

UNIVERSIDADE FEDERAL DO PIAUÍ
CAMPUS SENADOR HELVÍDIO NUNES DE BARROS
CURSO BACHARELADO EM SISTEMAS DE INFORMAÇÃO

**USO DE DESCRITORES DE TEXTURA PARA CLASSIFICAÇÃO DE IMAGENS
DA RETINA PARA A DETECÇÃO AUTOMÁTICA DO GLAUCOMA**

WALLINSON DE LIMA SILVA

PICOS – PIAUÍ

2016

WALLINSON DE LIMA SILVA

USO DE DESCRITORES DE TEXTURA PARA CLASSIFICAÇÃO DE IMAGENS DA
RETINA PARA A DETECÇÃO AUTOMÁTICA DO GLAUCOMA

Monografia submetida ao Curso de Bacharelado de Sistemas de Informação como requisito parcial para obtenção de grau de Bacharel em Sistemas de Informação.

Orientadora: Prof. Ma. Alcilene Dalília de Sousa
Coorientador: Prof. Me. Flávio Henrique Duarte de Araújo

PICOS – PIAUÍ

2016

FICHA CATALOGRÁFICA
Serviço de Processamento Técnico da Universidade Federal do Piauí
Biblioteca José Albano de Macêdo

S586u Silva, Wallinson de Lima.

Uso de descritores de textura para classificação de imagens da retina para a detecção automática do glaucoma / Wallinson de Lima Silva.– 2016.

CD-ROM : il.; 4 ¼ pol. (42 f.)

Monografia (Curso Bacharelado em Sistemas de Informação) – Universidade Federal do Piauí, Picos, 2016.

Orientador(A): Profª. Ma. Alcilene Dalília de Sousa

1. Glaucoma. 2. Imagens Médica. 3. Local Binary Pattern.
I. Título.

CDD 005

USO DE DESCRITORES DE TEXTURA PARA CLASSIFICAÇÃO DE IMAGENS DA
RETINA PARA DETECÇÃO AUTOMÁTICA DO GLAUCOMA

WALLINSON DE LIMA SILVA

Monografia aprovada como exigência parcial para obtenção do grau de
Bacharel em Sistemas de Informação.

Data de Aprovação

Picos – PI, 18 de fevereiro de 2016



Prof.^a. Ma. Alcilene Dalília de Sousa
Orientador



Prof.^a. Ma. Patrícia Medyna Lauritzen de Lucena Drumond
Membro



Prof. Me. Antonio Oseas de Carvalho Filho
Membro

Dedico este trabalho a Deus, por ter me concedido força, sabedoria e entendimento. Dedico a minha família, em especial aos meus pais, Adriene Souza de Lima Silva e Anielson de Carvalho Silva, por me ajudarem a lutar por meus sonhos. Por último, dedico a Ramayama Kariny por sempre acreditar no meu potencial e me apoiar durante todo o tempo.

AGRADECIMENTOS

A Deus, por seu amor eterno e incomparável. Por ter me mantido firme durante todo esse tempo. Agradeço pela sua constante presença e fidelidade em minha vida. Pelos caminhos que o Senhor me permitiu trilhar debaixo da sua vontade. Pelo aprendizado, não só o acadêmico, mas também o pessoal, onde dia após dia aprendi a confiar e esperar, pois para tudo há um tempo determinado.

Aos meus pais, Adriene Souza de Lima Silva e Anielson de Carvalho Silva, por todos os conselhos, instruções e ensinamentos, os quais constituíram a minha base moral. Agradeço por todos os esforços para me proporcionar o melhor. Agradeço também ao meu irmão, pelos momentos de descontração.

Agradeço a minha namorada Ramayama Kariny dos Santos, por seu companheirismo, amizade, paciência, compreensão e apoio. Por ter dividido todos os momentos bons e ruins. Agradeço pelas suas palavras de ânimo em meus dias de estresse e pela sua alegria contagiante.

A minha orientadora, Ma. Alcilene Dalília de Sousa e ao meu coorientador Me. Flávio Henrique Duarte de Araújo, por sempre estarem dispostos a dividirem os seus conhecimentos com seus alunos. Agradeço pela paciência e pelo apoio, sempre me ajudando da melhor forma possível para realização desse trabalho.

À Universidade Federal do Piauí – UFPI.

A todos os professores do curso de Sistemas de Informação. Em especial aos professores Romuere Rodrigues Veloso e Silva e a Patrícia Medyna Lauritzen de Lucena Drumond coordenadora do curso, que mesmo não sendo meus orientadores estiveram sempre a disposição para tirar minhas dúvidas.

Um agradecimento mais que especial a Maíla de Lima Claro, Nayara de Moura Holanda e Maria Jaquelane de Moura. Vocês que sempre estiveram comigo nessa jornada. Hoje o que conquisto não é um mérito único e exclusivo meu, mas sim uma cooperação mútua de todos que vivem ao meu redor, inclusive vocês. Agradeço por todo auxílio e companheirismo de vocês e por todos os momentos de descontração, que por sinal não foram poucos.

A todos vocês muito obrigado!

“Melhor é o fim das coisas do que o princípio delas.”
Eclesiastes 7:8

RESUMO

O glaucoma é uma patologia que ataca o nervo óptico, causando danos irreversíveis no campo visual. Por ser uma doença assintomática nos estágios iniciais, a mesma só é detectada em seu estágio mais avançado. Assim, ela é considerada a segunda maior causa de cegueira no mundo. Apesar de ser uma patologia crônica, seus efeitos podem ser retardados por meio do tratamento, que pode ser facilitado a partir de um prévio diagnóstico. Dessa forma, esse trabalho apresenta um método para extração de características em imagens de retina pelo uso de descritores para fins de detecção automática do glaucoma, utilizando os dicionários visuais que são formas de representação robusta e os descritores de textura *Local Binary Pattern* (LBP) e *Grey Level Co-occurrence Matrix* (GLCM). O algoritmo desenvolvido foi testado utilizando a base de imagens RIM-ONE e vários classificadores, dentre eles, o LibLinear foi o que mais se destacou, por ter alcançado os melhores índices, com acurácia de 99% e Kappa de 0,97.

Palavras-chave: Imagens Médica, Glaucoma, LBP, GLCM.

ABSTRACT

Glaucoma is a disease that affecting the optic nerve, causing permanent damage to the visual field. Because it is an asymptomatic disease in the early stages, it is only detected in its most advanced stage. Thus, it is considered the second leading cause of blindness in the world. Although a chronic disease, its effects can be slowed by the treatment, which can be facilitated from a previous diagnosis. Thus, this paper presents a method for extracting features in retinal images by use of descriptors for automatic glaucoma detection purposes, using bag of words that are forms of robust representation and the texture descriptors Local Binary Pattern (LBP) and Grey Level Co-occurrence Matrix (GLCM). The developed algorithm has been tested using the base RIM-ONE images and various classifiers, among them the LibLinear was what stood out for having achieved the best rates, with an accuracy of 99% and Kappa of 0.97.

Keywords: Medical Images, Glaucoma, LBP, GLCM.

LISTA DE ILUSTRAÇÕES

Figura 1 - Seções do olho humano.....	16
Figura 2 - Imagens de Retina. a) Retina saudável, b) Retina glaucomatosa.....	18
Figura 3 - Seleção de pontos característicos utilizando o SURF.....	19
Figura 4 - Ilustração do funcionamento do descritor de textura LBP.	21
Figura 5 - Matriz de coocorrências de tons de cinza.	21
Figura 6 - Níveis angulares para cálculo de probabilidades de coocorrências.	22
Figura 7 - Fluxograma com os passos do método proposto.....	29
Figura 8 - Formação dos dicionários visuais.	30
Figura 9 - Processo de formação das assinaturas para a imagem.....	31

LISTA DE TABELAS

Tabela 1 - Classes da matriz de confusão.....	26
Tabela 2 - Nível de exatidão de uma classificação, conforme o valor do Kappa.	28
Tabela 3 - Resultados encontrados pela extração de características com o SURF, LBP e GLCM separadamente.	34
Tabela 4 - Resultados encontrados pela combinação dos descritores SURF e GLCM.	35
Tabela 5 - Resultados encontrados pela combinação dos descritores LBP e GLCM.	35
Tabela 6 - Resultados encontrados pela combinação dos descritores SURF e LBP.	36
Tabela 7 - Resultados encontrados pela combinação dos descritores SURF, LBP e GLCM.	37

LISTA DE ABREVIATURAS E SIGLAS

A	Acurácia
CAD	<i>Computer Aided Diagnosis</i>
Con	Contraste
Corr	Correlação
Ene	Energia
FM	<i>F-Measure</i>
FN	Falso Negativo
FP	Falso Positivo
GLCM	<i>Grey Level Co-occurrence Matrix</i>
HOG	<i>Histograms of Oriented Gradients</i>
Hom	Homogeneidade
K	Kappa
KNN	<i>K-Nearest-Neighbor</i>
LBP	<i>Local Binary Pattern</i>
LMT	<i>Logistic Model Trees</i>
MLP	<i>Multi Layer Perceptron</i>
P	Precisão
PDI	Processamento Digital de Imagens
PI	Pontos de Interesse
PIO	Pressão Intraocular
R	<i>Recall</i>
RBFN	<i>Radial Basis Function Network</i>
RD	Retinopatia Diabética
RGB	<i>Red, Green e Blue</i>
RI	Região de Interesse
SURF	<i>Speed-Up Robust Features</i>
SVM	<i>Support Vector Machine</i>
TCH	Transformada Circular de Hough
VN	Verdadeiro Negativo
VP	Verdadeiro Positivo
WEKA	<i>Waikato Environment for Knowledge Analysis</i>

WHO

World Health Organization

SUMÁRIO

1	INTRODUÇÃO	14
1.1	Objetivo	15
1.2	Organização do Trabalho	15
2	ESTADO DA ARTE	16
2.1	Olho Humano	16
2.2	Glaucoma	17
2.3	Processamento Digital de Imagens	17
2.4	Base de Imagens	18
2.5	Descritores	19
2.5.1	SURF	19
2.5.2	Dicionários Visuais	20
2.5.3	LBP	20
2.5.4	GLCM	21
2.6	Trabalhos Relacionados	23
2.7	CrITÉrios de Avaliação	25
2.7.1	Matriz de Confusão	25
2.7.2	Precisão	26
2.7.3	<i>Recall</i>	26
2.7.4	<i>F-Measure</i>	26
2.7.5	Acurácia	27
2.7.6	Índice Kappa	27
3	METODOLOGIA	29
3.1	Pré-Processamento	29
3.2	Extração de Características	29
3.3	Classificação	31
4	RESULTADOS E DISCUSSÕES	33
5	CONSIDERAÇÕES FINAIS	38
5.1	Trabalhos Futuros	38
5.2	Publicações Obtidas	38
	REFERÊNCIAS BIBLIOGRÁFICAS	40

1 INTRODUÇÃO

O uso de Processamento Digital de Imagens (PDI) vem avançando bastante, sendo utilizado como objeto de pesquisas. Ele possibilita a obtenção de resultados para determinados problemas a partir da análise de imagens, permeando em quase todas as áreas de atividade humana.

