric Local Binary Patterns (CS-LBP) é apresentado como uma variante ao LBP original (OJALA T.; PIETIKÄINEN, 1996), baseado na comparação entre pares simétricos de *pixels*.

O método proposto analisa a capacidade de invariância do descritor com relação à rotação, escala e luminosidade. Um descritor eficiente deve ser tolerante à mudanças de iluminação, ruídos, borrões, compressões e distorções, preservando seu caráter distintivo. Para isso, os autores sugerem a combinação dos pontos fortes encontrados nos descritores LBP e SIFT (LOWE, 1999).

Figura 8 – Comparativo do cálculo realizado para extração do vetor descritor para LBP e CS-LBP.



Fonte: ADAPTADO DE (HEIKKILÄ; PIETIKÄINEN; SCHMID, 2006).

Com o objetivo de gerar padrões binários compactos, o CS-LBP realiza a comparação apenas de pares de *pixels* simétricos, com um total de quatro comparações ao longo dos quatro eixos (vertical, horizontal, diagonal e anti-diagonal), como ilustra a Figura 8. É possível analisar que em uma situação de 8 *pixels* de vizinhança, o LBP produz 256 padrões binários diferentes, enquanto o CS-LBP produz apenas 16. A variante pode ser expressa segundo a Equação 2.7.

$$CS-LBP_{R,N,T}(x,y) = \sum_{i=0}^{(N/2)-1} S(n_i - n_{i+(N/2)})2^i, \quad s(x) = \begin{cases} 1 & \text{se } x > T \\ 0 & \text{caso contrário} \end{cases} \quad (2.7)$$

onde n_i e $n_{i+(N/2)}$ correspondem aos valores na escala de cinza dos pares centro-simétricos de *pixels* igualmente espaçados em um círculo de raio R. Nos experimentos realizados para validação do descritor, o valor do limiar T foi determinado como 1% do intervalo de

valores de *pixels*, o valor R do raio como 2 e tamanho T da vizinhança igual a 8. Como benefícios, o CS-LBP propõe à redução significativa quanto a dimensionalidade dos padrões preservando o padrão distintivo.

2.5.4 Extend Local Binary Pattern (E-LBP)

O LBP, originalmente proposto por OJALA T.; PIETIKÄINEN (1996), é invariante a qualquer transformação monótona na escala de cinza, ou seja, o vetor descritor resultante não é afetado ao final da aplicação do operador. Tal condição é possível devido a análise apenas dos sinais de diferença em vez dos exatos valores da escala de cinza. Considerando a textura T expressa na Equação 2.8:

$$T \approx t(s(g_0 - g_c), s(g_1 - g_c), \dots, s(g_{P-1} - g_c)) \quad (2.8)$$

em uma vizinhança local com níveis de cinza de $P(P>1)$ *pixels* de imagem. Onde $g_p (p = 0, \dots, P-1)$ valores de cinza, com g_c sendo o valor de cinza do pixel central e

$$s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (2.9)$$

onde o sinal é 1 caso positivo e 0 caso negativo. A operação ilustrada na Equação 2.9 é transformada em um código único de padrão P-bit, atribuindo coeficiente binomial 2^p para cada sinal $s(g_p - g_c)$, resultando na Equação 2.10:

$$LBP_{P,R} = \sum_{p=0}^{P-1} S(g_p - g_c) 2^p \quad (2.10)$$

onde as características extraídas do LBP são calculadas utilizando a invariante de rotação LBP com *padrões uniformes* (estruturas circular uniformes), onde a equação final pode ser descrita em 2.11 e 2.12.

$$LBP_{P,R}^{riu2} = \begin{cases} \sum_{p=0}^{P-1} S(g_p - g_c) 2^p & \text{se } U(LBP_{P,R}) \leq 2 \\ P + 1 & \text{caso contrário} \end{cases} \quad (2.11)$$

$$\text{onde } U(LBP_{P,R}) = |s(g_{P-1} - g_c) - s(g_0 - g_c)| + \sum_{p=0}^{P-1} |s(g_p - g_c) - s(g_{p-1} - g_c)| \quad (2.12)$$

no qual U("padrão") é medida de uniformidade, a qual corresponde ao número de transições espaciais no padrão e o sobrescrito *riu2* é a rotação invariante uniforme que tem 2 como valor máximo de U.

Apesar de ser uma excelente medida do espaço padrão, esta abordagem descarta o contraste da imagem. Com este intuito, [Ojala, Pietikainen e Maenpaa \(2002\)](#) sugeriram o Extend Local Binary Pattern (E-LBP). Caso a invariância da escala de cinza não seja necessária e a capacidade de incorporar a análise de contraste local da imagem seja exigida, é possível calcular o mesmo a partir da invariante de rotação de variância local, dado pela Expressão 2.13 ilustrada abaixo.

$$VAR_{P,R} = 1/P \sum_{p=0}^{P-1} (g_p - \mu)^2, \quad \text{onde} \quad \mu = 1/P \sum_{p=0}^{P-1} g_p \quad (2.13)$$

onde $VAR_{P,R}$ é por definição invariante a mudanças em escala de cinza. Para melhorar a performance do algoritmo de descrição, [Ojala, Pietikainen e Maenpaa \(2002\)](#) sugeriram combinar a distribuição LBP com a medida de variância local denotada por $LBP_{P,R}^{riu2}/VAR_{P,R}$.

2.5.5 eXtended Center-Symmetric Local Binary Pattern (XCS-LBP)

Em [Heikkilä, Pietikäinen e Schmid \(2006\)](#) é proposto a comparação dos níveis de cinza dos pares de *pixels* com direções centro-simétricas ao invés de comparar o pixel central com seus vizinhos, como apresentado em [OJALA T.; PIETIKÄINEN \(1996\)](#). Assumindo um número igual P de *pixels* vizinhos, o operador CS-LBP é dado pela Equação 2.14:

$$CS-LBP_{R,N,T}(x,y) = \sum_{i=0}^{(N/2)-1} S(n_i - n_{i+(N/2)})2^i, \quad s(x) = \begin{cases} 1 & \text{se } x > T \\ 0 & \text{caso contrário} \end{cases} \quad (2.14)$$

onde o valor de T é um limiar definido de acordo com a metodologia proposta. Partindo do ponto que os níveis de cinza estão normalizados em [0,1], os autores recomendam usar um valor menor para o limiar.

Com o propósito de sugerir uma variante do método descrito acima, [Silva, Bouwmans e Frélicot \(2015\)](#) propuseram o XCS-LBP (eXtend CS-LBP), um operador binário que visa a comparação dos níveis de cinza dos pares centro-simétricos considerando também o *pixel* central, gerando um histograma de dimensão reduzida. A variante pode ser expressa pela Equação 2.15:

$$XCS-LBP_{P,R}(c) = \sum_{i=0}^{(P/2)-1} s(g_1(i,c) + g_2(i,c))2^i \quad (2.15)$$

onde a função de limiarização s , a qual é utilizada para determinar os tipos de transição

de padrão local, podendo ser definida pela Equação 2.16:


$$s(x_1 + x_2) = \begin{cases} 1 & \text{se } (x_1 + x_2) \geq 0 \\ 0 & \text{caso contrário} \end{cases} \quad (2.16)$$

e $g_1(i, c)$ e $g_2(i, c)$ são definidos pela Equação 2.17:

$$\begin{aligned} g_1(i, c) &= (g_i - g_c + (P/2)) + g_c \\ g_2(i, c) &= (g_i - g_c)(g_i + (P/2) - g_c) \end{aligned} \quad (2.17)$$

É importante ressaltar que, na variante XCS-LBP, a função de *threshold* não exige a definição do valor padrão para a mesma. A computação realizada pelo descritor XCS-LBP para uma vizinhança de tamanho $P=8$ é ilustrada na Figura 9.

