

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

MAÍLA DE LIMA CLARO

**CLASSIFICAÇÃO AUTOMÁTICA DO GLAUCOMA USANDO DESCRITORES DE
TEXTURA, COR E MÚLTIPLOS CLASSIFICADORES**

PICOS - PI
2015

MAÍLA DE LIMA CLARO

CLASSIFICAÇÃO AUTOMÁTICA DO GLAUCOMA USANDO DESCRITORES DE
TEXTURA, COR E MÚLTIPLOS CLASSIFICADORES

Trabalho de Conclusão de Curso apresentado ao Curso de Bacharelado em Sistemas de Informação do Campus Senador Helvídio Nunes de Barros da Universidade Federal do Piauí como parte dos requisitos para obtenção do Grau de Bacharel em Sistemas de Informação.

Orientadora: Prof^a. Ma. Alcilene Dalília de Sousa.

Coorientador: Prof^o. Me. Flávio Henrique Duarte Araújo

PICOS - PI

2015

FICHA CATALOGRÁFICA

Serviço de Processamento Técnico da Universidade Federal do Piauí

Biblioteca José Albano de Macêdo

C613c Claro, Maíla de Lima.

Classificação automática do glaucoma usando descritores de textura, cor e múltiplos classificadores / Maíla de Lima Claro.– 2015.

CD-ROM : il.; 4 ¾ pol. (41 f.)

Monografia (Curso Bacharelado em Sistemas de Informação) – Universidade Federal do Piauí, Picos, 2015.

Orientador(A): Prof^a. Ma. Alcilene Dalília de Sousa

1. Glaucoma-Imagens da retina. 2. Glaucoma-Classificação Automática. 3. Processamento Digital de Imagens. I. Título.

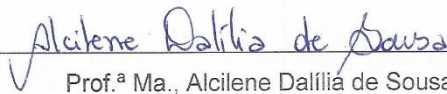
CDD 005

CLASSIFICAÇÃO AUTOMÁTICA DO GLAUCOMA USANDO DESCRITORES
DE TEXTURA, COR E MÚLTIPLOS CLASSIFICADORES

Maíla de Lima Claro

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

PICOS - PI, 28 / 01 / 2016



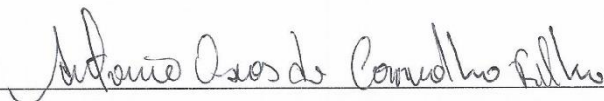
Prof.^a Ma., Alcilene Dalília de Sousa

Orientadora



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

Membro



Prof. Me., Antonio Oseas de Carvalho Filho

Membro

Dedico este trabalho a minha família, em especial aos meus pais, Maria Vilani de Lima Claro e José Claro Neto, por sempre acreditarem no meu potencial e me apoiarem durante todo o tempo.

AGRADECIMENTOS

À Deus, em primeiro lugar, por nos dá a vida, e por sempre guiar o meu caminho.

A minha família pelo amor, incentivo e confiança. Em especial aos meus pais, José Claro Neto e Maria Vilani de Lima Claro, pelos ensinamentos, conselhos e pelo esforço em sempre proporcionar a seus filhos tudo de melhor. Aos meus irmãos Maísa de Lima Claro e Maelson de Lima Claro pelos momentos de descontração.

À Universidade Federal do Piauí - UFPI.

Aos meus orientadores, Alcilene Dalília de Sousa e Flávio Henrique Duarte de Araújo, pela atenção e apoio durante o desenvolvimento do projeto e por todos os ensinamentos no decorrer destes anos.

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

Aos colegas e amigos, em especial Wallinson de Lima Silva, Nayara Holanda de Moura e Maria Jaqueline Carvalho de Moura que contribuíram com ideias, implementações, críticas e sugestões durante este período intenso de estudos, e que, apesar dos momentos de angústia no decorrer destes anos, nunca perderam a alegria.

A todos vocês muito obrigada!

“ - Eu sei como ele conseguiu.
Todos perguntaram: - Pode nos dizer como?
- É simples, respondeu o Einstein.
- Não havia ninguém ao seu redor, para
lhe dizer que não seria capaz”

Albert Einstein

RESUMO

Processamento digital de imagem é destaque no cenário médico para o diagnóstico automático de doenças, com ênfase na detecção de doenças na área oftalmológica. Glaucoma é a segunda principal causa de cegueira no mundo e não possui cura. Atualmente, existem tratamentos para prevenir a perda da visão, contudo a doença deverá ser descoberta nos estágios iniciais. Este estudo apresenta um método de detecção automática de Glaucoma em imagens da retina. A metodologia utilizada nessa pesquisa foi a aquisição das imagens, pré-processamento nas imagens da retina, extração de características de cor e entropia na área alvo e a seleção destas características. Finalmente, foi realizada a classificação das imagens em glaucomatosas ou não. Foram conseguidos resultados da ordem de 93,67% de acerto na classificação das imagens utilizando o classificador *Random Forest*.

Palavras-chave: Glaucoma, Imagens da retina e Seleção de características.

ABSTRACT

Digital image processing is featured in the medical setting for the automatic diagnosis of diseases with emphasis on disease detection in eye care. Glaucoma is the second leading cause of blindness in the world and has no cure. Currently, there are treatments to prevent vision loss, but the disease must be discovered in the early stages. This study presents an automatic detection method of Glaucoma in retinal images. The methodology used in this research was the image acquisition, preprocessing in retinal images, color feature extraction and entropy in the target area and the selection of these characteristics. Finally, the classification of images in glaucomatous or not was conducted. Results were achieved in the order of 93.67% accuracy in classification of images using the Random Forest classifier.

Keywords: Glaucoma, Retinal Images and Features of Selection.