“A análise de imagens de fundo de olho é muito utilizada pela comunidade médica para diagnóstico de doenças oculares ou doenças que tenham efeitos globais sobre a vasculatura do corpo” (SOARES, 2006). Por exemplo, a avaliação dos vasos do fundo do olho pode revelar sinais de hipertensão, diabetes, arteriosclerose e doenças cardiovasculares.

Weinreb (2004) afirma que o glaucoma é uma de muitas patologias que podem levar a perda da visão, ocasionada pelo aumento da pressão intraocular, gerando uma perda progressiva do campo de visão de maneira irreversível.

Uma característica preocupante do glaucoma é o fato de não possuir sintomas, tornando-a cada vez mais grave e podendo ser notada somente em seu estado mais avançado, ocasionando a perda permanente da visão. Os danos causados pelo glaucoma podem ser reduzidos a partir do diagnóstico antecipado, sendo assim, sua detecção precoce é de grande importância. Existem vários métodos utilizados para o diagnóstico dessa doença, tais como: avaliação da pressão intraocular; exame da pupila, que detecta lesões no nervo óptico; e avaliação do campo visual.

Segundo dados da Organização Mundial de Saúde (*World Health Organization*) (WHO) (2014), existem cerca de 60 milhões de glaucomatosos em todo o mundo, sendo que, a cada ano, surgem mais 2,4 milhões de casos. A prevalência da cegueira por glaucoma é de 5,2 milhões de pessoas, representando a segunda maior causa de cegueira no mundo. Segundo Quigley (2006), em 2020, cerca de 80 milhões de pessoas terão glaucoma.

Uma maneira viável e de baixo custo, levando em consideração outras técnicas de detecção do glaucoma, é o diagnóstico feito a partir da análise de imagens de fundo de olho. Nessa técnica as imagens são analisadas por um especialista humano que tenta identificar o acúmulo do líquido ao redor do disco

óptico.

O diagnóstico do glaucoma usando imagens também pode ser feito a partir de técnicas de processamento digital de imagens. As principais formas de detecção são por segmentação de regiões e por extração de características das imagens juntamente com técnicas de classificação de dados.

Diante do exposto, neste trabalho foram utilizados os descritores *Speed-Up Robust Features* (SURF) (BAY; TUYTELAARS; VAN, 2006), *Local Binary Pattern* (LBP) (OJALA; PIETIKÄINEN; HARWOOD, 1996) e *Grey Level Co-occurrence Matrix* (GLCM) (HARALICK; SHANMUGAM; DINSTEIN, 1973) para extração de características das imagens de fundo de olho e a detecção automática do glaucoma.

1.1 Objetivo

O objetivo deste trabalho consiste no desenvolvimento de um método para extração de características das imagens da retina pelo uso de descritores para fins de detecção automática do glaucoma. Os métodos propostos serão avaliados por meio de algoritmos classificadores, os quais irão demonstrar a eficiência dos algoritmos desenvolvidos.

1.2 Organização do Trabalho

Após a introdução que relatou sobre o problema que se pretende resolver e o objetivo do trabalho serão apresentados os próximos capítulos, que estão organizados da seguinte forma.

No Capítulo 2 – Estado da Arte: apresenta o embasamento teórico para o trabalho. São mostrados conceitos relacionados ao olho humano, glaucoma, processamento digital de imagens, base de imagens e algoritmos descritores.

O Capítulo 3 – Metodologia: é apresentada a metodologia utilizada para desenvolvimento desse trabalho.

Capítulo 4 – Resultados e Discussões: Nesse capítulo são mostrados detalhadamente todos os resultados obtidos e a discussão dos mesmos.

Capítulo 5 – Considerações Finais: Apresenta-se a conclusão do trabalho, trabalhos futuros e publicações obtidas.

2 ESTADO DA ARTE

Nesta Seção são apresentados os conceitos e recursos utilizados para alcançar os resultados demonstrado na seção 4.2.

2.1 Olho Humano

O olho humano possui uma forma aproximadamente esférica, sendo constituído por uma estrutura sensorial complexa. Sua função é a formação e o processamento de imagem em conexão com o cérebro.

“Baseado num conjunto de processos químicos e físicos básicos, o olho transforma estímulos luminosos em estímulos elétricos e envia-os ao cérebro para que possam ser interpretados” (GUERRA, 2008).

Os raios provenientes dos objetos externos penetram no olho através de uma abertura frontal na íris, a pupila, e de uma lente denominada cristalino, atingindo a retina, que constitui a camada interna posterior do globo ocular (JÚNIOR, 2006).

A Figura 1 representa o olho humano e seus principais componentes.

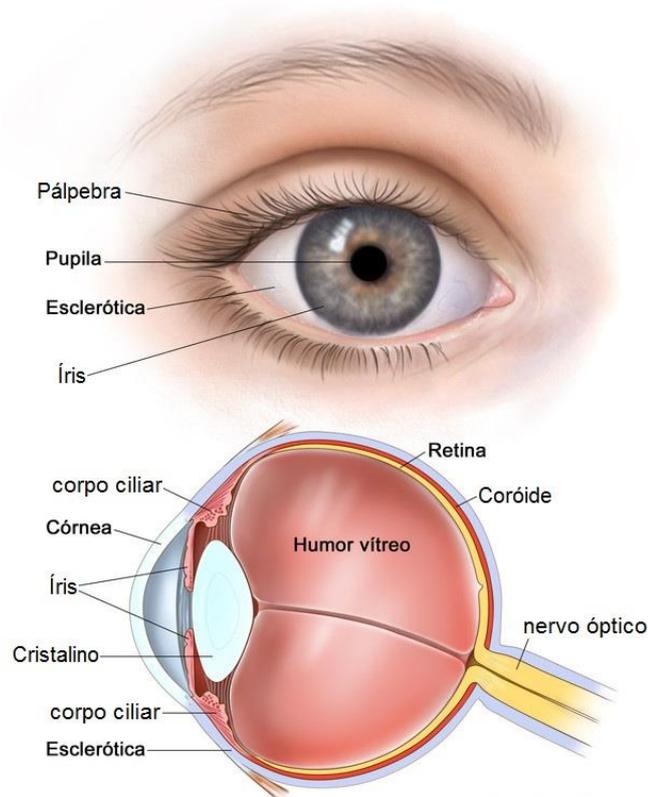


Figura 1 - Seções do olho humano.
Fonte: EMUC (2014)

“A retina constitui a membrana mais interna do olho, situando-se na parede posterior do olho. Quando o olho focaliza uma cena, a imagem correspondente é projetada sobre a retina” (VERAS, 2014). A partir da análise de imagens da retina é possível notar deformações causadas por patologias, sendo um exemplo delas o glaucoma, que vem sendo explorado no decorrer desse trabalho.

2.2 Glaucoma

O glaucoma é uma patologia neurodegenerativa que causa lesões progressivas no nervo ótico, ocasionando a perda gradativa do campo visual. Ele afeta o nervo óptico, que é uma estrutura formada por um feixe de fibras nervosas e responsável por levar até o cérebro todas as imagens que vemos (DANNY, 2011).

Usualmente o glaucoma é causado devido ao aumento da Pressão Intraocular (PIO). Isso ocorre devido ao acúmulo do líquido humor aquoso em virtude da má formação do sistema de drenagem do olho (IYYANARAPPAN; TAMILPAVAI, 2014).

2.3 Processamento Digital de Imagens

Uma imagem pode ser denotada como um modelo matemático. Sua representação é feita pelo uso da função $f(x, y)$, onde “ x ” e “ y ” representam as coordenadas espaciais e “ f ” representa o valor da intensidade da imagem naquele ponto. Em busca de uma melhor compreensão é possível fazer uso de uma matriz, onde cada ponto da matriz representa um pixel. Assim, o “ x ” é estabelecido como a representação de uma determinada linha e o “ y ” uma determinada coluna da matriz (GONZALES; WOODS, 2002).

Uma vez que, uma imagem é representada por uma matriz de pixels, podemos definir o valor de cada pixel entre 0 e 255 para imagens de 8 bits. O pixel terá sua representação em níveis de cinza; o valor 0 representa o preto, 255 representa o branco e o intervalo entre eles serão exibidos os níveis de cinza (SILVA, 2014b). No caso de alguma imagem possuir informações em bandas distintas, é necessário uma função $f(x, y)$ para cada banda. Podemos citar como exemplo uma imagem colorida padrão RGB (GONZALES; WOODS, 2002). Esse tipo de imagem possui três bandas com informações distintas: *Red*, *Green* e *Blue*.