Figura 9 – O descritor eXtended CS-LBP.



Fonte: (SILVA; BOUWMANS; FRÉLICOT, 2015).

Entre os benefícios levantados pelo autor, o eXtend CS-LBP produz um histograma menor que o LBP original(OJALA T.; PIETIKÄINEN, 1996), tão menor quanto o CS-LBP e possui a etapa de extração de *features* mais eficaz que outras abordagens. Isto é explicado pelo fato de sua implementação levar em consideração os níveis de cinza do pixel central em conjunto com os vizinhos.

2.5.6 BackGround Local Binary Pattern (BG-LBP)

Os padrões binários locais são invariantes com relação a mudanças monótonas na domínio da escala de cinza. Essa propriedade permite ao operador que apresente bom comportamento em aplicações com mudanças de iluminação local. Todavia, as variantes existentes não contemplam a operação em mudanças significativas na luminosidade das imagens, considerando o contexto completo da mesma. Visto isso, Davarpanah et al. (2016) propõe a variante BackGround Local Binary Pattern (BG-LBP). Esta foi implementada

para aplicações de extração de plano de fundo mas pode ser abstraída como descritor de características.

O algoritmo do descritor BG-LBP visa superar as seguintes lacunas, encontradas nas diversas variantes na literatura: (1) deve ser rápido e o número de *bins* deve ser o menor possível, e (2) deve ser calculado com base nos valores de píxel pertencentes a cada bloco. O operador é calculado segundo as equações 2.18, 2.19 e 2.20:

$$BGLBP_{P,R} = \begin{cases} \sum_{i=0}^{\frac{P}{2}-1} s(g_i, m, g_{\frac{P}{2}+i}) \times 2^i & \text{se } U(LB_{\frac{P}{2}P,R}) \leq 2 \\ 2^P & \text{caso contrário} \end{cases} \quad (2.18)$$

$$s(g_i, m, g_{\frac{P}{2}+i}) = \begin{cases} 1 & \text{se } (((g_i \geq m \geq g_{\frac{P}{2}+i}) \vee (g_i < m < g_{\frac{P}{2}+i})) \&\& \text{abs}(g_i - m) + \text{abs}(g_{\frac{P}{2}+i} - m)) \geq \beta \\ 0 & \text{caso contrário} \end{cases} \quad (2.19)$$

$$m = \frac{1}{P}(g_c + \sum_{i=1}^{P-1} g_i) \quad (2.20)$$

onde $g_i (i = 0, \dots, i = P - 1)$ corresponde aos valores na escala de cinza de P *pixels* igualmente espaçados em um caminho circular de raio R resultando na criação de um conjunto vizinho circular simétrico. g_c corresponde ao valor da intensidade do *pixel* central e U refere-se a um padrão uniforme.

Primeiro, os valores da média de intensidade local são calculadas (Equação 2.20). O valor da média é usado como coeficiente limite de intensidade para detectar as alterações nos *pixels* vizinhos, resultando na redução dos ruídos. A Equação 2.19 detecta as mudanças de intensidade do i -ésimo *pixel* quando o valor da mesma é maior que o valor médio e este é maior que o valor da intensidade do *pixel* correspondente localizado na diagonal ou quando o valor de intensidade do *pixel* é menor que o valor médio e o valor médio é menor que o valor de intensidade do correspondente *pixel* na diagonal.

Usando a condição anterior, as pequenas mudanças de iluminação na imagem são desconsideradas. Isso ajuda a detectar grandes mudanças mais apropriadamente. Como a soma de dois valores diferentes é utilizada com os mesmos valores mínimos, a diferença é considerada como uma mudança de iluminação no BG-LBP. Usando a Equação 2.18, metade das alterações dos *pixels* vizinhos são contabilizadas. Um padrão é uniforme se o número dos bits alterados correspondentes é menor ou igual a 2.

A abordagem do BG-LBP apresenta vantagens em relação a outras variantes. O tempo de processamento e custo de memória são menores comparado às demais implementações de LBPs. Por ser derivado do operador ULBP(HE et al., 2007), o número de *bins* é menor que os computados no LBP original($\log_2 n + 1$ vs. n).

2.6 Seleção de Características

Métodos automáticos de seleção de características são importantes em muitas situações em que se tem disponível um conjunto grande de características e deseja-se selecionar um subconjunto adequado. Além de ser uma forma de redução de dimensionalidade, uma aplicação importante é a fusão de dados procedentes de múltiplas modalidades de sensores ou de múltiplos modelos de dados.

A seleção de recursos é dividida em duas partes: o avaliador de características e o método de pesquisa. O avaliador de atributo é a técnica pela qual cada atributo em seu conjunto de dados (também chamado de coluna ou recurso) é avaliado no contexto da variável de saída (por exemplo, a classe). O método de busca é a técnica pela qual tentar ou navegar diferentes combinações de atributos no conjunto de dados para chegar a uma pequena lista de recursos escolhidos.

2.6.1 Correlation-based Feature Selection (CFS)

A medida *Correlation Feature Selection (CFS)* avalia subconjuntos de recursos com base na seguinte hipótese: "Bons subconjuntos de recursos contêm recursos altamente correlacionados com a classificação, mas não correlacionados entre si" (HALL, 1999). A Equação 2.21 apresenta o mérito de um subconjunto de recursos S que consiste em k características:

$$Merits_{S_k} = \frac{k\bar{r}_{cf}}{\sqrt{k + k(k-1)\bar{r}_{ff}}} \quad (2.21)$$

onde \bar{r}_{cf} representa o valor médio de todas as correlações de classificação de características e \bar{r}_{ff} é o valor médio de todas as correlações de recurso-recurso. O critério CFS é definido da seguinte forma (HALL, 1999):

$$CFS = \max_{S_k} \left[\frac{r_{cf_1} + r_{cf_2} + \dots + r_{cf_k}}{\sqrt{k + 2(r_{f_1f_2} + \dots + r_{f_if_j} + \dots + r_{f_kf_1})}} \right] \quad (2.22)$$

onde as variáveis r_{cf_i} e $r_{f_if_j}$ são referidas como as correlações.

2.6.2 Best-First

A *best-first* é um algoritmo de busca que explora um gráfico expandindo o nó mais promissor escolhido de acordo com uma regra especificada. Pearl (1984) descreveu o método de busca *best-first* como a estimativa da promessa do nó n por uma "função de avaliação heurística $f(n)$ que, em geral, pode depender da descrição de n , a descrição

da meta, a informações coletadas pela busca até aquele ponto, e mais importante, em qualquer conhecimento extra sobre o domínio do problema.

Usando um algoritmo guloso, expanda o primeiro sucessor do pai. Depois que um sucessor é gerado:

1. Se a heurística do sucessor for melhor que seu pai, o sucessor será definido na frente da fila (com o pai reinserido diretamente atrás dele) e o *loop* será reiniciado;
2. Senão, o sucessor é inserido na fila (em um local determinado por seu valor heurístico). O procedimento avaliará os sucessores remanescentes (se houver) do pai.