LISTA DE ILUSTRAÇÕES

Figura 1 - Olho humano e suas estruturas	16
Figura 2 - Imagem de fundo de olho normal	18
Figura 3 - Imagem de fundo de olho com Glaucoma Profundo.....	18
Figura 4 - Modelo de cor RGB.....	19
Figura 5 - Modelo RGB em cubo	20
Figura 6 - Componentes HSI da Figura 3. a) Hue, b) Saturation e c) Intensity.....	20
Figura 7 - Fluxograma da metodologia proposta neste trabalho	26
Figura 8 – Imagem do fundo de olho da retina com DO em evidência.....	27
Figura 9 - Exemplo de uma imagem da retina no Modelo de cor RGB a) Componente R b) Componente G e c) Componente B	28
Figura 10 - Exemplo de uma imagem da retina no Modelo de cor HSI a) Componente H b) Componente S e c) Componente I	28
Figura 11 - Exemplo de uma imagem da retina no Modelo de cor L^*u^*v a) Componente L, b) Componente U e c) Componente V.	28

LISTA DE TABELAS

Tabela 1 - Nível de Exatidão de uma Classificação, conforme o valor do Índice kappa	25
Tabela 2 - Características eliminadas	30
Tabela 3 - Características mais significativas	30
Tabela 4 - Resultado da Classificação com todos os atributos extraídos	33
Tabela 5 - Resultado da Classificação somente com os atributos restantes após a seleção	33

LISTA DE ABREVIATURAS E SIGLAS

A	Acurácia
DO	Disco Óptico
FM	<i>F-Measure</i>
FN	Falso Negativo
FP	Falso Positivo
GLCM	<i>Gray-Level Cooccurrence Matrix</i>
HRT	<i>Heidelberg Retina Tomography</i>
HSI	<i>Hue Saturation Intensity</i>
K	Kappa
L*u*v	Luminosidade, cromaticidade u, cromaticidade v
MDD	<i>Minimun Distance Discriminant</i>
MLP	<i>Multi Layer Perceptron</i>
OCT	<i>Optical Coherence Tomography</i>
P	Precisão
PDI	Processamento Digital de Imagens
R	Recall
RBF	<i>Radial Basis Function</i>
RGB	<i>Red Green Blue</i>
SVM	<i>Support Vector Machine</i>
VN	Verdadeiro Negativo
VP	Verdadeiro Positivo

SUMÁRIO

1	INTRODUÇÃO	14
1.1	Objetivo	15
1.2	Organização do Documento	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	Descritor de cor	20
2.5.2	Descritor de textura	22
2.6	Trabalhos Relacionados	22
2.7	Métricas de Avaliação dos Classificadores	23
2.7.1	Precisão	24
2.7.2	<i>Recall</i>	24
2.7.3	Acurácia	24
2.7.4	<i>F-Measure</i>	25
2.7.5	Índice kappa	25
3	METODOLOGIA	27
3.1	Pré-processamento	27
3.2	Extração de Características da Imagem	28
3.3	Seleção de Características	30
3.4	Classificação	31
3.4.1	<i>Multi Layer Perceptron</i>	31
3.4.2	<i>Radial Basis Function</i>	32
3.4.3	<i>Random Forest</i>	32
3.4.4	<i>Support Vector Machine</i>	33
4	RESULTADOS E DISCUSSÕES	34
4.1	Resultados	34
5	CONSIDERAÇÕES FINAIS	36
5.1	Trabalhos Futuros	36

5.2	Publicações Obtidas	36
	REFERÊNCIAS	37

1 INTRODUÇÃO

O processo de globalização contribuiu significativamente para avanços no campo da ciência, principalmente, na área da tecnologia. Os benefícios obtidos da mesma se refletem em benefícios para o ser humano, como por exemplo, nos exames oftalmológicos, em que o processamento digital de imagens tem desempenhado papel relevante na detecção de patologias (FENGSHOU, 2011).

Existem muitas doenças oculares que podem causar cegueira como Catarata, Glaucoma, Retinopatia Diabética, Conjuntivite, entre outras. Glaucoma é uma doença crônica, irreversível e neurodegenerativa (com perda progressiva), em que o nervo que conecta o olho ao cérebro (nervo ótico), é progressivamente danificado o que pode ocasionar a perda da visão nos pacientes (ZHANG *et al.*, 2009). Nos estágios iniciais, o Glaucoma é uma doença assintomática, ou seja, não há sintomas, só quando a doença já está em um grau bastante avançado, é que os sintomas aparecem, por esta razão a descoberta precoce da doença é necessária, pois há tratamentos que evitam a progressão da doença e a perda de visão do paciente.

De acordo com a 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. Um estudo populacional conduzido na região sul do Brasil selecionou aleatoriamente 1636 indivíduos acima de 40 anos, e destes, encontrou-se uma prevalência de Glaucoma em 3,4% dos casos. Ainda de acordo com essa pesquisa, 90% dos glaucomatosos desconheciam seu diagnóstico (SAKATA *et al.*, 2007).

Uma forma de detecção do Glaucoma é através de exames periódicos, sendo que, para realizar estes exames, é necessário um equipamento especializado, como exemplos são a *Optical Coherence Tomography* (OCT) e *Heidelberg Retina Tomography* (HRT). Outra importante técnica de detecção do Glaucoma é através da análise de imagens do fundo de olho, onde neste método, o especialista na área do Glaucoma terá que identificar através das imagens digitais de fundo de olho, o acúmulo do líquido ao redor do Disco Óptico (DO) e informar se aquela imagem da retina possui ou não Glaucoma (LIU *et al.*, 2011).

1.1 Objetivo

O objetivo principal deste trabalho é apresentar o método desenvolvido para a detecção automática do glaucoma em imagens da retina. Este tem como propósito auxiliar o profissional da área, mostrando uma segunda opinião, em relação ao diagnóstico do glaucoma.

1.2 Organização do Documento

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

- Capítulo 2 – Estado da Arte: Fornece o embasamento teórico para o trabalho. São mostrados conceitos relacionados ao olho humano, Glaucoma, processamento digital de imagens, descritores, métricas de avaliação dos classificadores, trabalhos relacionados e a base de imagens utilizada.
- Capítulo 3 – Metodologia: Será mostrado os passos seguidos para a detecção do Glaucoma em imagens digitais.
- Capítulo 4 – Resultados e Discussões: São mostradas as métricas para avaliação do método desenvolvido, juntamente com os resultados deste método.
- Capítulo 5 – Considerações finais: Apresenta-se as considerações finais, indicações de trabalhos futuros e publicações obtidas.

2 ESTADO DA ARTE

Neste capítulo serão mostradas as principais fontes de pesquisas e bases de estudos, que reunidas possibilitaram o desenvolvimento do projeto.