A aquisição das imagens pode ser feita de várias formas assim não há um padrão pré-determinado. A obtenção das imagens pode variar desde o equipamento até o método utilizado, como por exemplo a resolução empregada, distância, ângulo, entre outros critérios usados no momento da aquisição das imagens. Com isso o desenvolvimento de sistemas de detecção por imagens torna-se cada vez mais complexos, pois eles devem ser capazes de executar o diagnóstico correto em meio as diferentes variações nas imagens.

O uso do PDI tem apresentado grandes evoluções, estando presente nas mais variadas áreas desde uma simples câmera fotográfica, sendo ele usado na detecção de rostos e sorrisos, até no diagnóstico médico, que é o foco desse trabalho, como por exemplo os sistemas de Diagnóstico Auxiliado por Computador - *Computer Aided Diagnosis* (CAD).

2.4 Base de Imagens

As imagens utilizadas neste trabalho foram retiradas da base RIM-ONE. Essa base de imagens 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 fornecidas por diferentes especialistas, provendo assim, diversas imagens de olhos saudáveis e com diferentes níveis de glaucoma (TRUCCO *et al.*, 2013). A Figura 2 apresenta duas imagens de retina retiradas da base RIM-ONE.

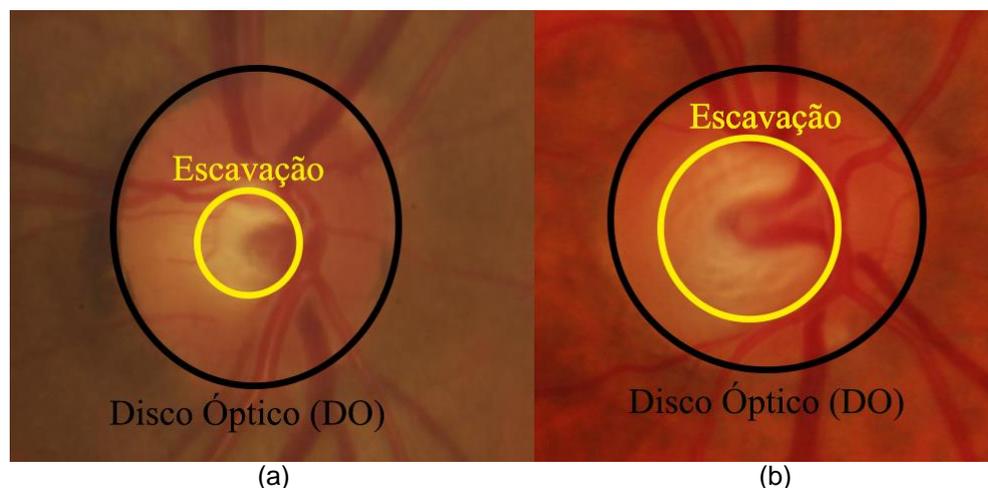


Figura 2 - Imagens de Retina. a) Retina saudável, b) Retina glaucomatosa.

A base é separada por categorias, ou seja, 118 imagens saudáveis e 40

imagens glaucomatosas. Essa característica possibilitou que a mesma fosse utilizada nesse trabalho, pois outras bases encontradas não forneciam essa distinção entre as imagens.

2.5 Descritores

Descritores são formas de representar uma imagem a partir de suas características, tais como cor, textura, tonalidade, estrutura, dentre outras (CARVALHO, 2010). O processamento realizado pelo descritor retornará como saída um vetor de atributos que evidenciará os pontos característicos mais importantes da imagem.

Nessa seção serão apresentados os algoritmos descritores utilizados para o desenvolvimento desse trabalho.

2.5.1 SURF

O SURF é um descritor local que identifica os pontos de interesse com base na matriz Hessiana (SILVA, 2014b). Foi projetado para detecção dos pontos de interesse independente de mudanças de luminosidade, rotação e escala, sendo muito utilizado para registro de imagens, calibração de câmeras, reconhecimento de objetos, dentre outros (CARVALHO, 2010). O processamento realizado pelo descritor retorna como saída dois vetores: pontos de interesse e um vetor de atributos que evidenciará os pontos característicos mais importantes da imagem. Na Figura 3 é apresentada a seleção de pontos característicos utilizando o SURF.

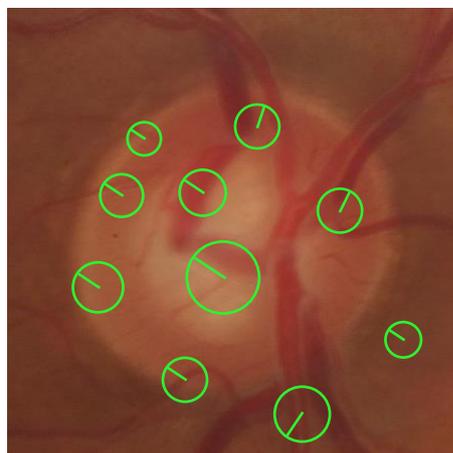


Figura 3 - Seleção de pontos característicos utilizando o SURF.

As imagens possuem características peculiares, que por sua vez podem ser consideradas pontos de interesse pelo descritor. Com isso o SURF pode retornar quantidades variáveis de atributos.

2.5.2 Dicionários Visuais

Apesar de ser uma boa opção para descrever imagens de forma mais detalhada, o uso de descritores locais pode se tornar uma grande dificuldade no momento da classificação das amostras. Eles retornam como saída um vetor de atributos que varia de acordo com a imagem, devido a isso, não há o controle da quantidade de atributos descritos. “Tendo em vista essa inconsistência, os classificadores não funcionam bem com representações geradas pelos descritores locais” (CARVALHO, 2010). Para solucionar a dificuldade dos classificadores tem-se como opção a utilização dos dicionários visuais.

Os dicionários são uma forma de representação robusta para imagens, onde cada imagem é vista apenas como uma coleção de regiões nas quais a informação espacial da região não importa. Segundo Bay *et al.* (2008) “a única informação considerada é a aparência da região”.

Os dicionários visuais são matrizes compostas por palavras (linhas da matriz) que são feitas pelos pontos mais representativos da imagem extraídos pelo algoritmo SURF. “Esses dicionários são usados para capturar as propriedades comuns entre as regiões marcadas pelo algoritmo SURF” (ARAÚJO, 2013).

2.5.3 LBP

O LBP é um método simples de extração de características, contudo sua simplicidade não o torna menos eficiente, podendo ser considerado um excelente método de extração de características relacionadas com a textura. Ele destaca-se por suas vantagens, sendo elas: “a não influência das variações de iluminação, baixa complexidade computacional, capacidade de codificar detalhes e permitir realizar análise local das informações” (NANNI; LUMINI; BRAHNAM, 2012).

O LBP cria janelas 3x3 a partir da imagem original e compara o pixel central

com seus 8 vizinhos, criando a partir dessa comparação uma matriz binária onde os valores menores que o pixel central recebem valor zero e os maiores recebem um. Feito isso, uma nova matriz 3x3 é gerada contendo como pesos, valores baseados em potências de 2. Os valores da matriz binária foram multiplicados por os valores da matriz de peso, assim, foram somados os resultados da multiplicação, sendo esse resultado armazenado em um histograma de 0 a 255. A Figura 4 mostra o funcionamento do descritor de textura LBP.

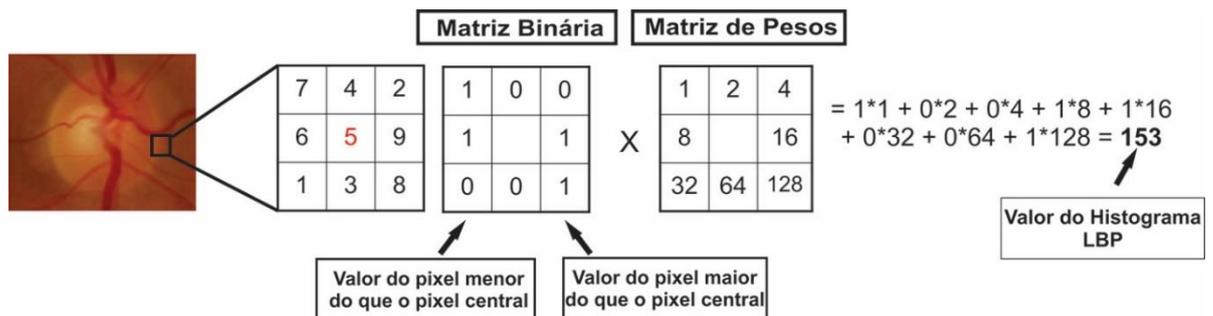


Figura 4 - Ilustração do funcionamento do descritor de textura LBP.

2.5.4 GLCM

A GLCM ou Matriz de Co-ocorrências de Tons de Cinza é um descritor para análise de textura em imagens, que apresenta na forma de uma matriz quadrada $L \times L$ uma medida de probabilidade de ocorrência de cores separadas por uma dada distância em uma direção, mapeando o número de transições de intensidade entre pixels de uma imagem I , segundo o critério de vizinhança, como pode ser visto na Figura 5.

