

# Automatic Detection of Glaucoma Using Disc Optic Segmentation and Feature Extraction

Maíla Claro, Leonardo Santos, Wallinson Silva, Flávio Araújo, Alcilene Dalília e André Santana

**Abstract**—Digital image processing is highlighted in the medical setting for automatic diagnosis of diseases. Glaucoma has no cure, and is the second leading cause of blindness worldwide. Currently there are treatments to prevent vision loss, but the disease will be discovered still in the early stages. Thus, this study aims to develop an automatic detection method of Glaucoma in retinal images. The methodology used in the study was: image acquisition, segmentation of the optic disc area (DO) in retinal images, color feature extraction and entropy in the targeted area and shortly after the selection of attributes. Finally, classification of images was conducted for identifying glaucoma.

**Index Terms**—Classification, Feature Extraction, Retinal Images, Segmentation.

## I. 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 [1].

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 [2]. Nos estágios iniciais, o Glaucoma é uma doença assintomática, 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) [3], 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 [4].

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 forma de detecção, e mais barata em relação aos exames convencionais, é através da análise de imagens

digitais 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 [5].

O objetivo deste trabalho é criar um método de detecção automática do Glaucoma pela análise de imagens da retina. Para isso, seguimos 5 fases: aquisição de imagens, segmentação da região do DO, para que essa região segmentada possa ser utilizada na detecção automática do Glaucoma, extração de características, a partir da região segmentada, seleção de atributos e classificação. Cada uma dessas fases será detalhada na Seção III.

## II. TRABALHOS RELACIONADOS

No trabalho de Kavitha et al. 2010 [6] foi realizada a segmentação da região do DO e da sua escavação. Nesse trabalho, os autores realizaram a localização da Region of Interest (ROI), ou região de interesse, para que em seguida seja utilizada a morfologia matemática, onde ocorre a suavização das imagens e eliminação de ruídos e vasos sanguíneos. Por fim, utilizou-se o algoritmo de contorno ativo para extração exata da borda. A diferença da segmentação do disco óptico e da escavação está com relação a entrada da imagem. Na detecção do DO foi utilizado o canal vermelho da imagem, e na escavação foi utilização o canal verde. O método foi testado em cerca de 300 imagens, onde destas, em quase todas o CDR (Cup-to-Disc ration) foi calculado corretamente.

Uma estratégia similar à proposta neste artigo foi a detecção de imagens da retina com Retinopatia Diabética realizada em Araújo et al. 2013 [7]. Nesse trabalho, o primeiro passo realizado 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.

No trabalho do autor Danny 2011 [8] desenvolveu-se um novo método de detecção automática do Glaucoma, a partir das imagens digitais de fundo de olho. Para isso foram utilizadas técnicas de pré-processamento e extração de características de textura baseadas na matriz GLCM (Gray-Level Co-Occurrence 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%.

Um método para classificar a camada de fibras nervosas da retina como propensa a glaucomatosa ou não glaucomatosa foi proposto em Lamani et al. 2014 [9]. Para resolver o problema da camada de fibras nervosa, 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 do modelo RGB 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.

### III. METODOLOGIA

O método proposto neste trabalho tem como finalidade segmentar a região do DO das imagens da retina e utilizar a região segmentada, ou região de interesse, para a extração da entropia e das características de cor, para em seguida classificar as imagens como glaucomatosa ou não.

Para a detecção automática do Glaucoma foram seguidas 5 fases, ilustradas no fluxograma da Figura 1. Inicialmente foi realizada a aquisição de imagens. O passo seguinte foi segmentar a região do DO, para que a partir desta região segmentada fosse possível extrair a entropia e características de cor das imagens em diferentes modelos de cores. Em seguida utilizando um algoritmo de seleção de atributos foram selecionadas as características que melhor representavam as imagens. Por fim, as características selecionadas foram utilizadas para classificar a imagem em normal (sem Glaucoma) ou doente (com Glaucoma).