2.1 Olho humano

O olho humano é um sistema sensorial complexo que desempenha funções de formação e processamento de imagem em conexão com o cérebro. Ele capta a energia luminosa refletida pelos objetos e a transforma em impulsos nervosos transmitidos ao cérebro, que serão convertidos na imagem do objeto observado (PASSOS; ANDRADE-NETO; LEMAIRE, 2008).

A retina é uma parte do olho humano responsável pela formação de imagens. A retina é como uma tela, onde as imagens se projetam, ela arquiva as imagens e traduz para o cérebro através de impulsos elétricos enviados pelo nervo óptico (RAMOS, 2006).

O DO (Disco óptico) da retina diz respeito à porção do nervo óptico vista no fundo dos olhos, formado pelo encontro de todos os axônios das células ganglionares da retina, assim que penetram no disco óptico. Em outras palavras, o DO é o fundo do olho, que pode ser enxergado pelo oftalmologista com o auxílio de um oftalmoscópio (aparelho oftalmológico para enxergar patologias nos olhos não vistas a olho nu) (PASSOS; ANDRADE-NETO; LEMAIRE, 2008). O indivíduo com glaucoma após a pressão intra-ocular aumentar significativamente, pode causar danos irreversíveis ao disco óptico que atrofia de modo progressivo o campo visual, podendo causar a cegueira. Lembrando que, se houver um tratamento adequado de glaucoma este risco é menor.

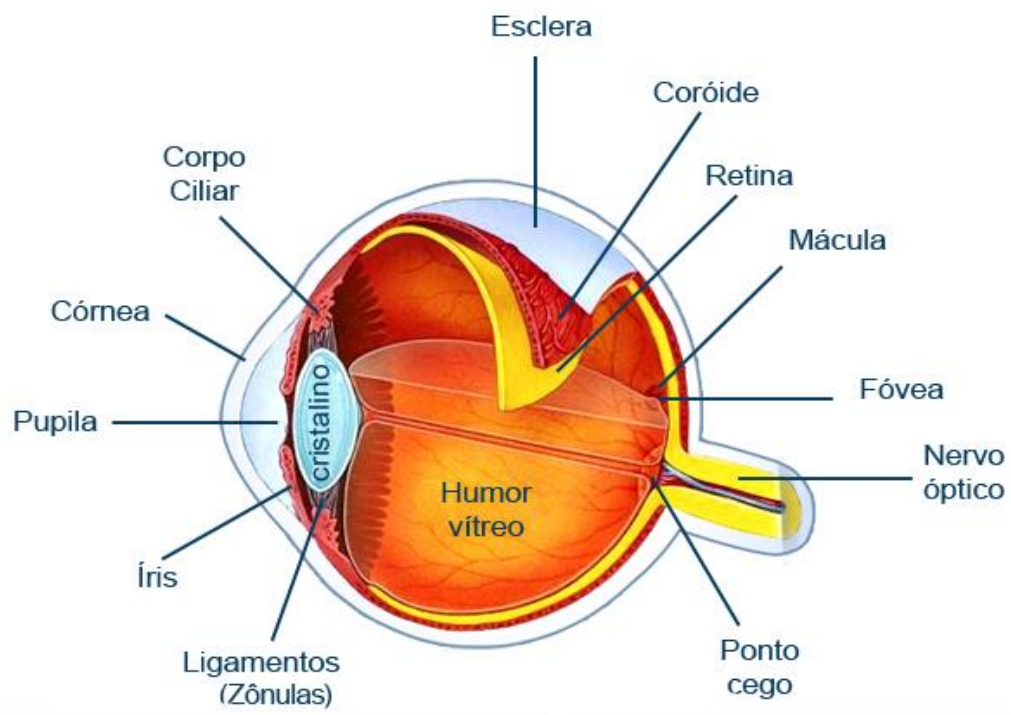


Figura 1 – Olho humano e suas estruturas.

Fonte: www.optivista.com.br

2.2 Glaucoma

Glaucoma é uma doença ocular que 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. O Glaucoma, em sua fase inicial é assintomático, na maioria dos casos a doença progride lentamente sem que o paciente se dê conta de que está perdendo gradualmente a visão (DANNY, 2011).

Os principais sinais de alerta é a dificuldade para focar objetos, visão embaçada, dificuldade para enxergar no escuro, diminuição da visão periférica, desconforto ou dor nos olhos, entre outros. A perda da visão provocada pelo Glaucoma é perfeitamente evitável, desde que o diagnóstico e o tratamento sejam feitos pelo oftalmologista no início do aparecimento da doença (LAMANI *et al.*, 2014).

2.3 Processamento Digital de Imagens

Uma imagem pode ser definida como sendo a representação visual de um objeto. Do ponto de vista matemático, uma imagem 2D é considerada uma função

bidimensional $f(x,y)$ onde x e y são coordenadas planas, e a amplitude de f em qualquer par de coordenadas (x,y) é chamada de intensidade ou nível de cinza da imagem no referido ponto. Quando (x,y) e a amplitude de f fazem parte de um conjunto de valores finitos, ou discretos, a imagem é chamada de imagem digital (GONZALES; WOODS, 2002).

Em outras palavras, uma imagem digital pode ser representada através de uma matriz $n \times m$, onde cada elemento da matriz corresponde à intensidade ou nível de cinza $f(x,y)$ em um determinado ponto da imagem. Estes elementos de imagens digitais são os pixels, que na prática possuem uma intensidade que representa uma cor em um determinado ponto da imagem. Para imagens binárias (em preto e branco) os valores dos pixels podem assumir os valores 0 e 1. Para imagens em tons de cinza estes valores podem variar de 0 a 255 e, finalmente, para imagens coloridas, tem-se que o valor do pixel é representado por três valores variando de 0 a 255 cada um (OSHIRO; GOLDSCHMIDT, 2008).

As imagens são produzidas por diversos dispositivos físicos, tais como câmeras, microscópicos eletrônicos e magnéticos, radares, entre outros vários. A criação e utilização de imagens podem ter diversas finalidades, que vão do entretenimento até em aplicações médicas e tecnológicas. O objetivo da análise de imagens, seja por um observador humano ou por uma máquina, é extrair informações úteis e relevantes para cada aplicação desejada.