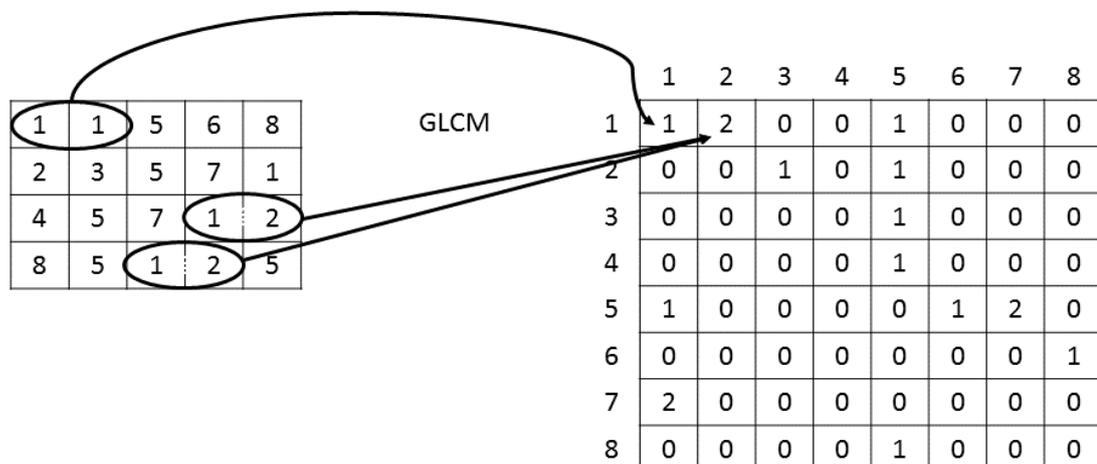


Figura 5 - Matriz de coocorrências de tons de cinza.

GLCM é um método para extração de características que usa estatísticas de segunda ordem, pois analisa as co-ocorrências existentes entre pares de pixels, ou seja, ela não analisa cada pixel individualmente, mas sim, conjuntos de pixels relacionados através de algum padrão (SILVA, 2013).

Para calcular as probabilidades de co-ocorrências entre dois níveis de cinza i e j , é necessário estabelecer uma distância d e uma orientação Θ (Tetha), que pode assumir os valores de 0° , 45° , 90° e 135° , como pode ser visto na Figura 6.

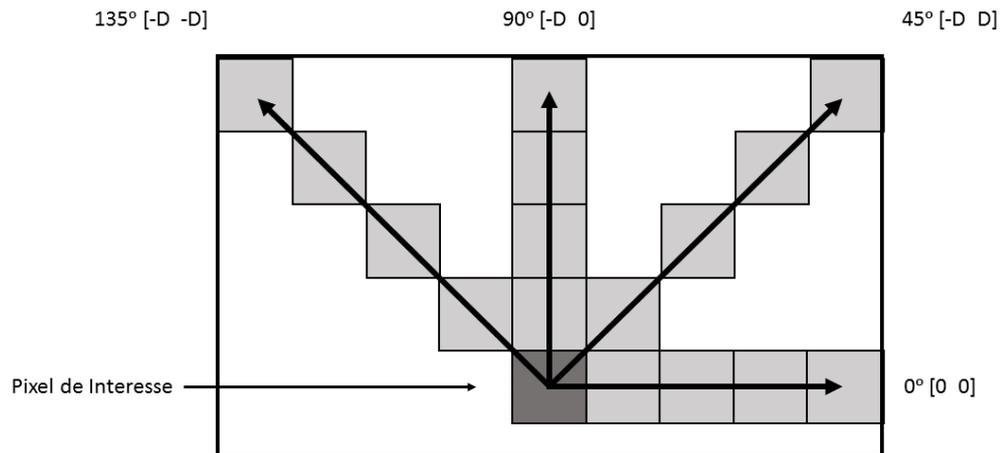


Figura 6 - Níveis angulares para cálculo de probabilidades de coocorrências.

Fonte: <http://www.mathworks.com/help/images/gray-level-co-occurrence-matrix-glc.html> (2015)

Haralick *et al.* (1973), definiu 14 características significativas para a GLCM, porém a quantidade de características utilizadas pode variar de acordo com o problema, podendo gerar um melhor desempenho, do que a utilização de todas. Assim, baseando-se em Santos, Santos e Souto (2012), para esse trabalho foram utilizados os cálculos dos seguintes atributos de textura:

Contraste (*Con*): mede o contraste entre um pixel e seus vizinhos. Essa medida é feita em todos os pixels da imagem. Quando uma imagem é constante o seu contraste é 0 (zero). O seu cálculo pode ser feito por meio da Equação 1:

$$Con = \sum_{i,j=0}^{Ng-1} |i - j|^k (C_{ij})^l. \quad (1)$$

Correlação (*Corr*): calcula o quão relacionado determinado pixel com seu vizinho. No caso de imagens completamente correlacionadas esse valor é 1. Seu cálculo é expresso pela Equação 2:

$$Corr = \sum_{i,j=0}^{Ng-1} \frac{ijC_{ij} - \mu_i\mu_j}{\sigma_i\sigma_j}. \quad (2)$$

Homogeneidade (*Hom*): avalia o quão próximo a distribuição dos elementos estão da diagonal principal da GLCM. O seu cálculo pode ser feito por meio da Equação 3:

$$Hom = \sum_{i,j=0}^{Ng-1} \frac{C_{ij}}{1 + |i - j|}. \quad (3)$$

Energia (*Ene*): retorna à uniformidade da textura na GLCM, avaliando as repetições de pares de pixels da imagem. Quando há muita diferença entre os pixels da imagem, a energia é 0 e quando é constante a energia é 1. O seu cálculo pode ser feito por meio da Equação 4:

$$Ene = \sum_{i,j=0}^{Ng-1} (C_{ij})^2. \quad (4)$$

2.6 Trabalhos Relacionados

Para o desenvolvimento desse trabalho, foram utilizados descritores clássicos aplicados em diversos trabalhos encontrados na literatura.

Ali *et al.*, (2014), desenvolveram um método de detecção automática do glaucoma com base em características de textura locais em imagens de fundo de olho. O descritor utilizado para extração das características foi o LPB. Nesse trabalho foi implementado a modelagem completa do LBP, de modo a capturar as características de textura em toda a imagem, sem visar nenhum sintoma específico. Cada região local é representada por três operadores, seu pixel central, e a diferença local com os dois componentes complementares, o sinal e a magnitude. Para classificação fora utilizadas 13 imagens com glaucoma e 28 não glaucomatosas, sendo que, dessas 28 algumas continham Retinopatia Diabética (RD). O critério usado para classificação foi o *leave-one-out* em conjunto com o classificador KNN, obtendo uma taxa de reconhecimento de 95%, com uma especificidade de 92,3% e sensibilidade de 96,4%. O método obteve bons resultados, distinguindo até mesmo as imagens com RD como não glaucomatosas. O ponto negativo desse trabalho foi

a pequena quantidade de imagens utilizadas.

Silva *et al.*, (2014a), desenvolveram um sistema para detecção e classificação de motocicletas em vias públicas e detecção de motociclista sem capacete. Para atingir o objetivo os autores utilizaram um descritor híbrido para extração de características com base nos descritores LBP, *Histograms of Oriented Gradients* (HOG) e Transformada Circular de Hough (TCH). Nesse trabalho as imagens não foram avaliadas por completo, pois só importava a parte que continha a cabeça do motociclista. Após selecionada a região de interesse da imagem foi aplicada a TCH para identificar os dez melhores círculos na imagem, que provavelmente seriam a cabeça do motociclista. Em seguida foi aplicado os descritores LBP e HOG nos círculos identificados pela TCH, após isso os dois vetores resultantes do LBP e HOG são combinados, gerando um único vetor. Esses descritores foram utilizados para extrair as características das imagens e em seguida os vetores de atributos foram usados para classificação. Para avaliação do sistema proposto foram usadas 471 imagens de motociclistas e três classificadores, dentre eles, o que mais se destacou foi *Naive Bayes*, obtendo uma acurácia superior 92%.

Simonthomas, Thulasi e Asharaf (2014), tinham como objetivo apresentar um novo método para detecção automática do glaucoma, utilizando o descritor de características de Haralick em imagens de fundo de olho. Esse descritor foi escolhido por ser invariante a translação e rotação, e descrever aspectos intuitivos das imagens. Primeiramente foi calculada a matriz GLCM para as quatro orientações da imagem em tons de cinza, sendo elas 0°, 45°, 90° e 135°. Logo após foram extraídas as 14 características de Haralick a partir da matriz GLCM. Para classificação foram utilizadas 30 imagens saudáveis e 30 doentes, sendo essa uma das desvantagens do trabalho, pois é um conjunto pequeno de amostras. O classificador usado foi o *K-Nearest-Neighbor* (KNN), que por sua vez demonstrou a eficácia do método desenvolvido, pois alcançou uma acurácia acima de 98%. Com isso podemos ver que o novo método atingiu um excelente resultado.

O trabalho de Araújo *et al.*, (2013), teve como objetivo o diagnóstico da RD que é uma patologia causada pelo diabetes mellitus. Um dos métodos propostos utilizava o algoritmo SURF para extração de características, porém o número de atributos retornados pelo algoritmo era diferente para cada imagem, dificultando o uso de classificadores. Para contornar essa situação, foram utilizados os dicionários

visuais para gerar um único vetor de atributos para classificação. O vetor de atributo encontrado foi utilizado para classificação das imagens em saudáveis ou patológicas. A classificação foi feita por meio do classificador *Support Vector Machine* (SVM), usando 9 imagens da retina para treinamento, a saber: 4 patológicas e 5 não patológicas. Para testar o classificador foram utilizadas 35 imagens patológicas e 45 não patológicas. A etapa de classificação obteve uma acurácia acima de 81%.

Rocha *et al.* (2012) buscavam em seu trabalho o desenvolvimento de um algoritmo para a detecção automática da Retinopatia Diabética (RD). O método proposto baseava-se nos Dicionários Visuais, que por sua vez eram construídos por meio da detecção de Pontos de Interesse (PI) encontrados dentro da Região de Interesse (RI), região essa delimitada por especialistas. O descritor utilizado para seleção dos PIs foi o SURF, buscando encontrar um número razoável de PIs, número este definido em 1000 PIs por imagens. O critério utilizado para classificação foi o *cross-validation* e o classificador foi o SVM. Foram executados vários testes com diversas bases de imagens, estabelecendo níveis de sensibilidade diferente em busca de um resultado satisfatório, onde o melhor resultado foi 87% de especificidade com uma sensibilidade maior que 95% e área sob a curva ROC de 95,30%.