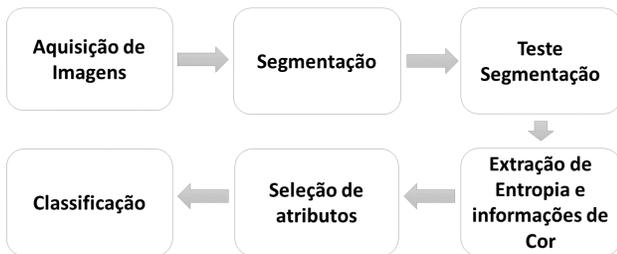


Figure 1. Fluxograma da metodologia proposta neste trabalho.

#### A. Aquisições de Imagens

A etapa de aquisição de imagens é uma das etapas mais significativas na construção de uma metodologia para segmentação de imagens, pois, para verificar a qualidade da segmentação é necessária uma base que forneça uma marcação correta da região que será segmentada.

Nesta etapa foram selecionadas três bases de imagens para segmentar e testar se o método desenvolvido está selecionando a região de interesse, que neste caso é a região do disco óptico. Cada uma destas bases possui imagens com diferentes níveis de Glaucoma e com as suas respectivas marcações do DO, são elas: RIM-ONE [10], DRISTHI-GS [11] e DRIONS-DB [12].

A base RIM-ONE é um banco de imagens que possui 169 imagens fornecidas por diferentes especialistas. Esta base possui diversas imagens de olhos saudáveis e com diferentes níveis de Glaucoma juntamente com as suas respectivas segmentações do DO, que foi fornecida por três hospitais: Hospital Universitário de Canarias, Hospital Clínico San Carlos e Hospital Universitário Miguel Servet, como demonstrado na Figura 2.

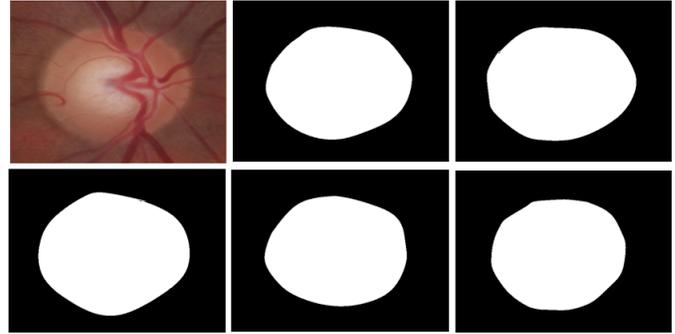


Figure 2. Exemplo de uma imagem da base RIM-ONE e suas respectivas marcações do DO (máscaras).

A base DRISTHI-GS é constituída por 50 imagens com a sua respectiva marcação do DO, feita por um especialista, observado na Figura 3. A base DRIONS-DB contém 110 imagens e suas respectivas marcações do DO realizada por um especialista e pode ser observada na Figura 4.

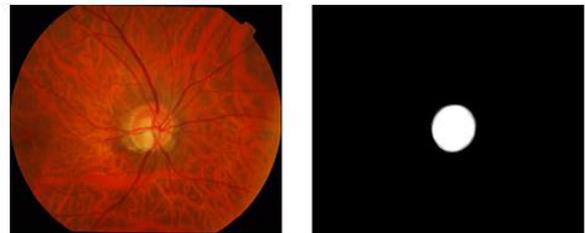


Figure 3. Exemplo de uma imagem da base DRISTHI-GS e a sua marcação do DO (máscara).

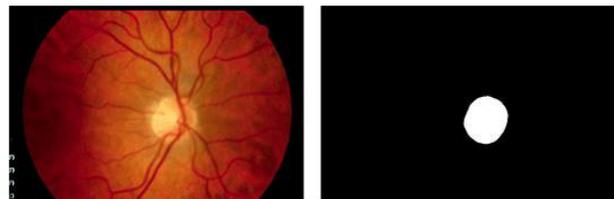


Figure 4. Exemplo de uma imagem da base DRIONS-DB e sua respectiva marcação do DO (máscara).