2.7 Aprendizado de Máquina

O aprendizado de máquina é um conceito baseado em regras de indução. Estas são denotadas como uma forma de inferência lógica que possibilita a tomada de decisões genéricas mediante a análise de um grupo particular de exemplos. A indução pode ser caracterizada como um raciocínio que se origina em um conceito específico e o generaliza, analisando a da parte para o todo (MONARD; BARANAUSKAS, 2003).

A inferência indutiva é um dos principais métodos utilizados para derivar conhecimento novo e prever eventos futuros. Esta pode ser classificada em dois tipos: aprendizado supervisionado e não-supervisionado. No primeiro, mediante o conhecimento dos rótulos das classes analisadas, um algoritmo de aprendizado realiza a predição baseada em um conjunto de exemplos de treinamento (MONARD; BARANAUSKAS, 2003).

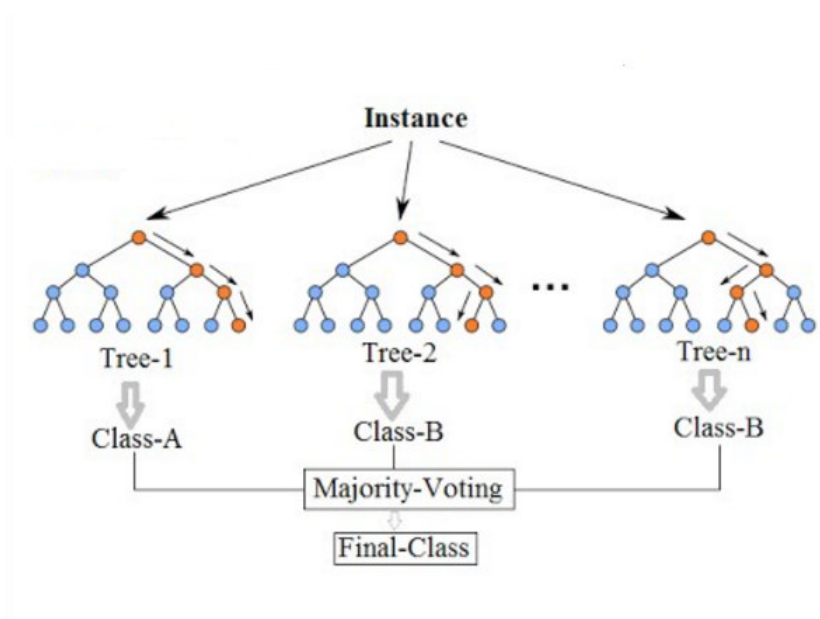
Abstraindo para a campo da computação, os exemplos são denominados de vetores de características, ou atributos, e o rótulo da classe referente. Neste caso, o principal objetivo do algoritmo é construir um modelo matemático (classificador) capaz de determinar a qual classe pertence amostras ainda não rotuladas. Para os rótulos de classes com valores discretos, ou seja, quantidades finitas enumeráveis, a problemática é conhecida como *classificação*, e para valores contínuos é denominado *regressão* (MONARD; BARANAUSKAS, 2003).

Por outro lado, no aprendizado não-supervisionado nenhum tipo de rótulo é fornecido ao algoritmo de aprendizado. Este analisa os dados fornecidos e busca semelhança entre os mesmos, formando *agrupamentos* ou *clusters*. Após os agrupamentos criados, é realizada uma análise para determinar a significância de cada um no contexto da metodologia apresentada (MONARD; BARANAUSKAS, 2003).

2.7.1 Random Forest

O método de aprendizado *Random Forest* consiste em um conjunto de árvores de decisão geradas dentro de um mesmo contexto. Esse conjunto passa por um mecanismo de votação (*bagging*), que elege a respectiva classificação com maior número de votos. A classificação é representada nos nós terminais das mesmas (BREIMAN, 2001).

Figura 10 – Representação da método Random Forest ilustrando a escolha da melhor classificação.



Fonte: (BREIMAN, 2001)

Simplificando, o algoritmo visa a construção de um conjunto de árvores correlacionadas. A partir da criação de árvores de decisão é realizada a classificação. Cada árvore de decisão realizará uma predição a partir das características do indivíduo que a mesma representa. Ao fim do processo, é realizada uma comparação com os resultados obtidos por todas e é escolhida a melhor configuração (BREIMAN, 2001).

Em outras palavras, o método *Random Forest* é um tipo de *ensemble learning*, método que gera muitos classificados e ao final do processo, os resultados são agregados. A partir da geração de múltiplas árvores de decisão pode-se realizar a classificação de novas instâncias (BREIMAN, 2001).

2.7.2 Máquina de Vetores de Suporte

A Máquina de Vetores de Suporte é um modelo de aprendizado de máquina supervisionado utilizado para realizar classificação. Levando em consideração um conjunto de dados de entrada, o objetivo da técnica é definir a qual classe cada dado pertence. O modelo MVS está baseado no princípio da construção de um hiperplano que sirva como


superfície de tomada de decisão, considerando que a distância entre os pontos dos dados, de ambas as classes, mais próximas ao hiperplano, seja máxima.

Proposto por (VAPNIK V. N, 1992), a técnica é amplamente utilizada na área de reconhecimentos de padrões e mineração de dados por possuir elevada taxa de acerto. Com fundamentação metodológica baseada na Teoria de Aprendizado Estatístico (VAPNIK, 2013), teoria que quantifica os registros classificados de forma incorreta e por meio de induções, gera um modelo de predição que torne o erro sobre os dados de entrada mínimo, até que um limite seja considerado admissível.

A partir de um conjunto de amostras de treinamento (x_i, y_i) , sendo $x_i \in R^n$ o valor de entrada, y_i a classificação correta dos dados e $i = 1, \dots, n$ o índice de cada ponto amostral. O objetivo da classificação encontra-se na estimação da função $f = R^n \rightarrow \pm 1$, que separe corretamente os exemplos de teste em classes distintas.

Os vetores de suporte maximizam a margem de separação entre as classes definidas no problema. Porém, nele podem haver até um número infinito de dimensões. Todavia, mesmos para os casos de classes não separáveis, os conceitos provenientes da Teoria do Aprendizado Estatístico permitem encontrar o hiperplano ótimo.

Figura 11 – Representação das curvas de decisão adotadas em conjunto de treinamento binário.



Fonte: ADAPTADO DE (VAPNIK V. N, 1992)

A etapa de treinamento estima a função $f(x) = (w \cdot x) + b$, procurando por valores de w e b tais que a relação representada pela equação 2.23 abaixo.

$$y_i((w \cdot x_i) + b) \geq 1 \quad (2.23)$$

onde w é o vetor normal ao hiperplano de decisão e b , a distância da função f em relação à origem.

A função kernel de base radial, Radial Basis Function (RBF), é uma função de núcleo comumente utilizada em aplicações na área de reconhecimento de padrões e foi utilizada neste trabalho.

$$K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (2.24)$$

2.7.3 Regressão Logística

A Regressão Logística é uma técnica estatística que tem como objetivo produzir, a partir de um conjunto de observações, um modelo que permita a predição de valores tomados por uma variável categórica, frequentemente binária, a partir de uma série de variáveis explicativas contínuas e/ou binárias (AGRESTI, 2018).

Ela consiste, fundamentalmente, na busca de um modelo que seja capaz de assimilar uma determinada variável Y , denominada de "variável resposta", aos "fatores" X_1, \dots, X_{p-1} , supondo-se que estas, influenciam as ocorrências de um evento. Visto que é mais usual o uso das variáveis em sua forma dicotômica, neste caso existe o interesse apenas na ocorrência, ou não, do evento em questão (AGRESTI, 2018).