Processamento Digital de Imagens (PDI) entende-se a manipulação de uma imagem por computador de modo que a entrada e a saída do processo sejam imagens. O objetivo de se usar processamento digital de imagens é melhorar o aspecto visual de certas feições estruturais para o analista humano e fornecer outros subsídios para a sua interpretação, inclusive gerando produtos que possam ser posteriormente submetidos a outros processamentos (GONZALES; WOODS, 2002).

2.4 Base de Imagens

As imagens digitais do fundo de olho da retina foram adquiridas a partir da base de imagens RIM-ONE (TRUCCO *et al.*, 2013), que possui 169 imagens fornecidos por diferentes especialistas. Esta base possui diversas imagens de olhos saudáveis e com diferentes níveis de Glaucoma, juntamente com as respectivas segmentações do DO,

que foi fornecido por três hospitais: *Hospital Universitario de Canarias*, *Hospital Clínico San Carlos* e *Hospital Universitario Miguel Servet*.

As Figuras 2 e 3 apresentam duas imagens desta base. A Figura 2 é um exemplo de fundo de olho normal e a Figura 3 é um exemplo de uma imagem com Glaucoma profundo. O diagnóstico do especialista é realizado baseado na maior ou menor variação de cor no interior da região do DO. Nas imagens com Glaucoma o DO possui uma coloração mais homogênea, ou seja, uma menor variação de cor, enquanto que em imagens saudáveis o DO possui uma maior variação ou diversidade de cor.




Figura 2 – Imagem de fundo de olho normal.

Fonte: RIM-ONE



Figura 3 – Imagem de fundo de olho com Glaucoma Profundo

Fonte: RIM-ONE

2.5 Descritores

Objetos em imagens possuem forma, cores e texturas. Estas propriedades podem ser mensuradas e são denominadas características da imagem. Estas

características são normalmente agrupadas em um vetor de características, denominado *descritor de imagem* (SILVA, 2014).

2.5.1 Descritor de cor

Nas imagens digitais coloridas, cada pixel é descrito por meio de um conjunto de propriedades como por exemplo matiz, saturação e brilho. Assim, a cor de cada pixel é representada por um ponto no espaço definido pelo modelo de cor. Um modelo de cor é um sistema de coordenadas 3D onde cada cor é representada por um ponto nesse espaço tridimensional (GONZALES; WOODS, 2000). Existem diversos modelos de cores, a seguir é explicado o modelo RGB (*Red, Green, Blue*), HSI (*Hue, Saturation, Intensity*) e L^*u^*v (*Lightness, Chromaticity u, Chromaticity v*).

O modelo RGB é um modelo aditivo no qual as características físicas do dispositivo de exibição são mapeadas diretamente. Para representar uma cor nesse sistema, atribui-se um valor entre 0 e 255 para cada um dos componentes vermelho, verde e azul que o formam. A combinação dos valores RGB em quantidades iguais levam ao branco e, portanto, quanto mais alto são os valores RGB, mais clara será a cor resultante. Quando duas ou três cores primárias são sobrepostas, uma cor secundária é formada, como mostra na Figura 4 (SANTOS, 2012). Por exemplo, quando as cores vermelho e verde se sobrepõem a cor resultante é o amarelo.



Figura 4 – Modelo de cor RGB.

Fonte: www.paletacolores.com

O modelo HSI é frequentemente utilizado na área de processamento digital de imagens, ele separa a componente intensidade (I) da informação de tonalidade e saturação (H+S). A saturação (S) pode ser interpretada com a pureza da cor (distância para a cor pura) e a tonalidade (H) pode ser interpretada com a distância para o vermelho (GONZALES; WOODS, 2000).




Figura 5 – Modelo RGB em cubo.

Fonte:stackoverflow.com




Figura 6 – Componentes HSI da Figura 3. a) Hue, b) Saturation e c) Intensity

Fonte: gec.di.uminho.pt

O modelo de cores L^*u^*v é também conhecido como CIELUV. Ele foi definido na tentativa de aumentar a uniformidade das cores percebidas pelo sistema visual humano, em 1976 pela CIE (Internacional Commission on Illumination – Comissão Internacional de Iluminação) (FRASER; MURPHY; BUNTING, 2005). A componente L define o valor de luminosidade corrigida para uma escala perceptualmente linear. Já as componentes u e v indicam a cromaticidade da cor.

2.5.2 Descritor de textura

Textura é uma propriedade muito importante para a caracterização e reconhecimento de imagens. Ela constitui uma característica diretamente relacionada com propriedades físicas que a superfície de um objeto representa (rugosa, lisa, macia, áspera ou ondulada), além de descrever o padrão de variação de tons de cinza ou cor em uma determinada região (SANTOS, 2009).

Uma textura se caracteriza pela repetição de um modelo sobre uma região, sendo este modelo repetido em sua forma exata ou com pequenas variações. Através de sua análise é possível distinguir regiões que apresentem as mesmas características de refletância e, portanto, mesmas cores em determinada combinação de bandas. Isso torna a textura um excelente descritor regional, contribuindo para uma melhor precisão dos processos de reconhecimento, descrição e classificação de imagens (HARALICK; SHANMUGAM; DINSTEN, 1973).

Diferentemente de cor, a textura é uma propriedade difícil de se analisar considerando apenas o valor de um único pixel. Ela ocorre principalmente devido à variação de brilho entre pixels vizinhos. Dessa maneira, é possível nomear atributos para texturas. Ela possui atributos de contraste, direcionalidade, rugosidade, homogeneidade, correlação entre pixels, entre outros (HARALICK; SHANMUGAM; DINSTEN, 1973).

2.6 Trabalhos Relacionados

A seguir são apresentados alguns trabalhos que tratam da extração de características e da classificação de imagens médicas.

Uma estratégia similar à proposta neste artigo foi utilizada por Araújo *et al.* (2013) para detecção de imagens da retina com Retinopatia Diabética. O primeiro passo realizado nesse trabalho foi a segmentação das regiões de interesse, que eram os exsudatos. Após a identificação dessas regiões, foram extraídas as características de cor e forma. O classificador que apresentou um melhor resultado na detecção de Retinopatia Diabética foi o *Multilayer Perceptron* (MLP). Nesse trabalho foram encontrados resultados da ordem de 88,89% de acerto.