2.7 Critérios de Avaliação

Nessa seção, serão apresentados os critérios utilizados para avaliação dos resultados obtidos por meio dos classificadores.

2.7.1 Matriz de Confusão

A maioria dos critérios de análise dos resultados de uma classificação parte de uma matriz de confusão, que indica a quantidade de classificações corretas e incorretas para cada uma das classes.

Uma matriz de confusão é criada baseada em quatro valores: Verdadeiro Positivo (VP), número de imagens corretamente classificadas como glaucomatosas; Falso Positivo (FP) número de imagens classificadas como saudáveis, quando na realidade, eram glaucomatosas; Falso Negativo (FN), número de imagens classificadas como glaucomatosas, quando na realidade, eram saudáveis e Verdadeiro Negativo (VN), número de imagens classificadas como saudáveis

corretamente (CHIMIESKI; FAGUNDES, 2013).

Para uma melhor compreensão podemos usar como suposição a existência de duas classes hipotéticas: *X* e *Y*. A Tabela 1 mostra os valores e a forma como cada um é definido.

Tabela 1 - Classes da matriz de confusão.

VP	Total de itens X pertencentes a classe X
FP	Total de itens Y pertencentes a classe X
FN	Total de itens X pertencentes a classe Y
VN	Total de itens Y pertencentes a classe Y

A partir dessas quantidades algumas taxas estatísticas podem ser calculadas para avaliar o desempenho dos classificadores. As taxas de Precisão, *Recall*, Acurácia e *F-Measure* (FM) são calculadas respectivamente pelas Equações 5, 6, 7 e 8.

2.7.2 Precisão

A precisão (*P*) é uma medida que reflete a proporção de VP em relação a todas as predições positivas. A precisão pode ser calculada pela seguinte Equação 5:

$$P = \frac{VP}{VP + FP}. \quad (5)$$

2.7.3 Recall

O *recall* (*R*) é a proporção de VP em relação as suas predições positivas e as suas incorretas predições negativas. O seu cálculo é expresso pela Equação 6:

$$R = \frac{VP}{VP + FN}. \quad (6)$$

2.7.4 F-Measure

O *F-Measure* (FM) reflete a proporção de VP em relação as predições positivas e todas as suas predições negativas. Segundo Chimieski e Fagundes (2013), essa medida só produz bons resultados quando as taxas de precisão e *recall* são equilibradas, assim, essa medida é bastante significativa. Seu cálculo é expresso pela Equação 7:

$$FM = \frac{2 * VP}{2 * VP + FN + FP}. \quad (7)$$

2.7.5 Acurácia

A acurácia (A) de um classificador é a representação da porcentagem de casos corretamente analisados em um conjunto de teste. Essa medida mede o quanto bem um classificador reconhece instâncias de diversas classes. Ela pode ser calculada a partir da Equação 8:

$$A = \frac{VP + VN}{VP + FP + FN + VN}. \quad (8)$$

2.7.6 Índice Kappa

O índice Kappa (K) vem sendo recomendado como uma medida apropriada da exatidão por representar inteiramente a matriz de confusão. Ele toma todos os elementos da matriz em consideração, ao invés de apenas aqueles que se situam na diagonal principal, o que ocorre quando se calcula a exatidão global da classificação (ROSENFELD; FITZPATRICK-LINS, 1986).

“O Kappa é um coeficiente de concordância para escalas nominais que mede o relacionamento entre a concordância, além da casualidade, e a discordância esperada” (ROSENFELD; FITZPATRICK-LINS, 1986). O índice Kappa pode ser encontrado com base na Equação 9:

$$K = \frac{(\text{observado} - \text{esperado})}{1 - \text{esperado}}. \quad (9)$$

Neste caso, entenda-se por “observado” o valor global para a porcentagem correta, ou seja, o somatório da diagonal principal da matriz dividido pela quantidade de elementos. Por “esperado” entenda-se os valores calculados usando-se os totais de cada linha e cada coluna da matriz.

O nível de exatidão do índice Kappa foi classificado conforme a Tabela 2, de acordo com o estabelecido por Landis e Koch (1977).

Tabela 2 - Nível de exatidão de uma classificação, conforme o valor do Kappa.

Índice <i>Kappa</i> (K)	Qualidade
$K < 0.2$	Ruim
$0.2 \leq K < 0.4$	Razoável
$0.4 \leq K < 0.6$	Bom
$0.6 \leq K < 0.8$	Muito Bom
$K \geq 0.8$	Excelente

3 METODOLOGIA

O fluxograma apresentado na Figura 7 ilustra todos os passos realizados neste trabalho.

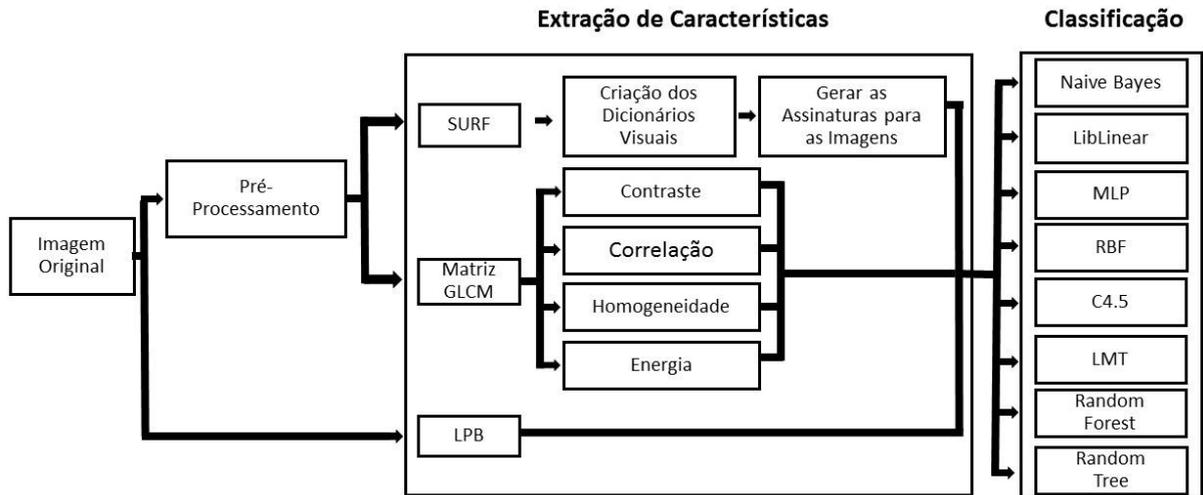


Figura 7 - Fluxograma com os passos do método proposto.

3.1 Pré-Processamento

A etapa de Pré-Processamento tem como objetivo amenizar as diferenças de luminosidade entre as imagens e, evidenciar suas características para a fase de Extração de Características com o SURF e GLCM. Inicialmente as imagens foram convertidas para tons de cinza, e em seguida, foi realizada a equalização do histograma, de modo a melhorar o contraste das imagens.

3.2 Extração de Características

Na etapa da Extração de Características com o SURF, as imagens equalizadas foram submetidas à extração. O SURF por padrão retorna para cada ponto característico um vetor com 64 posições, esse vetor contém os valores que representarão a imagem numericamente, mas para melhor representar as imagens, nesse trabalho foi utilizado o valor de 128 posições, de modo a melhor descrever as imagens.

Na etapa de Criação dos Dicionários Visuais as duas matrizes com as características extraídas passaram por um processo de agrupamento. O algoritmo

utilizado para agrupamento foi o *k-means*. Esse algoritmo dividiu a matriz em 128 *clusters*, e logo após selecionou as características que melhor representaram cada um desses *clusters*. A Figura 8 apresenta de forma ilustrativa os passos seguidos na formação do dicionário visual.

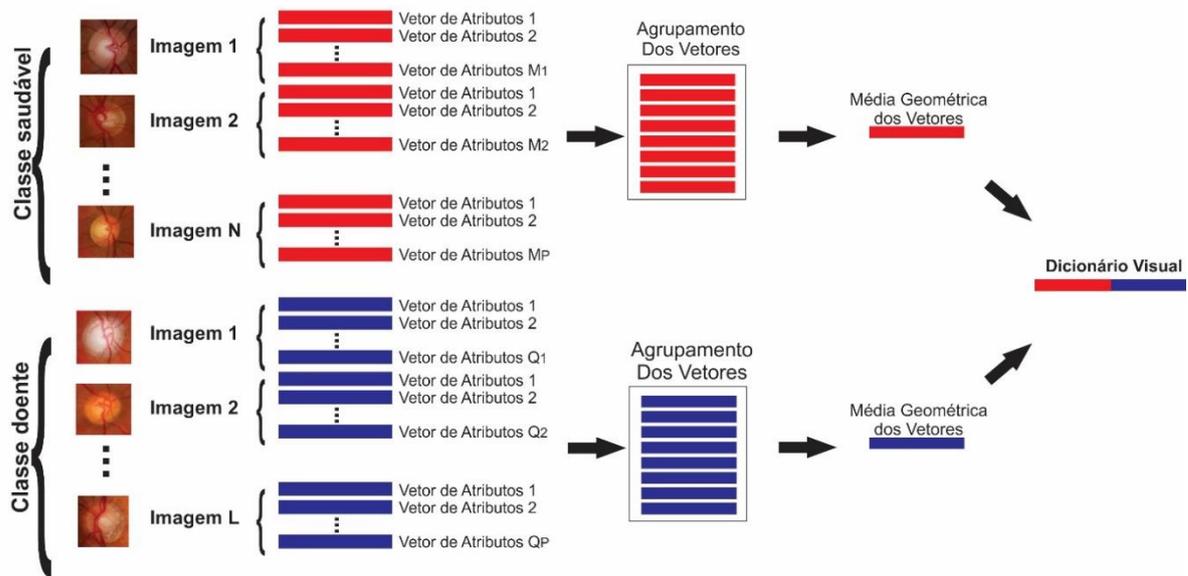


Figura 8 - Formação dos dicionários visuais.