No modelo logístico, a relação é ilustrada pela seguinte função (ver Equação 2.25) do tipo sigmoide:

$$Y = \frac{e^\mu}{1 + e^\mu} \quad (2.25)$$

onde μ é uma expressão que relaciona os fatores acima e tem como representação

$$\mu = \beta' * X + \epsilon = \beta_0 + \beta_1 * X_1 + \beta_2 * X_2 + \dots + \beta_{p-1} * X_{p-1} + \epsilon = \beta_0 + \sum_{i=1}^{p-1} \beta_i * X_i + \epsilon \quad (2.26)$$


O gráfico da função sigmoide é ilustrado na Figura 12. A função 2.25 assume valores entre 0 e 1 para $\mu \in (-\infty, \infty)$.

O *score* y representa a probabilidade de ocorrência de um determinado evento associado a "1", dessa forma, $y = P(\underline{X} \in W_1) = P(\underline{X})$. Dessa forma, tem-se que:

$$P(\underline{X}) = \frac{e^{\beta_0 + \sum_{i=1}^{p-1} \beta_i * X_i}}{1 + e^{\beta_0 + \sum_{i=1}^{p-1} \beta_i * X_i}} \quad (2.27)$$

onde a estimação dos coeficientes $\beta_0, \beta_1, \dots, \beta_{p-1}$ é feita através do Método da Máxima Verossimilhança.

Figura 12 – Gráfico da função sigmoide.



Fonte: (GUIMARÃES; NETO, 2002)

2.8 Métricas de Validação

Os estudos de avaliação são frequentemente descritos como testes de validade dos diagnósticos e é um dos mais importantes atos na área da Medicina. Para elaborar um diagnóstico, é necessário utilizar métodos que permitam distinguir entre populações de doentes e não doentes, ou seja, o teste de diagnóstico. O grande empecilho desta tarefa encontra-se no fato de não existir um estudo de referência, usando-se como comparativo na maioria das pesquisas, o melhor procedimento disponível na literatura.

Visto isso, recomenda-se que após a etapa de reconhecimento de padrões seja realizada uma validação dos resultados produzidos, pelo fato do mesmo ser um processo que resulta em uma probabilidade. Desta forma, em problemas deste âmbito, costuma-se medir o desempenho da metodologia calculando algumas métricas estatísticas.

De acordo com Luna (1999), no âmbito das metodologias na área da saúde, a estrutura básica dos testes de classificação tem em seu objetivo definir o quão bem um teste discrimina a presença ou ausência da patologia. À vista disso, analisando uma determinada doença com quadros positivos e negativos, estes podem ser subdivididos no seguintes grupos:

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

Mediante os grupos citados acima, as métricas estatísticas normalmente calculadas sobre os resultados para mensurar a performance de um classificador no domínio de análise

de imagens médicas são a acurácia (A), a sensibilidade (S) e a especificidade (E) (BLAND, 2015).

A acurácia refere-se a capacidade do método possuir um resultante correto. Ela é responsável por determinar a eficácia do diagnóstico e pode ser representada pela Expressão 2.28:

$$A = \frac{VP + VN}{VP + FP + VN + FN} \quad (2.28)$$

A sensibilidade define-se como sendo a capacidade de um teste de diagnóstico identificar corretamente os indivíduos que possuem a doença. Esta pode ser definida pela Equação 2.29:

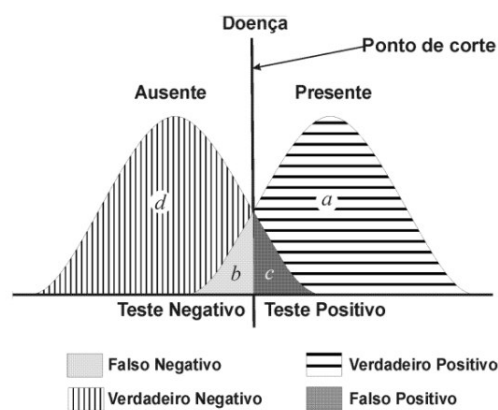
$$S = \frac{VP}{VP + FN} \quad (2.29)$$

Por fim, a especificidade mede a proporção de pessoas sem a doença analisada, ou seja, quando o resultado do teste é negativo. A métrica pode ser representada segundo a expressão 2.30:

$$E = \frac{VN}{VN + FP} \quad (2.30)$$

Ao se realizar um teste de diagnóstico comparando duas populações, a que possui a doença e a outra sem, dificilmente é possível visualizar uma separação total entre os grupos, como ilustra a Figura 13.

Figura 13 – Disposição das distribuições na comparação entre os resultados de um teste em pacientes com e sem a doença.



Fonte: (SILVA, 2004).

Além das três métricas descritas acima, para validação da metodologia, também foi utilizada a métrica de precisão. Esta por de ser descrita pela Equação 2.31:

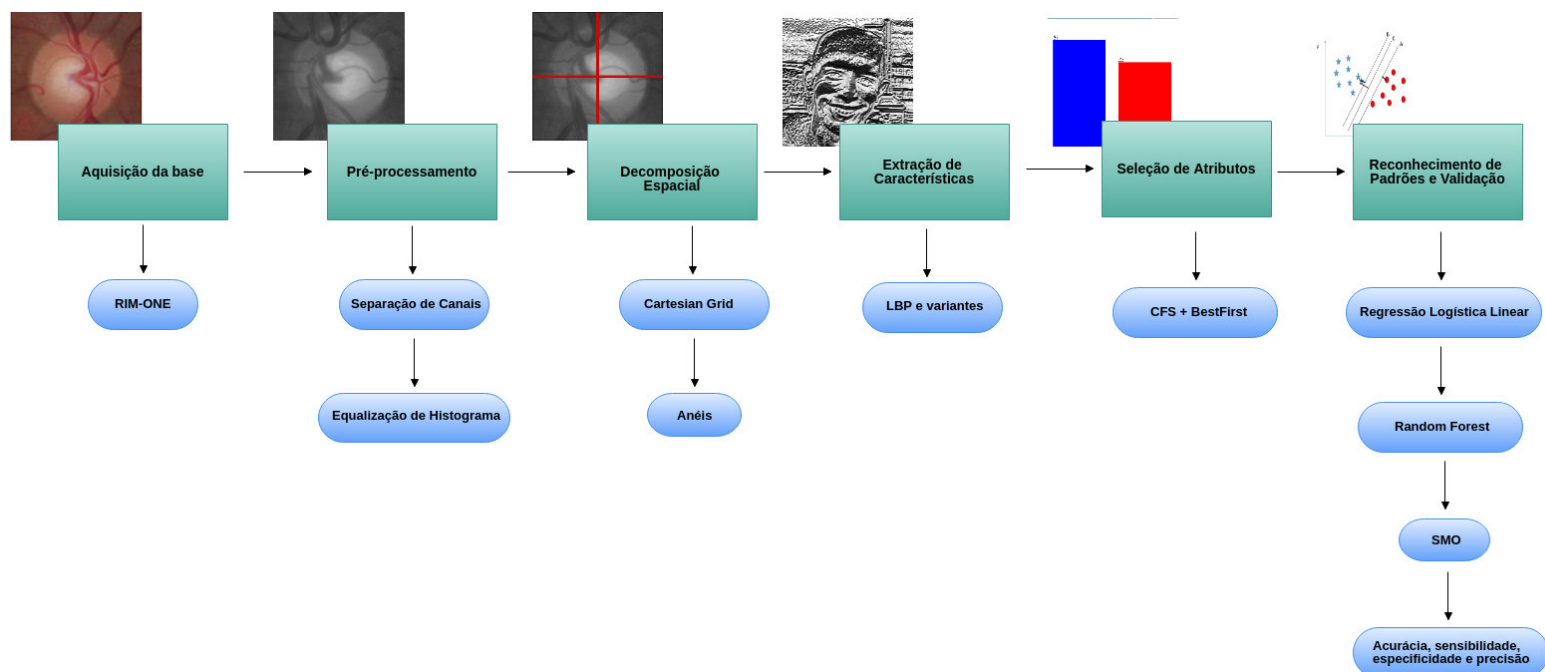
$$P = \frac{VP}{VP + FP} \quad (2.31)$$

3 Metodologia

O enfoque deste capítulo encontra-se na apresentação da metodologia proposta nesta monografia. Conforme já apresentado, o objetivo deste trabalho consiste em apresentar uma análise de descritores de textura para o diagnóstico do glaucoma.

Nesta seção são descritos detalhadamente os procedimentos realizados da aquisição da base até a validação dos resultados obtidos. A metodologia proposta possui as seguintes etapas: (1) Aquisição da base; (2) Realização de operações de pré-processamento; (3) Extração de características; (4) Reconhecimento de padrões e (5) Validação dos resultados obtidos. O esquema proposto está ilustrado na Figura 14.

Figura 14 – Etapas da metodologia proposta.



Fonte: Elaborado pelo Autor.


3.1 Aquisição da base

Nesta etapa do projeto, o foco central é na aquisição das imagens obtidas pelo exame da retinografia. A base de imagens de fundo de olho utilizada é a RIM-ONE, em sua segunda versão (TRUCCO E.; RUGGERI, 2013). Esta possui 455 imagens divididas em duas classes: A classe *Normal*, com 255 imagens de retinas saudáveis, e a classe *Glaucoma and Suspicious*, possuindo 200 imagens de retinas com glaucoma ou suspeitas. As imagens

da base foram fornecidas por três diferentes hospitais: Hospital Clínico San Carlos, Hospital Universitario Miguel Servet e Hospital Universitario de Canarias.

As imagens são fornecidas no formato JPEG, sistemas de cor RGB e acompanhadas por uma marcação do disco óptico. Na Figura 15, é ilustrado os tipos de imagens de fundo de olho presentes na base de aquisição.

Figura 15 – Exemplos de imagens da base RIM-ONE.



Fonte: ADAPTADO DE (TRUCCO E.; RUGGERI, 2013).

3.2 Pré-processamento


Etapas de pré-processamento são utilizadas visando melhorias na base de imagens para que os algoritmos utilizados nas fases seguintes possuam maior eficiência. Direcionando para a metodologia aplicada, tais melhoras estão relacionadas à redução das diferenças de luminosidade e melhora de contraste, com o intuito de evidenciar a região de interesse, o disco óptico. Ao detectar as características que melhor representam a imagem, consequentemente, os processos posteriores serão executados com melhor qualidade e acurácia.

No âmbito do trabalho, as imagens de fundo de olho possuem variações não relacionadas ao glaucoma. Visto isso, a análise individual dos canais e a aplicação de técnicas como a equalização de histograma, técnica responsável pela correção de contraste em imagens é fundamental no aprimoramento de etapas seguintes, principalmente no desempenho dos algoritmos de extração de características.

Como dito na seção anterior, o sistema de cores da base fornecida é o RGB (*Red, Green, Blue*), canal de cores mais utilizado no processamento de imagens. Nesta metodologia, os canais foram analisados tanto separadamente quanto em conjunto. De acordo com a literatura, os canais R e G destacam diferentes estruturas presentes na imagem de retinografia, escavação e disco óptico. Visto isso, foram analisados os canais

R, G, B e a imagem resultante da transformação para níveis de cinza, como ilustrado na Imagem 16.


Figura 16 – Separação dos canais de cores na base de aquisição.



Fonte: Elaborado pelo autor.

Após a separação dos canais, é realizada a equalização do histograma para cada canal extraído na etapa anterior. Esta técnica tem o intuito de realçar aspectos visuais da imagem, enriquecendo o detalhamento da mesma, fator impactante durante a descrição da imagem. Como ilustra a Figura 17, é considerável a melhora na distribuição das características, visto a nova disposição no histograma das mesmas.

Figura 17 – Aplicação da equalização do histograma nas imagens de fundo de olho.



Fonte: Elaborado pelo autor.


3.3 Decomposição Espacial

A etapa de decomposição espacial tem o intuito criar uma representação capaz de analisar a região de interesse (ROI) localmente. Para a metodologia proposta, foram utilizados duas abordagens: a *Cartesian Grid* e a em formato de anéis.


A *Cartesian Grid* trabalha com o janelamento da imagem. A ROI é dividida em sub-regiões mediante a uma função parametrizada de m e n , onde m corresponde ao número de divisões horizontais e n ao número de divisões verticais. Na trabalho, foi utilizada a disposição com grid 2x2.

A área de um anel é formada entre dois círculos consecutivos pois esses compartilham o mesmo centro. Para a decomposição espacial em forma de anel é tomado por base o círculo de maior raio, o qual é retirado sua intersecção com o círculo de raio menor, obtendo-se assim uma sub-região em forma de anel. A Imagem 18 ilustra as decomposições espaciais aplicadas no trabalho. No âmbito do trabalho, foram estabelecidas a utilização de três abordagens de anéis, com o raio R igual a 1, 2 e 3.

Figura 18 – Decomposições espaciais utilizadas na metodologia.



a) *Cartesian Grid*



b) *Anéis*

Fonte: Elaborado pelo autor.

3.4 Extração de Características

Com as etapas de pré-processamento realizadas, o próximo passo é descrever as sub-regiões geradas somente em relação a textura. O propósito é gerar um vetor de características que será utilizado na etapa de reconhecimento de padrões.

Neste trabalho serão utilizadas técnicas para extração de textura, o LBP e suas variantes. O LBP, *Local Binary Pattern*, é um descritor de textura apresentado por OJALA T.; PIETIKÄINEN (1996). É um operador de textura invariante aos níveis de cinza e rotação, baseado em padrões locais binários (NETO, 2016).

Além do descritor LBP Original, na implementação do projeto foram utilizados quatro variantes do mesmo: CS-LBP, E-LBP, XCS-LBP, BG-LBP. Inicialmente, os cálculos feitos em todos os descritores foram aplicados em uma janela 3x3, abordagem comumente utilizada na literatura. Além disso, foi determinada uma vizinhança de valor igual a 8 e raio R igual a 1. Para os descritores CS-LBP e XCS-LBP, a medida de threshold T foi igual a 0.

Após a descrição das características, foram aplicadas duas abordagens: inicialmente, foram calculados os histogramas para as imagens resultantes da aplicação dos filtros LBPs, para cada canal, sem esta ser submetida à decomposições espaciais. Após a aplicação dos filtros, os histogramas de cada canal (R, G e B) foram concatenados. Em seguida, a fim de estabelecer um estudo comparativo, foram calculados os histogramas parciais para cada método de decomposição espacial. Os mesmos foram concatenados, gerando o vetor de características final. Na Tabela 3 é possível visualizar o tamanho do histograma em cada abordagem de variante LBP.