#### B. Segmentação

As imagens das bases estavam no formato RGB (Red, Green, blue). Como visto no trabalho de Kavitha et al. 2010

[6] o DO é mais facilmente encontrado na camada Red do modelo RGB, portanto as imagens foram convertidas para esta camada.

A obtenção da ROI foi realizada para reduzir a área onde o processamento será feito e consequentemente diminuir o tempo de processamento. A região delimitada refere-se ao retângulo localizado no centro da imagem, calculada mediante a subtração entre o tamanho da imagem e a razão entre o tamanho da imagem e um valor previamente definido, conforme o resultado expresso na Figura 5.

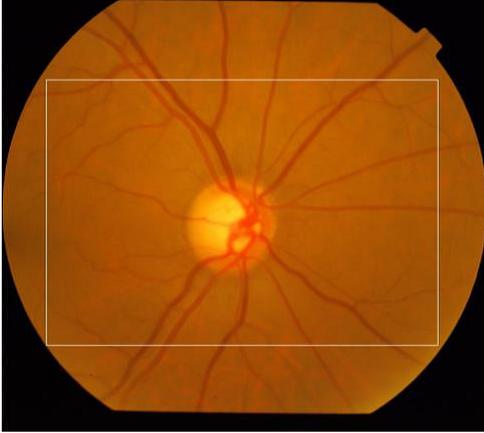


Figure 5. Delimitação da Região de Interesse.

A partir da ROI, foi definido como coordenada do centro do DO o pixel central de uma janela 5x5, que a média de intensidade dos seus pixels fosse a maior da ROI. Após a definição desse pixel, foi realizado o cálculo do raio da circunferência do DO. Vale destacar que, durante o cálculo desse raio o pixel definido anteriormente como o centro do DO será modificado.

Para o cálculo do raio estimado do DO utilizou-se uma técnica baseada em limiar. A obtenção deste limiar foi encontrada de forma automática, a partir do pixel encontrado como o centro do DO. Para isso, foram delineados, em seguida, quatro raios, para cima no ângulo de 90°, para baixo no ângulo de 270°, para direita no ângulo de 0° e esquerda no ângulo de 180°.

Devido as diferentes intensidades dos pixels nas imagens, foi calculado um novo limiar para cada direção, como sendo a média entre o pixel de maior e o de menor intensidade de cor naquela direção. Assim, o raio em cada uma das direções será definido como sendo a distância entre o pixel do centro do DO e o primeiro pixel que seja menor que o valor do limiar.

Após o cálculo do raio em cada uma das quatro direções é realizada a atualização do centro do DO que é calculado conforme a equação a seguir:

$$X_{Centro} = X_{Canterior} + \text{Raio } 0 - \frac{\text{Raio } 0 + \text{Raio } 180}{2}. \quad (1)$$

$$Y_{Centro} = Y_{Canterior} + \text{Raio } 90 - \frac{\text{Raio } 90 + \text{Raio } 270}{2}. \quad (2)$$

Após a definição do raio, partindo do centro do DO até as fronteiras definida pelo limiar, foi retirada a média aritmética para obtenção do valor que será utilizado na etapa seguinte, como apresentado na equação a seguir:

$$\text{Raio}_{DO} = \frac{\text{Raio } 0 + \text{Raio } 90 + \text{Raio } 180 + \text{Raio } 270}{4}. \quad (3)$$

Após realizado o procedimento anterior, obteve-se como resultado as coordenadas do centro do DO e o raio estimado. Em seguida, aplicou-se a equação da circunferência para traçar as bordas do DO, como visto a seguir na Equação 4:

$$(X_{\text{posição}} - X_{\text{centro}})^2 + (Y_{\text{posição}} - Y_{\text{centro}})^2 = (\text{Raio}_{DO})^2. \quad (4)$$

A Figura 6 apresenta exemplos do processo de segmentação. A Figura 6(a) mostra uma imagem da base RIM-ONE juntamente com a região do DO, encontrada pela metodologia e a região segmentada. As Figuras 6(b) e 6(c) são semelhantes a 6(a), porém para as bases DRISHTI-GS e DRIONS-DB, respectivamente.