A partir das imagens digitais de fundo de olho, Danny (2011) desenvolveu um novo método para detecção automática do Glaucoma. Para isso foram utilizadas

técnicas de pré-processamento e extração de características de textura baseadas na matriz GLCM (*Gray-Level Cooccurrence Matrix*). Os resultados obtidos indicaram que os recursos aplicados foram clinicamente significativos no diagnóstico do Glaucoma, onde o sistema proposto identificou a presença do Glaucoma com precisão de 81%.

No trabalho de Lamani *et al.* (2014) os autores descrevem um método para classificar a camada de fibras nervosas da retina como propensa a glaucomatosa ou não glaucomatosa. Para resolver o problema os autores utilizam descritor de textura e dimensão fractal, seguidos de uma classificação. A cor nas imagens de fundo de olho é utilizada para uma melhor análise da região da camada de fibras. O canal *Red* foi utilizado na imagem para posterior extração de características de textura e dimensão fractal. O classificador utilizado foi *Support Vector Machine* (SVM), onde verificou-se que após a utilização deste método, em que ocorreu 40% de perda da camada de fibras nervosas da retina, poderá ser realizado a detecção automática do Glaucoma.

Wang *et al.* (2000) apresenta um método para detectar a presença de exsudatos ou lesões, nas imagens da retina. É criada uma abordagem que combina o ajuste de brilho com o método de classificação estatística. Os recursos de cores são extraídos e em seguida utiliza-se o *Minimum Distance Discriminant* (MDD), que é um classificador baseado em técnicas de reconhecimento de padrões estatísticos, para identificar lesões ou exsudatos na retina. Assim, os resultados são capazes de atingir 100% de precisão em termos de identificação das imagens da retina com lesões e uma precisão de 70% para classificar corretamente as imagens sem lesões (normal).

2.7 Métricas de Avaliação dos Classificadores

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).

A partir dessas quantidades algumas taxas estatísticas podem ser calculadas para avaliar o desempenho dos classificadores. As taxas de Precisão (P), *Recall* (R), Acurácia (A) e *F-Measure* (FM). A seguir será realizado uma discussão sobre os critérios citados.

2.7.1 Precisão

A precisão reflete a proporção de verdadeiros positivos em relação a todas as predições positivas e seu cálculo é expresso pela Equação 1, ou seja, precisão corresponde a porcentagem de amostras positivas classificadas corretamente sobre o total de amostras classificadas como positivas.

$$P = \frac{VP}{VP+FP} \quad (1)$$

2.7.2 Recall

O *Recall* reflete a proporção de verdadeiros positivos em relação a suas predições positivas e as suas incorretas predições negativas e seu cálculo é expresso pela Equação 2.

$$R = \frac{VP}{VP+FN} \quad (2)$$

2.7.3 Acurácia

A acurácia de um classificador é a porcentagem de casos corretamente classificados em um conjunto de teste. Essa medida mede o quão bem um classificador reconhece instâncias de diversas classes. Seu cálculo é expresso pela Equação 3.

$$A = \frac{VP+VN}{VP+FP+FN+VN} \quad (3)$$

2.7.4 *F-Measure*

O *F-Measure* reflete a proporção de verdadeiros positivos em relação as predições positivas e todas as suas predições negativas. Vale destacar que esta medida só produz bons resultados quando as taxas de precisão e recall são equilibradas, assim essa é uma medida bastante significativa (CHIMIESKI; FAGUNDES, 2013). Seu cálculo é expresso pela Equação 4.

$$FM = \frac{2*VP}{2*VP+FN+FP} \quad (4)$$

2.7.5 Índice kappa

Outra medida utilizada foi o índice Kappa, que 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 índice Kappa é um coeficiente de concordância para escalas nominais que mede o relacionamento entre a concordância e casualidade, além da discordância esperada (ROSENFELD; FITZPATRICK-LINS, 1986). O índice Kappa pode ser encontrado com base na Equação 5.

$$K = \frac{(\text{observado}-\text{esperado})}{1-\text{esperado}} \quad (5)$$

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

Landis e Koch (1977) classificaram o nível de exatidão do resultado de uma classificação pela relação com o índice kappa obtido. Essa relação pode ser vista na Tabela 1.

Tabela 1 – Nível de Exatidão de uma Classificação, conforme o valor do Índice kappa.

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

3 METODOLOGIA

O método proposto neste trabalho tem como finalidade detectar o Glaucoma a partir de imagens digitais da retina, usando extração de características e classificação. Foram seguidas 4 fases, ilustradas no fluxograma da Figura 7. As imagens utilizadas foram obtidas a partir da base RIM-ONE (TRUCCO *et al.*, 2013). Inicialmente foi realizado o pré-processamento das imagens. O passo seguinte foi a extração da entropia e das características de cor das imagens. Em seguida foram selecionadas as principais características que representavam as imagens. Por fim, as características selecionadas foram utilizadas para classificação das imagens em glaucomatosas ou não.




Figura 7 – Fluxograma da metodologia proposta neste trabalho.

3.1 Pré-processamento

A detecção automática do Glaucoma necessita que a região do DO tenha sido previamente identificada. Vários algoritmos de detecção da região do DO foram propostos, contudo nenhum é livre de erros. Como o objetivo do trabalho é identificar imagens de DO com Glaucoma utilizamos uma máscara, fornecida pela própria base de imagens, para a remoção dos pixels que não eram pertencentes ao DO. Esse pré-processamento foi realizado para evitar que os pixels externos ao DO influenciassem na extração das características de cor e de entropia da imagem. Pode ser observada no círculo branco da Figura 8, o Disco Óptico em evidência.




Figura 8 – Imagem do fundo de olho da retina com DO em evidência.

3.2 Extração de Características da Imagem

A extração de atributos tem por finalidade descrever as imagens em função das características extraídas. Tais características são utilizadas para o reconhecimento de algum padrão. Dependendo do propósito do problema, a extração de atributos pode retornar diferentes características para uma mesma imagem (SILVA *et al.*, 2013).

A cor desempenha um papel importante na forma como percebemos e analisamos as coisas ao nosso redor. Com base neste aspecto, uma série de modelos de cores foram estabelecidos para medir quantitativamente as cores. Medição de cor quantitativa é um dos componentes chave em ciência da cor, análise de cenas, detecção e rastreamento. Neste contexto e baseados em alguns trabalhos encontrados na literatura, neste trabalho decidimos extrair a entropia e as características de cores das imagens.