Para gerar as assinaturas das imagens, o processo realizado foi basicamente o mesmo para constituição do dicionário visual. Primeiramente as imagens passaram pela etapa de Pré-processamento, depois foram extraídas suas características com SURF, resultando assim em duas matrizes, uma com atributos doentes e outra com atributos saudáveis. A assinatura é a representação de uma imagem por meio de um vetor, construído a partir do dicionário visual, sendo inicialmente composto apenas por zeros.

As assinaturas das imagens foram geradas a partir da comparação de cada atributo da imagem com todas as linhas (palavras) do dicionário, calculando a diferença entre o atributo e a linha do dicionário, assim, a posição que possuía a menor diferença foi localizada. Além disso, foi incrementada em uma unidade a respectiva posição no vetor, ocorrendo esse processo para todos os atributos de todas as imagens. A Figura 9 ilustra o processo de formação das assinaturas.

A fase de extração de características com LBP ocorre com as imagens originais, ou seja, elas não necessitam de pré-processamento e nem da conversão para tons de cinza.

Foram utilizadas quatro características da GLCM, a saber: contraste, correlação, homogeneidade e energia. Essas características foram calculadas usando as quatro orientações disponíveis (0°, 45°, 90° e 135°). De acordo com a quantidade de orientações, cada característica retorna um valor. No final da extração serão gerados 16 valores.

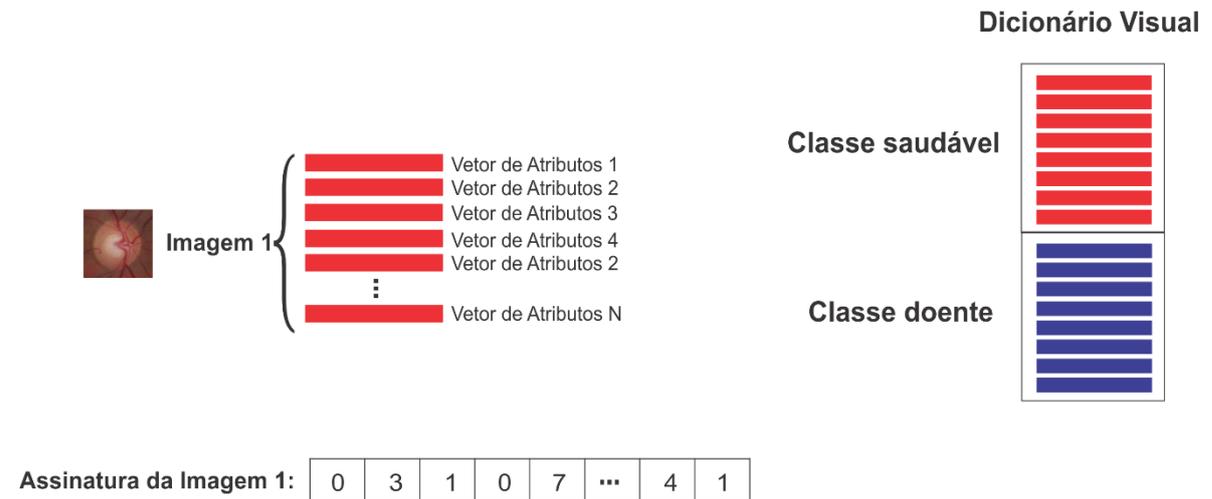


Figura 9 - Processo de formação das assinaturas para a imagem.

3.3 Classificação

O objetivo de um classificador é separar em classes os vetores de atributos. Dessa maneira, os vetores de atributos que estiverem na mesma região de decisão compartilham a mesma classe (SILVA, 2014b).

Nesse trabalho, para avaliar a eficiência da extração de características foram utilizados os seguintes classificadores:

Naive Bayes (JOHN; LANGLEY, 1995): “O Naive Bayes se baseia na aplicação da teoria Bayesiana para o cálculo das probabilidades necessárias para a classificação” (MITCHELL, 1997).

LibLinear (FAN *et al.*, 2008): O LibLinear é classificador que suporta regressão logística e máquinas de vetores de suporte lineares. Ele é muito eficiente para a resolução de problemas com grande quantidade de dados.

Multi Layer Perceptron (MLP) (AMARI, 1967): Haykin (2001) afirma que “uma

rede MLP é um sistema de neurônios ligados por conexões sinápticas e dividido em neurônios de entrada, que recebem estímulos do meio externo, neurônios internos e neurônios de saída, que se comunicam com o exterior”.

Radial Basis Function Network (RBFN) (LEWITT, 1990): Em sua forma mais básica, uma Rede de Função de Base Radial (*Radial-Basis Function Network*) contém três camadas com papéis totalmente diferentes. A primeira camada possui em sua constituição as unidades sensoriais, responsáveis por fazer a conexão entre a rede e seu ambiente. A segunda camada aplica uma transformação não linear do espaço de entrada para o espaço oculto. Por fim, a camada de saída é sempre linear.

C4.5 (QUINLAN, 1986): O algoritmo C4.5 tem como objetivo a criação de Árvores de Decisão com tratamento de atributos contínuos e discretos construindo uma árvore com um número de partições variável e com folhas sendo indicadas pelos valores do atributo categórico.

Logistic Model Trees (LMT) (LANDWEHR; HALL; FRANK, 2005): O LMT utiliza-se de técnicas como métodos de indução de árvore e modelos lineares. Essas técnicas são comuns para tarefas de aprendizagem supervisionada, previsões de classes nominais e valores numéricos. Vale destacar que algoritmo se adapta a problemas de classificação, utilizando regressão logística em vez de regressão linear.

Random Forest (BREIMAN, 2001): O algoritmo *Random Forest* é uma combinação de predições de diversas árvores em que cada árvore depende dos valores de um vetor independente, amostrados aleatoriamente e com a mesma distribuição para todas as árvores da floresta. Aqui, floresta é o que se denomina para uma série de Árvores de Decisão. Após a geração de um grande número de árvores, as classes com maior número de votos são eleitas.

Random Tree (ALDOUS, 1991): O algoritmo *Random Tree* é uma árvore induzida aleatoriamente a partir de um conjunto de árvores possíveis, usando “ K ” atributos aleatórios em cada nodo. O termo “aleatoriamente” significa que cada árvore tem uma chance igual de ser amostrada. “Uma das formas mais utilizadas de se construir uma *Random Tree*, é através do processo de ramificação Galton-Watson” (RODRIGUEZ, 2012).

4 RESULTADOS E DISCUSSÕES

Neste capítulo, serão apresentados os resultados encontrados no desenvolvimento da metodologia desse trabalho. Para isso, foram utilizadas 40 imagens saudáveis e 15 doentes para construção do dicionário visual, e para verificar o desempenho do algoritmo, foram usadas 78 imagens saudáveis e 25 doentes. Vale destacar que as imagens utilizadas para o teste do algoritmo foram diferentes das utilizadas para a formação do dicionário e a quantidade de imagens foi definida de modo empírico.

Para os descritores GLCM e LBP, foram realizados testes com todas as imagens da base, tendo em vista que eles retornam de seu processamento um único vetor de características para cada imagem.

O *software* utilizado para classificação foi o *Waikato Environment for Knowledge Analysis* (WEKA) (WITTEN; FRANK; HALL, 2011). Os algoritmos classificadores utilizados nesse trabalho foram: *Naive Bayes*, *Random Forest*, C4.5, RBFN, MLP, LMT, *Random Tree* e LibLinear.

Para avaliação dos resultados foram utilizados os seguintes critérios: VP, FP, FN, VN, precisão, *recall*, FM, acurácia e Kappa. Os parâmetros utilizados para classificação foram os padrões do WEKA e o critério de avaliação foi o *k-fold cross-validation* (com $k = 10$).

Inicialmente foram executados testes separados com cada um dos descritores: SURF, LPB e GLCM. Os resultados obtidos são apresentados na Tabela 3, onde inicialmente são mostrados os resultados com as características extraídas pelo SURF, logo em seguida os resultados obtidos após a extração pelo LBP e por fim com a GLCM.

Com base nos resultados da classificação apresentados na Tabela 3, pode-se concluir que ambos descritores de modo individual não produzem bons resultados. Os melhores resultados foram produzidos pela RBF, *Random Forest* e MLP para as características do SURF, LBP e GLCM respectivamente, com Kappa de 0.13, 0.34 e 0,31. De acordo com a Tabela 2 esses resultados são classificados apenas como “ruim” e “razoáveis”.

Dessa maneira, buscando melhorar os resultados da classificação, as

características extraídas pelos descritores SURF, LBP e GLCM foram combinadas da seguinte forma: SURF + GLCM, LBP + GLCM, SURF + LBP e SURF + LBP + GLCM. Desse modo, foram verificadas todas as possibilidades, formando um vetor único para melhor descrever as imagens.

Tabela 3 - Resultados encontrados pela extração de características com o SURF, LBP e GLCM separadamente.