Tabela 3 – Tamanho do histograma para cada descritor utilizado.

Fonte: Elaborado pelo autor.

Descritor	Tamanho do Histograma
LBP	256
ELBP	256
CSLBP	16
XCSLBP	16
BGLBP	256

3.5 Seleção de Características

Sabemos que a seleção de atributos é largamente utilizada como uma tarefa de preparação dos dados antes que seja criado um modelo de aprendizado de máquina. Ao usar um seletor de características, podemos aumentar a efetividade do classificador e também remover dados irrelevantes e com redundância, o que acaba elevando a eficiência da tarefa de aprendizado, que tem como resultado direto um aumento na acurácia e melhora na performance do classificador.

Neste trabalho, a etapa de seleção de atributos será realizada para diminuir a dimensionalidade do vetor de características resultante da etapa de extração de características visando aumentar a efetividade do classificador.

Para esta tarefa foram combinados os algoritmos de avaliação de atributos CFS (*Correlation-based Feature Selection*) e o algoritmo de busca *Best-first*.

Uma técnica popular para selecionar os atributos mais relevantes em seu conjunto de dados é usar correlação. Calcula-se a correlação entre cada atributo e a variável de saída e seleciona-se apenas os atributos que têm uma correlação positiva ou negativa, de moderada a alta (próximo a -1 ou 1) e são eliminados os atributos com baixa correlação (valor próximo de zero).

Para realização dos testes, foram utilizadas as implementações da biblioteca WEKA [Hall et al. \(2009\)](#). O número de threads durante a utilização do CFS foi igual 1, valor igualmente definido ao valor do *poolSize*. No algoritmo de busca do Best-first foram definidos os parâmetros de direção *Forward* e *searchTermination* igual a 5.

3.6 Reconhecimento de Padrões

Nesta etapa, o objetivo é o reconhecimento das imagens de fundo de olho, realizando testes com todas as configurações de decomposição/descriptor, classificando as imagens em saudáveis e glaucomatosas, utilizando de algoritmos de aprendizado de máquina. Ao fim, será realizada a validação do resultados obtidos em cada método utilizado.

Com os características devidamente compactadas na etapa de seleção de atributos, foi realizada a etapa da classificação. Para isso, foram escolhidos três classificadores para os experimentos, o Random Forest, o SMO (implementação do método da Máquina de Vetores de Suporte) e o *Simple Logistic* (implementação da Regressão Logística), todos com implementação na ferramenta WEKA.

Para o algoritmo do Random Forests, foi ajustado o parâmetro de 100 árvores para criação da floresta de busca. Já para o SMO, foi determinado o valor de C igual 1 e o kernel RBF (citado na seção 2.7.2). No *Simple Logistic* foram utilizados os parâmetros padrões definidos pela ferramenta.

4 Resultados

Este capítulo aborda e discute a respeito dos resultados obtidos na aplicação da metodologia proposta de análise de imagens médicas para o diagnóstico de padrões glaucomatosos. O trabalho proposto teve sua validação utilizando a base de imagens RIM-ONE (TRUCCO E.; RUGGERI, 2013). Esta contém um total de 455 imagens, sendo 255 casos saudáveis e 200 casos divididos em casos suspeitos e com glaucoma (ver Seção 3.1).

Os experimentos serão organizados da seguinte forma: a base, composta por 455 imagens, será dividida na proporção de 80% para as fases de treino e 20% para as fases de teste, com a execução de 5 *batches* aleatórios para cada configuração de decomposição/descritor.

Por fim, os resultados serão validados utilizando as métricas de acurácia, sensibilidade, especificidade e precisão (descritos na seção 2.8).

Ao final de todos os testes realizados, os resultados foram dispostos da seguinte forma: com o intuito de realizar uma comparação, primeiramente foram realizados os experimentos sem realizar a etapa de decomposição espacial, para cada descritor proposto pela metodologia. Na Tabela 4 estão ilustrados as médias das métricas analisadas após a realização dos cinco *batches* aleatórios para todos os descritores sem realizar a etapa de decomposição espacial.

Tabela 4 – Resultados obtidos pela metodologia sem a etapa de decomposição espacial.

Fonte: Elaborado pelo autor.

Descritor	Acurácia	Sensibilidade	Especificidade	Precisão	Classificador
LBP Original	86,5% ± 0,019	87,8% ± 0,023	85,5% ± 0,061	86,9% ± 0,017	SMO
ELBP	86,3% ± 0,018	85,8% ± 0,032	87,0% ± 0,06	86,7% ± 0,016	Regressão Logística
CS-LBP	76,7 ± 0,04	75,9% ±	78,0% ± 0,016	77,2% ± 0,03	SMO
XCS-LBP	78,4% ± 0,042	76,2% ± 0,046	81,7% ± 0,08	79,2% ± 0,04	Random Forest
BG-LBP	77,3% ± 0,06	76,9% ± 0,08	77,8% ± 0,07	77,7 ± 0,06	Random Forest

Após a coleta desta disposição, com o intuito de inspecionar os efeitos da análise local das lesões, foram validados os resultados dos experimentos incluindo a etapa de decomposição espacial. Os resultados na aplicação do método do *Cartesian Grid* são explicitados na Tabela 5.

Tabela 5 – Resultados obtidos pela metodologia incluindo a decomposição *Cartesian Grid*.

Fonte: Elaborado pelo autor.

Descritor	Acurácia	Sensibilidade	Especificidade	Precisão	Classificador
LBP Original	86,5% ± 0,02	85,6% ± 0,04	87,2% ± 0,03	86,5% ± 0,02	Random Forest
ELBP	78,4% ± 0,03	79,5% ± 0,03	77,1% ± 0,06	78,7% ± 0,03	Random Forest
CS-LBP	78,4% ± 0,06	76,2% ± 0,08	81,7% ± 0,06	79,2% ± 0,05	SMO
XCS-LBP	72,5% ± 0,04	69,3% ± 0,05	78,8% ± 0,10	74,2% ± 0,05	Random Forest
BG-LBP	77,3% ± 0,02	75,3% ± 0,04	80,4% ± 0,05	78% ± 0,02	Random Forest

Tomando as mesmas configurações, os mesmos testes foram realizados com a abordagem de decomposição espacial em forma de anéis (ver Tabela 6).

Tabela 6 – Resultados obtidos pela metodologia incluindo a decomposição em forma de anéis.

Fonte: Elaborado pelo autor.

Descritor	Acurácia	Sensibilidade	Especificidade	Precisão	Classificador
LBP Original	86,3% ± 0,03	85,6% ± 0,05	87,2% ± 0,03	86,5% ± 0,03	Random Forest
ELBP	87,4% ± 0,01	85,5% ± 0,04	91,4% ± 0,04	88,5% ± 0,009	Random Forest
CS-LBP	86,3% ± 0,03	85,6% ± 0,05	87,2% ± 0,03	86,5% ± 0,03	Random Forest
XCS-LBP	86,3% ± 0,03	85,6% ± 0,05	87,2% ± 0,03	86,5% ± 0,03	Random Forest
BG-LBP	86,3% ± 0,03	85,6% ± 0,05	87,2% ± 0,03	86,5% ± 0,03	Random Forest

4.1 Discussão

Analisando todos os resultados obtidos com os experimentos, foi possível observar que, a abordagem utilizando a decomposição espacial em forma de anéis combinado com o descritor ELBP foi a mais bem sucedida, alcançando acurácia de 87,4%, sensibilidade de 85,5%, especificidade de 91,4% e precisão de 88,5%.