Cada imagem da retina foi convertida para os modelos de cor RGB, HSI e L^*u^*v , conforme podemos perceber nos exemplos abaixo em que as Figuras 9, 10 e 11 se referem a conversão da Figura 5 nestes modelos de cores, respectivamente. Após a conversão foi possível calcular a média, o desvio padrão e a entropia entre todos os pixels das imagens em cada uma dessas bandas.




Figura 9 – Exemplo de uma imagem da retina no Modelo de cor RGB a) Componente R b) Componente G e c) Componente B.




Figura 10 – Exemplo de uma imagem da retina no Modelo de cor HSI a) Componente H, b) Componente S e c) Componente I.




Figura 11 – Exemplo de uma imagem da retina no Modelo de cor L^*u^*v a) Componente L, b) Componente U e c) Componente V.

Média: Calculada pelo somatório dos valores de níveis de cinza, X , de todos os n pixels na região do disco óptico da imagem, divididos pelo número total de pixels. Esse cálculo é mostrado na Equação 6.

$$Média = \frac{1}{n} \sum_{i=1}^n X_i \quad (6)$$

Desvio Padrão: É a raiz quadrada da variância e indica a homogeneidade, ou heterogeneidade, de uma imagem digital, mostrada na Equação 7.

$$Desvio\ Padrão = (\sum_{i=1}^n (X_i - Média)^2)^{1/2} \quad (7)$$

Entropia: É uma medida estatística que pode ser utilizada para caracterizar a textura da imagem de entrada, mostrada na Equação 8.

$$Entropia = \sum_{i=1}^m (p_i \log_2 1/p_i) \quad (8)$$

Onde m é o número total de tons diferentes presentes na imagem e p_i é a probabilidade do i -ésimo tom ser utilizado novamente.

No final da extração serão gerados 27 valores, onde no vetor gerado conterà a média, o desvio padrão e a entropia de cada uma das bandas dos modelos utilizados.

3.3 Seleção de Características

Após ser gerado o vetor de características, obtido na etapa anterior, realizou-se uma seleção de atributos. Esta seleção tem como objetivo eliminar atributos desnecessários e consequentemente simplificar o modelo de predição, melhorar a performance dos algoritmos, reduzir o custo computacional destes modelos, além de, fornecer um melhor entendimento sobre os resultados encontrados.

O algoritmo utilizado para seleção de atributos foi a razão de ganho, que é uma métrica de ganho de informação. Este algoritmo é um tipo de filtro, que tende a superestimar a qualidade de atributos com muitos valores (QUINLAN, 1986). Neste contexto e realizando testes para melhorar os resultados obtidos, os atributos que obtiveram ganho 0 ou menor que o limiar de 0,17 foram eliminados. A Tabela 2 mostra as características eliminadas e a Tabela 3 demonstra as características mais significativas.

Tabela 2 – Características eliminadas

	R	G	B	H	S	I	L	U	V
Média		X	X						X
Desvio Padrão			X	X	X				X
Entropia							X		

Tabela 3 – Características mais significativas

	R	G	B	H	S	I	L	U	V
Média							X	X	
Desvio Padrão		X							
Entropia					X	X			

3.4 Classificação

Após a extração das características não é possível prever se uma imagem possui ou não Glaucoma, por isso fez-se necessário a etapa de classificação, onde as características extraídas na etapa anterior formaram um vetor, que servirá de entrada para os classificadores. Nesta etapa foram utilizados os classificadores *Multi Layer Perceptron* (MLP) (HAYKIN, 2001), *Radial Basis Function* (RBF) (HAYKIN, 2001), *Random Forest* (BREIMAN, 2001), e *Support Vector Machine* (SVM) (CORTES; VAPNIK, 1995).

3.4.1 *Multi Layer Perceptron*

Uma rede *Multi Layer Perceptron* (MLP) é um sistema de neurônios ligados por conexões sinápticas e dividido em neurônios de entrada, que recebem estímulos do meio externo, neurônios internos (ocultos) e neurônios de saída, que se comunicam com o exterior. (HAYKIN, 2001).

O MLP foi concebido para resolver problemas mais complexos, os quais não poderiam ser resolvidos pelo modelo de neurônio básico. Para isto são necessárias mais conexões, os quais só existem em uma rede de Perceptrons dispostos em camadas. Na camada oculta (ou camada intermediária), os neurônios são

denominados escondidos porque eles não têm acesso direto à saída da rede MLP, onde os erros de aproximação são calculados (ARAÚJO, 2014).

3.4.2 *Radial Basis Function*

Em sua forma mais básica, a RBF (*Radial Basis Function*) contém três camadas com papéis totalmente diferentes. A camada de entrada é constituída por nós de fonte (unidades sensoriais) que conectam a rede ao seu ambiente. A segunda camada aplica uma transformação não linear do espaço de entrada para o espaço oculto e a camada de saída é sempre linear (HAYKIN, 2001).

Quando uma RBF é usada para realizar uma tarefa complexa de classificação de padrões, o problema é resolvido basicamente pela transformação do espaço de entrada para um espaço de alta dimensionalidade, de forma não-linear de acordo com o Teorema de Cover (COVER, 1965). De acordo com esse teorema um problema complexo de classificação de padrões que esteja disposto não-linearmente em um espaço de alta dimensão tem uma probabilidade maior de ser linearmente separável do que em um espaço de dimensionalidade baixa.

3.4.3 *Random Forest*

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 (ARAÚJO, 2014).

Em uma *Random Forest*, cada nó é dividido usando o melhor dentre um subconjunto de indicadores escolhidos aleatoriamente naquele nó. Esta estratégia um tanto contraditória acaba por funcionar muito bem em comparação com muitos outros classificadores, além de ser robusto a superajuste nos parâmetros. Além disso, é de fácil utilização, no sentido que ele tem apenas dois parâmetros (o número de variáveis no subconjunto aleatório em cada nó e o número de árvores da floresta) e, normalmente, não é muito sensível aos seus valores (ARAÚJO, 2014).

3.4.4 *Support Vector Machine*

De um modo geral a SVM (*Support Vector Machine*) faz um mapeamento do espaço de entrada para um espaço de dimensionalidade maior. Após isso é calculado um hiperplano de separação ótimo. O hiperplano de separação ótimo é escolhido de modo a maximizar a distância de separação entre as classes (HAYKIN, 2001). Diz-se que duas classes são linearmente separáveis se existe um hiperplano que separe as mesmas.