	CLASSIFICADOR	VP	FP	FN	VN	P	R	FM	A	K
SURF 256 ATRIBUTOS	<i>Naive Bayes</i>	20	5	48	30	72,00	48,50	50,60	48,54	0,12
	<i>LibLinear</i>	11	14	6	72	79,10	80,30	79,20	80,58	0,41
	<i>MLP</i>	5	20	6	72	70,30	74,80	70,90	74,76	0,15
	RBF	5	20	7	71	69,20	73,80	70,20	73,79	0,13
	<i>C4.5</i>	8	17	20	58	65,50	64,10	64,70	64,07	0,06
	<i>LMT</i>	0	25	1	77	57,20	74,80	64,80	74,76	-0,02
	<i>Random Forest</i>	0	25	0	78	57,30	75,70	65,30	75,73	0
	<i>Random Tree</i>	6	19	51	57	62,20	61,20	61,70	61,16	-0,03
LBP 256 ATRIBUTOS	<i>Naive Bayes</i>	22	18	34	84	71,40	67,10	68,60	67,09	0,23
	<i>LibLinear</i>	15	25	12	106	74,50	76,60	74,90	76,58	0,31
	<i>MLP</i>	18	22	22	96	72,20	72,20	72,20	72,15	0,26
	RBF	2	38	4	114	64,50	73,40	65,30	73,41	0,02
	<i>C4.5</i>	11	29	21	97	66,20	68,40	67,10	68,35	0,10
	<i>LMT</i>	11	29	13	105	70,10	73,40	70,90	73,41	0,19
	<i>Random Forest</i>	16	24	11	107	76,00	77,80	76,30	77,85	0,34
	<i>Random Tree</i>	12	28	21	97	67,20	69,0	67,90	68,99	0,13
GLCM 16 ATRIBUTOS	<i>Naive Bayes</i>	19	21	55	63	62,50	51,90	55,00	51,90	0,01
	<i>LibLinear</i>	0	40	0	118	55,80	74,70	63,90	74,68	0
	MLP	16	24	14	104	74,20	75,90	74,70	75,95	0,31
	RBF	0	40	0	118	55,80	74,70	63,90	74,68	0
	<i>C4.5</i>	5	35	14	104	62,50	62,50	64,70	68,99	0,01
	<i>LMT</i>	5	35	6	112	68,40	74,10	68,10	74,05	0,09
	<i>Random Forest</i>	9	31	17	101	65,90	69,60	67,20	69,62	0,09
	<i>Random Tree</i>	16	24	27	91	68,50	67,70	68,10	67,72	0,17

A Tabela 4 mostra os resultados obtidos pela nova classificação utilizando as características da combinação SURF + GLCM, gerando um vetor com 272 características. Esse vetor é composto da seguinte forma: 256 características resultantes do dicionário visual utilizando o SURF e 16 da GLCM.

Analisando a Tabela 4 podemos compreender que a combinação dos descritores SURF e GLCM não produziram bons resultados. Essa combinação gerou os seguintes resultados: o pior resultado foi o do classificador LMT, com acurácia de 74% e Kappa de 0,02; o melhor resultado foi do LibLinear alcançando acurácia de 79% e Kappa de 0,37. Com base na Tabela 2 o resultado do LMT é considerado “ruim” e do LibLinear “razoável”.

Tabela 4 - Resultados encontrados pela combinação dos descritores SURF e GLCM.

	VP	FP	FN	VN	P	R	FM	A	K
<i>Naive Bayes</i>	18	7	46	32	69,00	48,50	51,20	48,54	0,09
LibLinear	10	15	6	72	77,80	79,60	77,90	79,61	0,37
MLP	7	18	7	71	72,50	75,70	73,10	75,73	0,22
RBF	6	19	8	78	70,00	73,80	71,00	73,79	0,16
C4.5	8	17	14	64	68,70	69,90	69,20	69,90	0,15
LMT	1	24	2	76	65,60	74,80	66,40	74,76	0,02
<i>Random Forest</i>	2	23	0	78	82,80	77,70	69,60	77,67	0,11
<i>Random Tree</i>	9	16	16	62	68,90	68,90	68,90	68,93	0,15

Na Tabela 5, são expostos os resultados da combinação dos descritores LBP e GLCM. O vetor de resultante contém 272 características, sendo composto da seguinte forma: 256 características resultantes do LBP e 16 da GLCM.

Tabela 5 - Resultados encontrados pela combinação dos descritores LBP e GLCM.

	VP	FP	FN	VN	P	R	FM	A	KAPPA
<i>Naive Bayes</i>	22	18	35	83	71,10	66,50	68,10	66,45	0,22
LibLinear	15	25	15	103	72,80	74,70	73,40	74,68	0,27
MLP	16	24	20	98	71,20	72,20	71,70	72,15	0,24
RBF	4	36	5	113	67,90	74,10	67,30	74,05	0,08
C4.5	8	32	22	96	62,80	65,80	64,10	65,85	0,01
LMT	10	30	13	105	69,10	72,80	70,00	72,78	0,16
<i>Random Forest</i>	15	25	11	107	75,10	77,20	75,40	77,15	0,32
<i>Random Tree</i>	17	23	19	99	72,60	73,40	72,90	73,41	0,27

Na Tabela 5 vemos que a junção dos descritores LBP e GLCM não geram bons resultados. A combinação produziu os seguintes resultados: o pior resultado foi o do classificador C4.5, alcançando apenas 64% de acurácia e Kappa de 0,01; o

melhor resultado foi do *Random Forest* alcançando acurácia de 77% e Kappa de 0,32. Com base na Tabela 2 o resultado do C4.5 é considerado “ruim” e do *Random Forest* “razoável”.

Por meio de comparações entre os resultados da combinação LBP + GLCM com os demonstrados na Tabela 4, compreendemos que a combinação LBP + GLCM gera resultados inferiores a combinação SURF + GLCM.

Uma outra combinação de descritores pode ser visualizada na Tabela 6. Nessa tabela, são apresentados os resultados da concatenação dos vetores de características dos descritores SURF e LBP. O vetor resultante contém 512 características, sendo composto da seguinte forma: 256 características resultantes do dicionário visual utilizando o SURF e 256 características do LBP.

Pela análise da Tabela 6 percebe-se que todos os classificadores obtiveram resultados melhorados em relação as classificações anteriores. Podemos observar que o pior resultado, gerado pela combinação SURF + LBP, é superior aos melhores resultados encontrados nas combinações anteriores.

Tabela 6 - Resultados encontrados pela combinação dos descritores SURF e LBP.

	VP	FP	FN	VN	P	R	FM	A	K
<i>Naive Bayes</i>	25	0	2	76	98,20	98,10	98,10	98,06	0,95
LIBLINEAR	25	0	1	77	99,10	99,00	99,00	99,00	0,97
MLP	24	1	2	76	97,10	97,10	97,10	97,09	0,92
RBF	24	1	2	76	97,10	97,10	97,10	97,09	0,92
C4.5	19	6	4	74	90,10	90,30	90,20	90,29	0,73
LMT	22	3	2	76	95,10	95,10	95,10	95,14	0,87
<i>Random Forest</i>	23	2	2	76	96,10	96,10	96,10	96,17	0,89
<i>Random Tree</i>	20	5	2	76	93,10	93,20	93,10	93,20	0,81

O classificador que mais se destacou foi o LibLinear, por ter alcançado os melhores índices, com acurácia de 99% e Kappa de 0,97. De acordo com a Tabela 2, o Kappa obtido pela LibLinear foi considerado “excelente”.

Por fim, foram combinados todos os descritores utilizados nesse trabalho, com o objetivo de analisar a melhor combinação. Na Tabela 7 são apresentados os resultados da concatenação dos vetores de características dos descritores SURF, LBP e GLCM. O vetor resultante contém 528 características, sendo composto da

seguinte forma: 256 características resultantes do dicionário visual utilizando o SURF e 256 características do LBP e 16 da GLCM.

Analisando a Tabela 7 compreendemos que a combinação de todos os descritores não produziu bons resultados, sendo seu melhor resultado inferior ao pior resultado da combinação SURF e LBP, apresentados na Tabela 6. Essa combinação gerou os seguintes resultados: o pior resultado foi o do classificador LibLinear, com acurácia de 79% e Kappa de 0,37; o melhor resultado foi do RBF alcançando acurácia de 83% e Kappa de 0,54. Dessa forma, de acordo com a Tabela 2 o resultado do LibLinear e do RBF são considerados “razoável” e “bom” respectivamente.

De acordo com as Tabelas 3, 4, 5, 6 e 7, pode-se afirmar que a combinação que obteve melhores resultados foi a do SURF e LBP. Por meio da avaliação da Tabela 6, vemos que com exceção do resultado do classificador C4.5, todos os outros são considerados excelentes. Percebe-se também que a junção do descritor GLCM não contribui para aprimoramento dos resultados, pois mediante a sua agregação a eficiência dos classificadores foi inferior.

Tabela 7 - Resultados encontrados pela combinação dos descritores SURF, LBP e GLCM.

	VP	FP	FN	VN	P	R	FM	A	KAPPA
<i>Naive Bayes</i>	12	13	6	72	80,30	81,60	80,40	81,55	0,44
LibLinear	10	15	6	72	77,80	79,60	77,90	79,61	0,37
MLP	12	13	5	73	81,40	82,50	81,30	82,52	0,47
RBF	16	9	8	70	83,30	83,50	83,40	83,49	0,54
C4.5	17	8	11	67	82,40	81,60	81,90	81,55	0,52
LMT	11	14	2	76	84,50	84,50	82,60	84,46	0,49
<i>Random Forest</i>	13	12	4	74	83,70	84,50	83,40	84,47	0,53
<i>Random Tree</i>	15	10	10	68	80,60	80,60	80,60	80,58	0,47

5 CONSIDERAÇÕES FINAIS

O processamento digital de imagens está evoluindo rapidamente tornando-se uma ferramenta de auxílio em todas as áreas. Na medicina, ele vem sendo utilizado em diversas áreas, uma vez que o diagnóstico de doenças por PDI traz rapidez, confiabilidade e redução de custo.

Esse trabalho apresentou uma forma de detecção automática do glaucoma em imagens do fundo de olho da retina pela extração de características. Para a extração das características das imagens foram utilizados o SURF, LBP e GLCM. Seus resultados foram avaliados separadamente, entretanto não foram aceitáveis. Com isso foram feitas várias combinações, concatenados as características obtidas pelos três descritores.

Os melhores resultados foram os obtidos por meio da combinação do SURF com o LBP, onde o classificador *LibLinear* atingiu cerca de 99% de acurácia, totalizando um Kappa de 0.97.