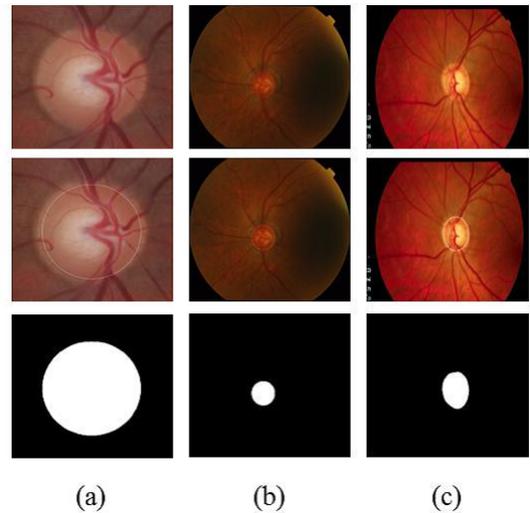


Figure 6. Exemplo da segmentação realizada pela metodologia proposta para a imagem da base a) RIM-ONE, b) DRISHTI-GS e c) DRIONS-DB.

Após todo este processo, a segmentação do DO foi alcançada. Foi gerada uma nova imagem correspondente a cada uma das imagens das bases utilizadas, onde esta nova imagem tem como intuito separar a região de interesse, que é o DO, do restante da imagem, que é o plano de fundo. Com isso, mas adiante será demonstrado o desempenho da segmentação proposta com a das segmentações já existentes na base de imagens.

### C. Extração de Características

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 [13].

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 [8] e [9], este trabalho tem como propósito extrair a entropia e as informações de cores das imagens segmentadas, obtidas na seção anterior.

Cada imagem da retina foi convertida para os modelos de cor RGB (Red, Green e Blue), HSI (Hue, Saturation e Intensity) e  $L*u*v$ . Em seguida, foi calculado a média, o desvio padrão e a entropia dos pixels da região segmentada do DO para cada um desses modelos.

*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 5.

$$Média = \frac{1}{n} \sum_{i=1}^n X_i. \quad (5)$$

*Desvio Padrão:* É a raiz quadrada da variância e indica a homogeneidade, ou heterogeneidade, de uma imagem digital, mostrada na Equação 6.

$$\text{Desvio Padrão} = \left( \sum_{i=1}^n (X_i - Média)^2 \right)^{\frac{1}{2}}. \quad (6)$$

*Entropia:* É uma medida estatística que pode ser utilizada para caracterizar a textura da imagem de entrada, mostrada na equação 7.

$$\text{Entropia} = \sum_{i=1}^n \left( \pi \log_2 \frac{1}{\pi} \right). \quad (7)$$

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

Para cada imagem foi calculada a média, o desvio padrão e a entropia de cada uma dessas bandas, onde, a partir destes valores, foi possível formar um vetor de atributos, que será utilizado pelos classificadores, descritos no tópico de classificação, a fim de determinar a qual classe a imagem pertence (Glaucomatosa ou não). Vale destacar que todas as características foram extraídas levando em consideração somente os pixels contidos na região segmentada pelo algoritmo.

#### D. Seleção de Atributos

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 [14]. Neste contexto, os atributos que obtiveram ganho 0 ou menor que o limiar de 0,1 foram eliminados.

Os atributos eliminados foram:

- Média: As bandas H, B, L, U, R, I;
- Desvio padrão: As bandas R, G, B, V, I, H;
- Entropia: As bandas S, H.