A SVM é uma técnica de aprendizagem supervisionada, ou seja, possui as fases de treinamento e teste. Na fase de treinamento, atributos e saídas desejadas são dados a fim de projetar os vetores de suporte. Tais vetores de suporte são usados para obter um classificador. Na fase de teste o classificador é utilizado para encontrar uma saída a partir de um vetor de entrada.

4 RESULTADOS E DISCUSSÕES

Neste capítulo serão apresentadas as métricas de avaliação dos classificadores bem como os resultados encontrados no desenvolvimento da metodologia desse trabalho.

4.1 Resultados

Para avaliação dos resultados foram utilizadas as medidas de Precisão, *Recall*, Acurácia, *F-Measure* e Kappa (ROSENFELD; FITZPATRICK-LINS, 1986), visto na Seção 4. Os parâmetros utilizados para classificação foram os padrões de cada classificador no *WEKA (Waikato Environment for Knowledge Analysis)* (WITTEN *et al*, 2011), e o método de validação utilizado foi o *k-fold cross-validation* (com $k = 10$). Para mostrar a importância da seleção de atributos são apresentados dois resultados, o primeiro na Tabela 4, com todos os atributos extraídos e o segundo na Tabela 5, somente com os atributos resultantes após a seleção.

Tabela 4 – Resultado da Classificação com todos os atributos extraídos

Classificadores	<i>Recall</i>	Precisão	Acurácia	<i>F-Measure</i>	Kappa
MLP	89,90	89,70	89,87	89,80	0,72
<i>Random Forest</i>	91,80	91,70	91,77	91,70	0,78
RBF	90,50	90,30	90,50	90,40	0,74
SVM	89,90	89,90	89,87	89,90	0,73

Tabela 5 – Resultado da Classificação somente com os atributos restantes após a seleção.

Classificadores	<i>Recall</i>	Precisão	Acurácia	<i>F-Measure</i>	Kappa
MLP	93,00	93,10	93,04	93,10	0,81
<i>Random Forest</i>	93,70	93,60	93,67	93,60	0,83
RBF	90,50	90,40	90,50	90,50	0,74
SVM	92,40	92,40	92,40	92,40	0,79

Pela análise das Tabelas 4 e 5, percebe-se que a seleção de atributos melhorou os resultados para quase todos os classificadores testados, a única exceção foi a RBF, onde os resultados se mantiveram praticamente constantes. O maior aumento dos resultados após a seleção de atributos foi da MLP, onde a Acurácia obteve uma melhora de mais de 3% e o índice Kappa saltou de 0,72 para 0,81. Ainda pela análise dessas tabelas percebe-se que a *Random Forest* foi o classificador com melhor desempenho nos dois testes, com índice Kappa de 0,78 e 0,83 respectivamente.

Com base na Tabela 1 percebe-se que antes da seleção de atributos todos os classificadores obtiveram desempenho “muito bom”, porém o desempenho da *Random Forest* e da MLP saltaram para “excelente” após a seleção dos atributos. Os resultados apresentados mostram que com os atributos extraídos, a seleção teve papel fundamental no crescimento da eficiência da classificação.

5 CONSIDERAÇÕES FINAIS

O uso de processamento digital de imagens vem se tornando cada vez mais decisivo em diversas ciências, principalmente na área médica. Muitas áreas da medicina já utilizam este novo recurso como uma forma de auxílio ao médico, pois além de garantir resultados rápidos, eles possuem confiabilidade e redução de custos quando comparados com os exames padrões.

Este trabalho apresentou uma forma de detecção automática do Glaucoma pela extração dos atributos de cor e de entropia e o uso de classificação nas imagens da retina. Os melhores resultados foram obtidos pela *Random Forest*, com 93,67% de Acurácia e Kappa de 0,83.

5.1 Trabalhos Futuros

Apesar dos resultados apresentados serem classificados como excelente baseados no índice Kappa, pretende-se ampliar esse estudo extraíndo, além das características de cor e textura, as informações sobre a forma.

5.2 Publicações Obtidas

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

CLARO, M. L.; SILVA, W. L.; SANTOS, L. M.; ARAÚJO, F. H. D.; SILVA, R. R. V.; SANTANA, A. M. **Detecção Automática do Glaucoma por Extração de Características e classificação**. XII Simpósio Brasileiro de Automação Inteligente (SBAI), Natal, Rio Grande do Norte – Brasil. 2015a.

CLARO, M. L.; SANTOS, L. M.; SILVA, W. L.; ARAÚJO, F. H. D.; SOUSA, A. D.; SANTANA, A. M. **Automatic Detection of Glaucoma Using Disc Optic Segmentation and Features Extraction**. XLI Conferencia LatinoAmericana de Informatica (CLEI), Arequipa – Peru. 2015b.

CLARO, M. L.; SANTOS, L. M.; SILVA, W. L.; ARAÚJO, F. H. D.; MOURA, N. H.; SANTANA, A. M. **Automatic Glaucoma Detection Based on Disc Optic Segmentation and Textures Feature Extraction**. CLEI Electronic Journal, 2016.