5.1 Trabalhos Futuros

Nesse trabalho, foram apresentados resultados provenientes da combinação de descritores. Entretanto, a combinação dos descritores SURF e LBP geraram muitos atributos. Dessa maneira, como trabalho futuro espera-se utilizar algoritmos de seleção de características para filtrar somente as mais significativas, também serão avaliados outros descritores e classificadores. Além disso, será feita a implementação de algoritmos existentes na literatura e comparado com o método desenvolvido.

5.2 Publicações Obtidas

Alguns artigos foram escritos descrevendo o algoritmo implementado e os resultados obtidos, os quais foram submetidos e aceitos em alguns congressos:

SILVA, W. L. *et al.* **Extração de Características de Imagens da Retina pelo uso do SURF e LBP para Detecção Automática do Glaucoma.** Escola Regional de Informática do Piauí - ERIPI. 2015a.

SILVA, W. L. *et al.* **Extração de Características de Imagens da Retina para a Detecção Automática do Glaucoma.** Simpósio Brasileiro de Automação Inteligente - SBAI. 2015b.

REFERÊNCIAS BIBLIOGRÁFICAS

ALDOUS, D. **The Continuum Random Rree**. Ann. Probab., 21(1):248–289, 1991.

ALI, M. A. *et al.* **Glaucoma Detection Based on Local Binary Patterns in Fundus Photographs**. In: SPIE Medical Imaging. International Society for Optics and Photonics, 2014. p. 903531-903531-7.

AMARI, S. **Theory of Adaptative Patter Classifiers**. IEEE Transactions, EC-16, pgs. 299–307, 1967.

ARAÚJO, F. *et al.* **Automatic Identification of Diabetic Retinopathy in Retinal Images Using Ensemble Learning**. Workshop de Informática Médica (WIM), Maceió, Alagoas, 2013.

BAY, H.; TUYTELAARS, T.; VAN, G. L. **SURF**: Speeded up robust features. In: Computer vision–ECCV 2006. Springer Berlin Heidelberg, p. 404-417, 2006.

BAY, H. *et al.* **Speeded-up Robust Features (SURF)**. Computer vision and image understanding, v. 110, n. 3, p. 346-359, 2008.

BREIMAN, L. **Random Forests**. Machine learning, v. 45, n. 1, p. 5-32, 2001.

CARVALHO, T. J. **Aplicação de Técnicas de Visão Computacional e Aprendizado de Máquina para a Detecção de Exsudatos Duros em Imagens de Fundo de Olho**. Dissertação de Mestrado em Ciência da Computação. Campinas: Instituto de Computação, Universidade Estadual de Campinas, 2010.

CHIMIESKI, B. F.; FAGUNDES, R. D. **Association and Classification Data Mining Algorithms Comparison over Medical Datasets**. Journal of Health Informatics, v. 5, n. 2, 2013.

DANNY, L. Y. T. **Computer Based Diagnosis of Glaucoma Using Principal Component Analylis (PCA): A Comparative Study**. Tese de Doutorado - SIM University, School of Science and Technology. 2011.

EMUC. Disponível em: <http://emuc2014.blogspot.com.br/2014/11/super-interessante-colecoes-o-corpo.html>. Acessado em janeiro de 2014.

FAN, R. E. *et al.* **LIBLINEAR**: A Library for Large Linear Classification. The Journal of Machine Learning Research, v. 9, p. 1871-1874, 2008.

GUERRA, R. A. A. **Identificação Automática do Disco Óptico em Imagens Coloridas da Retina**. Dissertação de Mestrado em Engenharia Biomédica. Porto-Portugal: Faculdade de Engenharia da Universidade do Porto, 2008.

GONZALES, R.C.; WOODS, R.E. **Digital Image Processing**. Nova Jersey: Prentice Hall, 2002. 793 p.

HARALICK, R. M.; SHANMUGAM, K.; DINSTEN, H. **Textural features for image classification**. Systems, Man and Cybernetics, IEEE Transactions on, n. 6, p. 610-621, 1973.

HAYKIN, S. **Neural Networks: A Comprehensive Foundation**. Prentice Hall, 2. ed. Prentice Hall, 2001.

IYYANARAPPAN, A.; TAMILPAVAI, G. **Glaucomatous Image Classification Using Wavelet Based Energy Features And PNN**. International Journal of Technology Enhancements and Emerging Engineering Research, vol. 2, issue. 4 , ISSN 2347-4289, 2014.

JOHN, G H.; LANGLEY, P. **Estimating Continuous Distributions in Bayesian Classifiers**. In: Proceedings of the Eleventh conference on Uncertainty in artificial intelligence. Morgan Kaufmann Publishers Inc. p. 338-345, 1995.

JUNIOR, S, S, L, P. **Detecção de vasos sanguíneos em Imagens de Fundo de Olhos**. Dissertação de Mestrado em Biometria. Recife: Departamento de Informática e Estatística, Universidade Federal Rural de Pernambuco. 2006.

LANDIS, J. R.; KOCH, G. G. **The Measurement of Observer Agreement for Categorical Data**. Biometrics, p. 159-174, 1977.

LANDWEHR, N.; HALL, M.; FRANK, E. **Logistic Model Trees**. Machine Learning, v. 59, n. 1-2, p. 161-205, 2005.

LEWITT, R. M. **Multidimensional Digital Image Representations Using Generalized Kaiserbessel Window Functions**. J. Opt. Soc. Am. A, 7(10):1834–1846, 1990.

MITCHELL, T.M. **Machine Learning**. McGraw Hill, New York, 1997.

NANNI, L.; LUMINI, A.; BRAHNAM, S. **Survey on LBP Based Texture Descriptors for Image Classification**. Expert Systems with Applications, v. 39, n. 3, p. 3634-3641, 2012.

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.

QUIGLEY, H. A.; BROMAN, A. T. **The Number of People with Glaucoma Worldwide in 2010 and 2020**. British journal of ophthalmology, v. 90, n. 3, p. 262-267, 2006.

QUINLAN, J. R. **Induction of Decision Trees**. Machine learning, v. 1, n. 1, p. 81-106, 1986.

ROCHA, A. *et al.* **Points of Interest and Visual Dictionaries for Automatic Retinal Lesion Detection**. Biomedical Engineering, IEEE Transactions on, v. 59, n. 8, p. 2244-2253, 2012.

RODRIGUEZ, P. M. **Processos de Ramificação**: teoria e aplicações. Technical report, ICMC/USP, São Carlos, 2012.

ROSENFELD, G. H.; FITZPATRICK-LINS, K. **A Coefficient of Agreement as a Measure of Thematic Classification Accuracy**. Photogrammetric engineering and remote sensing, v. 52, n. 2, p. 223-227, 1986.

SANTOS, C; SANTOS, E. M.; SOUTO, E. **Análise de Características para Detecção de Nudez em Imagens**. XXV SIBGRAPI – Conference on Graphics, Patterns and Images, 2012.

SILVA, M. A. T. **Uso de Matrizes de Co-ocorrências para Classificação Automática de Imagens de Cana-de-Açúcar**. Monografia de Graduação em Ciência da Computação. Minas Gerais: Universidade Federal de Lavras, 2013.

SILVA, R. R. V. *et al.* **Helmet Detection on Motorcyclists Using Image Descriptors and Classifiers**. In: Graphics, Patterns and Images (SIBGRAPI), 27th SIBGRAPI Conference on. IEEE, 2014. p. 141-148, 2014a.

SILVA, R, R, V. **Detecção do Uso de Capacete por Motociclistas em Vias Públicas**. Dissertação de Mestrado. Teresina, Centro de Ciências da Natureza, Universidade Federal do Piauí, 2014b.

SIMONTHOMAS, S.; THULASI, N.; ASHARAF, P. **Automated Diagnosis of Glaucoma Using Haralick Texture Features**. In: Information Communication and Embedded Systems (ICICES), 2014 International Conference on. IEEE, 2014. p. 1-6.

SOARES, J. V. B. **Segmentação de Vasos Sanguíneos em Imagens de Retina Usando Wavelets de Classificadores Estatísticos**. Dissertação de Mestrado. São Paulo: Instituto de Matemática e Estatística, Universidade de São Paulo, 2006.

TRUCCO, E. *et al.* **Validating Retinal Fundus Image Analysis Algorithms: Issues And a Proposal**. Invest. Ophthalmol. Vis. Sci., vol. 54, no. 5, pp. 3546–3559, 2013.

VERAS, R. M. S. **Detecção e Segmentação de Estruturas em Imagens Médicas de Retina**. Tese de Doutorado. Fortaleza: Universidade Federal do Ceará, Departamento de Engenharia de Teleinformática, 2014.

WEINREB, R. N.; KHAW, P. T. **Primary open-angle glaucoma**. The Lancet, v. 363, n. 9422, p. 1711-1720, 2004.

WHO. **World Health Organization (WHO)**. Disponível em: <http://apps.who.int/ghodata/?vid=5200>, 2014, acessado em outubro de 2014.

WITTEN, I. H.; FRANK, E.; HALL, M. A. **DATA MINING: Practical Machine Learning Tools and Techniques**. Morgan Kaufmann. 3. ed., 2011.



**TERMO DE AUTORIZAÇÃO PARA PUBLICAÇÃO DIGITAL NA BIBLIOTECA
“JOSÉ ALBANO DE MACEDO”**

Identificação do Tipo de Documento

- Tese
- Dissertação
- Monografia
- Artigo

Eu, Wallinson de Lima Silva, autorizo com base na Lei Federal nº 9.610 de 19 de Fevereiro de 1998 e na Lei nº 10.973 de 02 de dezembro de 2004, a biblioteca da Universidade Federal do Piauí a divulgar, gratuitamente, sem ressarcimento de direitos autorais, o texto integral da publicação *Uso de Descritores de Textura para Classificação de Imagens da Retina para a Detecção Automática do Glaucoma* de minha autoria, em formato PDF, para fins de leitura e/ou impressão, pela internet a título de divulgação da produção científica gerada pela Universidade.

Picos-PI 26 de fevereiro de 2016.



Assinatura