Os atributos mais significativos foram:

- Média: A banda G;
- Desvio padrão: As bandas S, U;
- Entropia: As bandas V, G, B;

#### E. 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 os atributos calculados na etapa anterior formaram um vetor, que servirá de entrada para os classificadores. Nesta etapa foram utilizados os classificadores Multi Layer Perceptron (MLP) [15], Random Tree (RBF) [16], Random Committee [17] e Random Forest [18]. Na Seção V, são mostrados os resultados obtidos para cada um desses classificadores.

### IV. MÉTRICAS DE AVALIAÇÃO DE DESEMPENHO

Nesta seção serão apresentadas as métricas de avaliação da segmentação, bem como as métricas de avaliação dos classificadores.

#### A. Métricas de Avaliação da Segmentação

A avaliação da eficácia obtida foi feita através da comparação entre o resultado obtido do algoritmo de segmentação implementado e o resultado da máscara das bases de imagens utilizadas, sendo essa máscara, uma imagem onde a região do DO está em evidência.

Para avaliar a qualidade da segmentação, foram calculadas duas medidas, chamadas de Eficácia e Precisão. Na Eficácia o valor é obtido pela razão entre a Quantidade de Pixels Segmentados Corretamente (QPSC) e a Quantidade Total de Pixels Segmentados (QTPS), demonstrado na Equação 8.

$$\text{Eficácia} = \frac{QPSC}{QTPS} * 100. \quad (8)$$

Para informar a Precisão, será calculado o módulo da subtração do QPSC com a Quantidade de Pixels da Máscara (QPM), onde o valor encontrado será dividido pela QPM, conforme demonstrado na Equação 9.

$$\text{Precisão} = 100 - \frac{QPSC - QPM}{QPM} * 100. \quad (9)$$

### B. 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 [19].

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 10, 11, 12 e 13.

$$P = \frac{VP}{VP + FP}. \quad (10)$$

$$R = \frac{VP}{VP + FN}. \quad (11)$$

$$A = \frac{VP + VN}{VP + FP + VN + FN}. \quad (12)$$

$$FM = \frac{2 * VP}{2 * VP + FP + FN}. \quad (13)$$

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 [20].

O índice Kappa é um coeficiente de concordância para escalas nominais que mede o relacionamento entre a concordância e casualidade, além da discordância esperada [20]. O índice Kappa pode ser encontrado com base na Equação 14.

$$K = \frac{(\text{observado} - \text{esperado})}{1 - \text{esperado}}. \quad (14)$$

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.

A categorização do nível de exatidão do resultado de uma classificação, pela relação do índice Kappa obtido, pode ser observado na Tabela I, conforme definido por Landis e Koch [21].

Table I  
NÍVEL DE EXATIDÃO DE UMA CLASSIFICAÇÃO, CONFORME O VALOR DO ÍNDICE KAPPA.

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

### V. RESULTADOS

Nesta seção são apresentados os resultados obtidos da segmentação e extração de atributos com base na metodologia proposta.

Para avaliação dos resultados de segmentação as medidas de Eficácia e Precisão, vistos na seção IV, foram utilizadas para o cálculo da acurácia do método. Foram considerados diferentes limiares de exigência, estes limiares variam de 60% a 80%, e se as duas medidas calculadas obtiverem valores maiores que o limiar estabelecido, então consideramos que aquela imagem foi segmentada corretamente. A Tabela II apresenta os resultados de acurácia obtidos para os diferentes níveis de exigência.