Pode-se atribuir a melhor eficiência do descritor ELBP pelo fato deste ser invariante em relação a qualquer transformação tônica da escala de cinza, aspecto presente em todos os descritores usados nesta metodologia, mas tendo como adicional a análise da variação dos níveis de cinza em abordagens locais. Devido a este fato, combinado com um método de decomposição espacial, a capacidade de descrição das características da retina e, conseqüentemente, a classificação da doença é mais sucessível a apresentar bons índices.

É passível de análise também que os maiores percentuais de especificidade na maioria das configurações ilustradas são superiores aos de sensibilidade, indicando uma maior facilidade da metodologia em identificar casos saudáveis.

Alguns erros na classificação tanto como Normal ou como Glaucoma podem ser explicados pelo fato de que a base escolhida apresenta imagens em diferentes estágios de glaucoma, inclusive em fase de suspeita, ou seja, sem a certeza de que é assimilada a um

determinada classe. Devido ao fato destas imagens não apresentarem um diagnóstico final, certas classificações atribuídas a classe glaucomatosa podem ser caracterizadas como da classe Normal.

5 Conclusão

O diagnóstico de glaucoma em imagens de fundo de olho baseado na análise de textura é uma tarefa complexa e requer estudos minuciosos. Com esta finalidade, a utilização de ferramentas computacionais auxiliares, os Sistemas de Detecção e Diagnóstico auxiliados por computador (CAdE - Computer-Aided Detecton, eCADx - Computer-Aided Diagnosis), ganham notoriedade a medida que proporcionam a comunidade médica melhorias no fluxo de trabalho durante a avaliação e qualidade do diagnóstico.

Neste estudo foi proposto a construção de uma metodologia para diagnóstico do glaucoma a partir da análise de imagens digitalizadas provenientes do exame da retinografia utilizando descritores de textura e técnicas de aprendizado de máquina para o reconhecimento de padrões. O método proposto foi organizado em sete etapas: (1) Aquisição da base; (2) Pré-processamento; (3) Decomposição Espacial; (4) Extração de Características; (5) Seleção de Atributos e (6) Reconhecimentos de Padrões e (7) Validação dos resultados.

Os resultados obtidos pela metodologia são considerados promissores, com taxa de acurácia equivalente a 87,4%. Tais índices comprovam que a extração de características baseados em textura podem ser utilizados no auxílio do diagnóstico do glaucoma.

5.1 Trabalhos Futuros

Devido ao fato do crescente interesse em implementações de metodologias de diagnóstico, com o intuito de ampliar a validação do método desenvolvido, sugere-se que:

- Realize os mesmos experimentos em diferentes bases de imagens, como a Drishti-GS;
- Utilizar outras variantes de LBP para extração de características, como por exemplo, o Compound Local Binary Pattern (CLBP), uma vez que este utiliza mais informações extraídas da vizinhança dos *pixels* da imagem;
- Utilizar outras técnicas de reconhecimento de padrões, como técnicas de meta-aprendizado, como por exemplo, algoritmos genéticos ou redes neurais convolucionais;
- Utilizar outras decomposições espaciais, como a em Círculos ou a Grid X.

Referências

- ABRIL, R. *Conheça o glaucoma e saiba quais são os sintomas da doença*. 2018. [Online; acessado 23-Outubro-2018]. Disponível em: <<https://saude.abril.com.br/bem-estar/conheca-o-glaucoma-e-saiba-quais-sao-os-sintomas-da-doenca/>>. Citado na página 21.
- AGRESTI, A. *An introduction to categorical data analysis*. [S.l.]: Wiley, 2018. Citado na página 37.
- AMARAL, V. d.; THOMAZ, C. E. *Extração e Comparação de Características Locais e Globais para o Reconhecimento Automático de Imagens de Faces*. Tese (Doutorado) — Dissertação de Mestrado, Centro Universitário da FEI, SP, Brasil, 2011. Citado na página 27.
- ARAÚJO, J. D. L. et al. *Diagnóstico de Glaucoma em Imagens de Fundo de Olho utilizando os Índices de Diversidade de Shannon e McIntosh*. Dissertação (Mestrado), 2017. Citado 2 vezes nas páginas 16 e 17.
- BLAND, M. *An introduction to medical statistics*. [S.l.]: Oxford University Press (UK), 2015. Citado na página 39.
- BRAZ, G. *Classificação de regiões de mamografias em massa e não massa usando estatística espacial e máquina de vetores de suporte*. Dissertação (Mestrado) — Dissertação (Mestrado em Engenharia de Eletricidade), Centro de Ciências . . . , 2008. Citado na página 26.
- BREIMAN, L. Random forests. *Machine learning*, Springer, v. 45, n. 1, p. 5–32, 2001. Citado na página 35.
- BUCAR, H. de O. *Retinografia*. 2018. [Online; acessado 22-Outubro-2018]. Disponível em: <<http://hospitaldeolhosbucar.com.br/site/exames/16-retinografia.html>>. Citado na página 21.
- BURGISS, S. G. G. S. G. Multiframe averaging and homomorphic filtering for clarification of dark and shadowed video scenes. In: IEEE. 2001. v. 4232, p. 4232 – 4232 – 9. Disponível em: <<https://doi.org/10.1117/12.417566>>. Citado na página 16.
- CLINIC, M. *Glaucoma*. 2015. [Online; acessado 23-Outubro-2018]. Disponível em: <<https://www.mayoclinic.org/diseases-conditions/glaucoma/symptoms-causes/syc-20372839>>. Citado na página 21.
- DAVARPANA, S. H. et al. A texture descriptor: Background local binary pattern (bglbp). *Multimedia Tools and Applications*, Springer, v. 75, n. 11, p. 6549–6568, 2016. Citado na página 31.
- DUA, S. et al. Wavelet-based energy features for glaucomatous image classification. *IEEE Transactions on Information Technology in Biomedicine*, v. 16, n. 1, p. 80–87, Jan 2012. ISSN 1089-7771. Citado 2 vezes nas páginas 16 e 17.
- GONZALEZ, R. C.; WOODS, R. E. *Pocessamento digital de imagens*. [S.l.]: Pearson Prentice Hall, 2010. Citado 6 vezes nas páginas 19, 20, 22, 23, 25 e 26.

GUEDES, R. As estratégias de prevenção em saúde ocular no âmbito da saúde coletiva e da atenção primária à saúde-aps. *Revista APS*, v. 10, n. 1, p. 66–73, 2007. Citado na página 14.

GUIMARÃES, I. A.; NETO, A. C. Reconhecimento de padrões: metodologias estatísticas em crédito ao consumidor. *RAE-eletrônica*, SciELO Brasil, v. 1, n. 2, 2002. Citado na página 38.

HALL, M. et al. The WEKA data mining software: an update. *SIGKDD Explorations*, v. 11, n. 1, p. 10–18, 2009. Citado 2 vezes nas páginas 16 e 46.

HALL, M. A. Correlation-based feature selection for machine learning. University of Waikato Hamilton, 1999. Citado na página 33.

HARALICK, R. M. et al. Textural features for image classification. *IEEE Transactions on systems, man, and cybernetics*, v. 3, n. 6, p. 610–621, 1973. Citado na página 26.