REFERÊNCIAS

- ARAÚJO, F. H. D. **Descoberta de Conhecimento em Base de Dados para o Aprendizado da Regulação Médica/Odontológica em Operadora de Plano de Saúde**. Dissertação Teresina: Universidade Federal do Piauí – UFPI, Brasil. 2014.
- ARAÚJO, F., SILVA, R., MACEDO A., AIRES, K. e VERAS, R. **Automatic Identification of Diabetic Retinopathy in Retinal Images Using Ensemble Learning**. Workshop de Informática Médica, Maceió, Alagoas, Brasil, 2013.
- BREIMAN, L. **Random Forests**. Machine Learning. 45(1):5-32. 2001.
- CHIMIESKI, B. F.; FAGUNDES, R. D. R. **Association and classification data mining algorithms comparison over medical datasets**. Journal of health informatics, v. 5, n. 2, 2013.
- CORTES, C. e VAPNIK, V. **Support-vector networks**. Machine Learning, 20:273–297. 1995.
- COVER, T. M. **Geometrical and statistical properties of systems of linear inequalities with applications in pattern recognition**. IEEE Transactions on Electronics Computers, n. 3, p. 326–334. 1965.
- DANNY, L. Y. T. **Computer Based Diagnosis of Glaucoma Using Principal Component Analysis (PCA): A Comparative Study**. Tese de Doutorado - SIM University, School of Science and Technology. 2011.
- FENGSHOU, Y. **Extraction of Features from Fundus Images for Glaucoma Assessment**. Tese de Doutorado - National University of Singapore, Department of Electrical & Computer Engineering, 2011.
- FRASER, B.; MURPHY, C.; BUNTING, F. **Real World Color Management**. 2º ed. Pearson Education. Estados Unidos, 2005.
- GONZALES, R. C.; WOODS, R. **Processamento de Imagens Digitais**, tradução do original Digital Image Processing. Edgard Blucher, 2000.
- GONZALES, R.C.; WOODS, R.E. **Digital Image Processing**. Nova Jersey: Prentice Hall, 2002. 793 p.
- HARALICK, R.; SHANMUGAM, K.; DINSTEN, I. **Textural features for image classification**. IEEE Transactions on Systems, Man and Cybernetics. v. 3, n. 6, p. 610-621, 1973.
- HAYKIN, S. **Neural Networks: A Comprehensive Foundation**. Prentice Hall, 2 edition. 2001.
- LAMANI, D.; MANJUNATH, T. C.; MAHESH, M. e NIJAGUNARYA, Y. S. **Early detection of Glaucoma through retinal nerve fiber layer analysis using fractal**

dimension and texture feature. International Journal of Research in Engineering and Technology. 2014.

LANDIS, J. e KOCH, G. **The measurement of observer agreement for categorical data.** Biometrics, 33(1):159–174. 1977.

LIU, J.; YIN, F. S.; WONG, D.W.K.; ZHANG, Z.; TAN, N.M.; CHEUNG, C. Y.; BASKARAN, M.; AUNG, T. e WONG, T.Y. **Automatic Glaucoma Diagnosis from Fundus Image.** 33rd Annual International Conference of the IEEE EMBS Boston, Massachusetts USA, 2011.

OSHIRO S. H.; GOLDSCHMIDT R. R. **Processamento de Imagens.** Monografias em Sistemas de Computação, No. 05/2008, ISSN: 1982-9035. Rio de Janeiro – Brasil. Setembro, 2008.

PASSOS, E. C.; ANDRADE-NETO, A. V.; LEMAIRE, T. **Comportamento Ótico do Olho e suas Ametropias.** Caderno de Física da Universidade Estadual de Feira de Santana 06, (01 e 02): 7-18, Bahia – Brasil, 2008.

QUINLAN, J. R. **Induction of decision tree.** Machine Learning, pgs. 81 – 106. 1986.

RAMOS, A. **Fisiologia da Visão:** Um estudo sobre o “ver” e o “enxergar”. Pontifícia Universidade Católica do Rio de Janeiro - PUC-Rio. 2006.

ROSENFELD, G. H. e FITZPATRICK-LINS, K. A. **A coefficient of agreement as a measure of thematic classification accuracy.** Photogrammetric Engineering and Remote Sensing, 52:223–227. 1986.

SAKATA, K.; SAKATA, L. M.; SAKATA, V. M.; SANTINI, C.; HOPKET, L. M. E BERNARDES, R. **Prevalence of glaucoma in a south brazilian population: Projeto Glaucoma.** Invest Ophthalmol Vis Sci. 47(11):4974-9. 2007.

SANTOS, A. P. O. **Desenvolvimento de descritores de Imagens para Reconhecimento de Padrões de Plantas Invasoras** (Folhas Largas e Folhas Estreitas). Dissertação São Carlos: Universidade Federal de São Carlos – UFSCar, Brasil. 2009.

SANTOS, D. F. D. **Recuperação em Imagens: Similaridade parcial baseada em espectro de grafo e cor.** Dissertação Uberlândia: Universidade Federal de Uberlândia, Brasil. 2012.

SILVA, R.; AIRES, K.; SANTOS, T.; ABDALLA, K.; VERAS, R. **Segmentação, classificação e detecção de motociclistas sem capacete.** XI Simpósio Brasileiro de Automação Inteligente (SBAI), Fortaleza, Ceará – Brasil. 2013.

SILVA, R.V. S. **Detecção de Uso de Capacete por Motociclistas em Vias Públicas.** Dissertação Teresina: Universidade Federal do Piauí – UFPI, Brasil. 2014.

TRUCCO, E.; RUGGERI, A.; KARNOWSKI, T.; GIANCARDIO, L.; CHAUM, E.; HUBSCHMAN, J. P.; AL-DIRI, B.; CHEUNG, C. Y.; WONG, D.; ABRÀMOFF, M.; LIM, G.; KUMAR, D.; BURLINA, P.; BRESSLER, N. M.; JELINEK, H. F.; MERIAUDEAU, F.; QUELLEC, G.; MACGILLIVRAY, T. e DHILLON, B. **Validating Retinal Fundus Image Analysis Algorithms: Issues And A Proposal**. Invest. Ophthalmol. Vis. Sci., vol. 54, no. 5, pp. 3546–3559. Disponível em: <http://www.ncbi.nlm.nih.gov/pubmed/23794433>. 2013.

WANG, H., HSU, W., GOH, K. G. e LEE, M. L. **An effective approach to detect lesions in color retinal image**. IEEE Conf. On Computer Vision and Pattern recognition, 2000.

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

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

ZHANG, Z.; LIU, J.; WONG, W. K.; TAN, N. M.; LIM, J. H.; LU, S. e LI, H. **Neuro-Retinal Optic Cup Detection in Glaucoma Diagnosis**. IEEE Proceedings of the 2nd International Conference on Biomedical Engineering and Informatics, 2009.



TERMO DE AUTORIZAÇÃO PARA PUBLICAÇÃO DIGITAL NA BIBLIOTECA
"JOSÉ ALBANO DE MACEDO"

Identificação do Tipo de Documento

- Tese
- Dissertação
- Monografia
- Artigo

Eu, **Maíla de Lima Claro**, 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 **Classificação automática do glaucoma usando descritores de textura, cor e múltiplos classificadores** 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 15 de fevereiro de 2016.

Maíla de Lima Claro

Assinatura