Table II  
ACURÁCIA DA SEGMENTAÇÃO DO DISCO ÓPTICO PARA DIFERENTES NÍVEIS DE EXIGÊNCIA.

| Base de Imagem   | N de imagens | Nível de exigência |       |       |
|------------------|--------------|--------------------|-------|-------|
|                  |              | 60%                | 70%   | 80%   |
| RIM-ONE          | 169          | 95.85              | 92.30 | 82.24 |
| DRISHTI-GS       | 50           | 92.00              | 90.00 | 76.00 |
| DRIONS-DB        | 110          | 82.72              | 67.27 | 36.36 |
| Todas as imagens | 329          | 90.57              | 83.58 | 65.95 |

Pela análise da Tabela II, observa-se que na base RIM-ONE, quando a exigência de acerto foi de 80%, a acurácia obtida pela segmentação do algoritmo foi maior que 82%, totalizando 139 imagens segmentadas corretamente de 169. Percebe-se também que quando o limiar de exigência foi menor que 80% a acurácia total obtida pelo algoritmo foi maior que 90%, totalizando mais de 153 imagens segmentadas corretamente.

Na base DRISHTI-GS nota-se que, quando a exigência de acerto foi de 80%, a acurácia obtida pela segmentação do algoritmo foi de 76%, totalizando 38 imagens segmentadas corretamente de 50. Percebe-se também que quando o nível de exigência foi menor que 80%, a eficácia total obtida pelo algoritmo foi igual ou superior a 90%, totalizando mais de 45 imagens segmentadas corretamente.

Ainda pela análise da Tabela II, percebe-se que na base DRIONS-DB, quando a exigência de acerto foi de 80%, a eficácia obtida pela segmentação do algoritmo foi maior que 36%, totalizando 40 imagens segmentadas corretamente de 110. Observa-se também que quando a exigência de acerto foi igual a 70% a eficácia total obtida pelo algoritmo foi quase o dobro do obtido pelo limiar de 80%. Esta base foi a que houve o maior crescimento de acurácia com a diminuição do grau de

exigência, chegando a atingir mais de 80% para a exigência de acerto de 60%.

De acordo com o resultado geral das três bases utilizadas, mostrado na Tabela II, observa-se que quando a exigência de acerto foi menor que 70%, a eficácia total obtida pelo algoritmo foi maior que 83%, totalizando mais de 275 imagens segmentadas corretamente de 329. Os resultados obtidos mostram que a metodologia proposta para segmentação foi eficiente na identificação da região do DO, levando em consideração a diversidade das bases e equipamentos utilizados para aquisição.

A Tabela III apresenta os resultados de Precisão, Recall, Acurácia, F-Measure e Kappa obtidos pela classificação das imagens em Glaucomatosas o não. Para mostrar a importância da seleção de atributos foram apresentados os resultados obtidos com todos os atributos extraídos e, somente, com os atributos resultantes após a seleção. Os parâmetros utilizados para classificação foram os padrões de cada classificador no WEKA (Waikato Environment for Knowledge Analysis) [22], e o método de validação utilizado foi o k-fold cross-validation (com  $k = 10$ ).

Table III  
RESULTADO DA CLASSIFICAÇÃO COM TODOS OS ATRIBUTOS EXTRAÍDOS E COM OS RESTANTES APÓS A SELEÇÃO DE ATRIBUTOS.

| Todos os atributos        |       |       |       |       |      |
|---------------------------|-------|-------|-------|-------|------|
| Classificadores           | R     | P     | A     | FM    | K    |
| MLP                       | 89.20 | 89.20 | 89.24 | 89.20 | 0.71 |
| Random Committe           | 89.20 | 90.00 | 89.24 | 88.30 | 0.67 |
| Random Forest             | 89.20 | 89.60 | 89.24 | 88.50 | 0.68 |
| Random Tree               | 82.20 | 82.50 | 82.91 | 82.70 | 0.53 |
| Após seleção de atributos |       |       |       |       |      |
| Classificadores           | R     | P     | A     | FM    | K    |
| MLP                       | 89.20 | 89.30 | 89.24 | 89.30 | 0.71 |
| Random Committe           | 92.40 | 92.30 | 92.40 | 92.20 | 0.78 |
| Random Forest             | 88.60 | 89.00 | 88.60 | 87.70 | 0.66 |
| Random Tree               | 84.80 | 84.60 | 84.81 | 84.70 | 0.59 |