HE, X. et al. Local binary patterns on hexagonal image structure. In: *7th IEEE International Conference on Computer and Information Technology (CIT 2007)*. [S.l.: s.n.], 2007. p. 639–644. Citado na página 32.

HEIKKILÄ, M.; PIETIKÄINEN, M.; SCHMID, C. Description of interest regions with center-symmetric local binary patterns. In: *Computer vision, graphics and image processing*. [S.l.]: Springer, 2006. p. 58–69. Citado 2 vezes nas páginas 28 e 30.

KANAN, C.; COTTRELL, G. W. Color-to-grayscale: Does the method matter in image recognition? *PLOS ONE*, Public Library of Science, v. 7, n. 1, p. 1–7, 01 2012. Disponível em: <<https://doi.org/10.1371/journal.pone.0029740>>. Citado 2 vezes nas páginas 24 e 25.

LAND, E. H.; MCCANN, J. J. Lightness and retinex theory. *J. Opt. Soc. Am.*, OSA, v. 61, n. 1, p. 1–11, Jan 1971. Disponível em: <<http://www.osapublishing.org/abstract.cfm?URI=josa-61-1-1>>. Citado na página 16.

LOWE, D. G. Object recognition from local scale-invariant features. In: IEEE. *Computer vision, 1999. The proceedings of the seventh IEEE international conference on*. [S.l.], 1999. v. 2, p. 1150–1157. Citado na página 28.

LUNA, B. Utilização racional de exames diagnósticos em cardiologia. *Arq Bras Cardiol*, v. 72, n. 1, 1999. Citado na página 38.

MAGURRAN, A. E. *Measuring biological diversity*. [S.l.]: John Wiley & Sons, 2013. Citado na página 16.

MAXWELL, J. C.; NIVEN, W. General considerations concerning scientific apparatus. *The Scientific Papers of James Clerk Maxwell, WD Niven, ed., Dover, New York*, 1890. Citado na página 24.

MONARD, M. C.; BARANAUSKAS, J. A. Conceitos sobre aprendizado de máquina. *Sistemas Inteligentes-Fundamentos e Aplicações*, v. 1, n. 1, p. 32, 2003. Citado na página 34.

- NETO, G. M. R. Estudo de variantes de padrões locais binários para o diagnóstico de câncer de mama. *Monografia (Bacharel em Ciência da Computação)*, 2016. UFMA (Universidade Federal do Maranhão). Citado na página 44.
- OFTALMOLOGIA, C. B. de. Glaucoma. [Http://www.cbo.net.br/novo/publico-geral/glaucoma.php](http://www.cbo.net.br/novo/publico-geral/glaucoma.php). 2017. Citado 2 vezes nas páginas 13 e 14.
- OJALA, T.; PIETIKAINEN, M.; MAENPAA, T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 24, n. 7, p. 971–987, July 2002. ISSN 0162-8828. Citado na página 30.
- OJALA T.; PIETIKÄINEN, M. H. D. A. A comparative study of texture measures with classification based on featured distributions. *Pattern recognition*, v. 29, n. 1, p. 51–59, 1996. Citado 7 vezes nas páginas 15, 27, 28, 29, 30, 31 e 44.
- PEARL, J. *Heuristics: Intelligent Search Strategies for Computer Problem Solving*. Boston, MA, USA: Addison-Wesley Longman Publishing Co., Inc., 1984. ISBN 0-201-05594-5. Citado na página 33.
- QUIGLEY, H. A.; BROMAN, A. T. The number of people with glaucoma worldwide in 2010 and 2020. *British Journal of Ophthalmology*, BMJ Publishing Group Ltd, v. 90, n. 3, p. 262–267, 2006. ISSN 0007-1161. Disponível em: <<https://bjo.bmj.com/content/90/3/262>>. Citado na página 14.
- RITCH, R.; SHIELDS, M.; KRUPIN, T. *The Glaucomas*. Mosby, 1989. (The Glaucomas, v. 1). ISBN 9780801641169. Disponível em: <<https://books.google.com.br/books?id=rMRsAAAAMAAJ>>. Citado na página 14.
- RODRIGUES, A. F. S. *Imagem de fundo ocular: Análise comparativa de técnicas e de novas tecnologias no diagnóstico oftalmológico da retina–Aplicação Clínica*. Dissertação (Mestrado), 2016. Citado na página 19.
- SBG. *Sociedade Brasileira de Glaucoma*. 2012. [Online; acessado 23-Outubro-2018]. Disponível em: <<http://www.cbo.com.br/novo/medico/pdf/jo/ed146/16.pdf>>. Citado na página 21.
- SILVA, A. C. *Algoritmos para Diagnostico Assistido de Nodulos Pulmonares Solitarios em Imagens de Tomografia Computadorizada*. Tese (Doutorado), 2004. Citado na página 39.
- SILVA, C.; BOUWMANS, T.; FRÉLICOT, C. An extended center-symmetric local binary pattern for background modeling and subtraction in videos. In: *International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications, VISAPP 2015*. [S.l.: s.n.], 2015. Citado 2 vezes nas páginas 30 e 31.
- SILVA, M. G. et al. Diagnóstico do glaucoma em imagens de retinografia usando variantes de padrões locais binários. *Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS_CSBC)*, v. 18, n.1/2018, 2018. Citado 2 vezes nas páginas 16 e 17.
- SOUSA, J. A. de et al. Texture based on geostatistic for glaucoma diagnosis from fundus eye image. *Multimedia Tools and Applications*, v. 76, n. 18, p. 19173–19190, Sep 2017. ISSN 1573-7721. Disponível em: <<https://doi.org/10.1007/s11042-017-4608-y>>. Citado na página 17.

- THORNTON, C. et al. Auto-weka: Combined selection and hyperparameter optimization of classification algorithms. In: *Proceedings of the 19th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. New York, NY, USA: ACM, 2013. (KDD '13), p. 847–855. ISBN 978-1-4503-2174-7. Disponível em: <<http://doi.acm.org/10.1145/2487575.2487629>>. Citado na página 17.
- TRUCCO E.; RUGGERI, A. K. T. G. L. E. J.-D. B. C. C. D. M. e. a. Validating retinal fundus image analysis algorithms: Issues and a proposal validating retinal fundus analysis algorithms. *Investigative ophthalmology visual science*, v. 54, n. 5, p. 3546–3559, 2013. The Association for Research in Vision and Ophthalmology. Citado 4 vezes nas páginas 17, 41, 42 e 47.
- VAPNIK, V. *The nature of statistical learning theory*. [S.l.]: Springer science & business media, 2013. Citado na página 36.
- VAPNIK V. N, B. B. E. G. I. M. A training algorithm for optimal margin classifiers. In: *Proceedings of the fth annual workshop on Computational learning theory*. [S.l.: s.n.], 1992. v. 1, p. p. 144–152. Citado na página 36.
- WANG, A. et al. A novel human detection algorithm combining hog with lbp histogram fourier. In: *2015 10th International Conference on Communications and Networking in China (ChinaCom)*. [S.l.: s.n.], 2015. p. 793–797. Citado na página 27.
- WGA. <https://wga.one/wga/>. 2017. Citado 4 vezes nas páginas 13, 20, 21 e 22.
- YOUNG, T. Ii. the bakerian lecture. on the theory of light and colours. *Philosophical transactions of the Royal Society of London*, The Royal Society, v. 92, p. 12–48, 1802. Citado na página 24.