Pela análise da Tabela III, percebe-se que a seleção de atributos aprimorou os resultados para alguns dos classificadores testados, as exceções foram o Multi Layer Perceptron, onde os resultados se mantiveram praticamente constantes, e a Random Forest, onde os resultados acabaram diminuindo. O maior aumento dos resultados após a seleção de atributos foi da Random Committe, onde a Acurácia obteve uma melhoria de mais de 3% e o índice Kappa saltou de 0,71 para 0,78. Ainda pela análise dessa tabela percebe-se que o Multi Layer Perceptron obteve um melhor resultado antes da seleção de atributos, pois o índice Kappa foi o maior, e a Random Committe foi o classificador com melhor desempenho após a seleção dos atributos.

Pela análise da Tabela I percebe-se que antes e após a seleção de atributos os classificadores obtiveram desempenho “muito bom”, com exceção da Random Tree, que obteve um desempenho “bom”. Os resultados apresentados mostram que com os atributos extraídos, a seleção teve papel relevante no crescimento da eficiência da classificação.

## VI. CONCLUSÃO E TRABALHOS FUTUROS

Processamento digital de imagens vem se tornando uma área de estudo com grande potencial, que, cada vez mais vem contribuindo para a sociedade. Na área da saúde, o processamento digital de imagens está sendo utilizada no auxílio do diagnóstico de doenças, para que ele seja realizado de forma eficaz e barata.

Este trabalho apresentou uma metodologia para detecção automática do DO em imagens digitais de fundo de olho e, a partir desta região foi extraído a entropia e as características de cores em diferentes modelos. Os testes de detecção do DO foram realizados em três bases de imagens distintas. A segmentação trouxe bons resultados, satisfazendo as expectativas, contabilizando uma acurácia superior a 83% quando avaliado com um limiar de exigência de 70%, que é o valor clássico encontrado na literatura.

Após a segmentação, 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. Vale destacar que também foi realizado um processo de seleção de atributos, em que os atributos menos significativos foram eliminados. Os melhores resultados foram obtidos pela Random Committe, com 92,20% de Acurácia e o índice Kappa de 0,78.

Como trabalho futuro serão comparados os resultados encontrados pela metodologia de segmentação proposta nesse trabalho com os resultados obtidos por algoritmos clássicos de detecção do DO propostos na literatura. Outro trabalho futuro será a implementação de um algoritmo de segmentação automática da escavação do DO, com o propósito de calcular o CDR (Cup-to-Disc ration), que é a razão entre a área da escavação e a área do DO. O cálculo do CDR é muito utilizado pelos médicos para o auxílio na detecção do Glaucoma.

Apesar dos resultados apresentados serem classificados como muito bom baseados no índice Kappa, pretendemos ampliar esse estudo extraíndo, além das características de cor, informações sobre forma e textura.

## REFERENCES

- [1] Y. Fengshou, “Extraction of Features from Fundus Images for Glaucoma Assessment”. Dissertação de Mestrado - National University of Singapore, Department of Electrical and Computer Engineering, 2011.
- [2] Z. Zhang, J. LIU, W. K. Wong, N. M. Tan, J. H. Lim, S. Lu e H. Li, “Neuro-Retinal Optic Cup Detection in Glaucoma Diagnosis”. IEEE Proceedings of the 2nd International Conference on Biomedical Engineering and Informatics, 2009.
- [3] WHO. “World health organization (WHO)”. Disponível em: <http://apps.who.int/ghodata/?vid=5200>, 2014, acessado em outubro de 2014.
- [4] K. Sakata et al., “Prevalence of glaucoma in a south brazilian population: Projeto Glaucoma”. Invest Ophthalmol Vis Sci. 47(11):4974-9, 2007.
- [5] J. Liu, F. S. Yin, D. W. K. Wong, Z. Zhang, N. M. Tan, C. Y. Cheung, M. Baskaran, T. Aung e T. Y. Wong, “Automatic Glaucoma Diagnosis from Fundus Image”. 33rd Annual International Conference of the IEEE EMBS Boston, Massachusetts USA, 2011.
- [6] S. Kavitha, S. Karthikeyan, e K. Duraiswamy, “Early Detection of Glaucoma in Retinal Images Using Cup to Disc Ratio”, Second International conference on Computing, Communication and Networking Technologies, 2010.

- [7] F. Araújo, R. Silva, A. Macedo, K. Aires e R. Veras, "Automatic Identification of Diabetic Retinopathy in Retinal Images Using Ensemble Learning". Workshop de Informática Médica, Maceió, Alagoas, Brasil, 2013.
- [8] L. Y. T. Danny "Computer Based Diagnosis of Glaucoma Using Principal Component Analysis (PCA): A Comparative Study". Tese de Doutorado - SIM University, School of Science and Technology, 2011.
- [9] D. Lamani, T. C. Manjunath, M. Mahesh e Y. S. Nijagunarya, "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.
- [10] E. Trucco, A. Ruggeri, T. Karnowski, L. Giancardo, E. Chaum, J.P. Hubschman, B. Al-diri, C. Y. Cheung, D. Wong, M. Abramoff, G. Lim, D. Kumar, P. Burlina, N. M. Bressler, H. F. Jelinek, F. Meriaudeau, G. Quellec, T. Macgillivray e B. Dhillon, "Validating Retinal Fundus Image Analysis Algorithms: Issues And A Proposal". Invest. Ophthalmol. 2013. Vis. Sci., vol. 54, no. 5, pp. 3546–3559. Disponível em: <http://www.ncbi.nlm.nih.gov/pubmed/23794433>.
- [11] Drishti-gs, "Provided by Medical Image Processing (MIP) group, IIIT Hyderabad", 2014 Disponível: <http://cvit.iiit.ac.in/projects/mip/drishti-gs/mip-dataset2>.
- [12] E. J. Carmona, M. Rincón, G. J. Feijoo e J. M. Martínez, "Identification of the optic nerve head with genetic algorithms", Artificial Intelligence in Medicine, 2008, Vol. 43(3), pp. 243-259.
- [13] R. Silva, K. Aires, T. Santos, K. Abdalla, e R. Veras, "Segmentação, classificação e detecção de motociclistas sem capacete". XI Simpósio Brasileiro de Automação Inteligente (SBAI), Fortaleza, Ceará – Brasil, 2013.
- [14] J. R. Quinlan, Induction of decision tree. Machine Learning, 1986, pgs. 81 – 106.
- [15] S. Haykin. Neural Networks: A Comprehensive Foundation. Prentice Hall, 2 edition, 2001.
- [16] D. Aldous. The continuum random tree. Ann. Probab., 21(1):248-289. 1991.
- [17] M. M. S. Lira, R. R. B. Aquino, A. A. Ferreira, M. A. Carvalho, O. N. Neto, e G. S. M. Santos, Combining Multiple Artificial Neural Networks Using Random Committee to Decide upon Electrical Disturbance Classification. In International Joint Conference on Neural Networks, 2007, pages 2863 - 2868.
- [18] L. Breiman Random Forests. Machine Learning, 2001, 45(1):5-32.
- [19] B. F. Chimieski e R. D. R. Fagundes, "Association and classification data mining algorithms comparison over medical datasets". Journal of health informatics, pp. 44-51, 2013.
- [20] G. H. Rosenfield e K. A. Fitzpatrick-Lins, "A coefficient of agreement as a measure of thematic classification accuracy". Photogrammetric Engineering and Remote Sensing, 1986. 52:223–227.
- [21] J. Landis e G. Koch. The measurement of observer agreement for categorical data. Biometrics, 1977. 33(1):159–174.
- [22] I. H. Witten, E. Frank e M. A. Hall, DATA MINING: Practical Machine Learning Tools and Techniques. Morgan Kaufmann, 3 edition, 2011.