

Detecção Automática do Glaucoma pelo uso de Descritores Locais, Matriz GLCM e Aprendizado de Máquina

Wallinson de Lima Silva
Universidade Federal do Piauí - UFPI
Picos, Brasil
iwallinsom@gmail.com

Leonardo de Moura Santos
Universidade Federal do Piauí - UFPI
Picos, Brasil
leonardo.moura.software@gmail.com

Alcilene Dalília de Sousa
Universidade Federal do Piauí - UFPI
Picos, Brasil
alcilene@ufpi.edu.br

Maíla de Lima Claro
Universidade Federal do Piauí - UFPI
Picos, Brasil
claromaila@gmail.com

Flávio Henrique Duarte Araújo
Universidade Federal do Piauí - UFPI
Picos, Brasil
flavio86@ufpi.edu.br

Nayara Holanda de Moura
Universidade Federal do Piauí - UFPI
Picos, Brasil
naayaholanda@hotmail.com

Abstract— Glaucoma is an asymptomatic disease and is considered the second greater cause of blindness in the world, it attacks the optic nerve causing irreversible damage to the visual field. Although there is no cure exists treatment, which can be facilitated from a previous diagnosis. Thus, this work consists of methods for feature extraction in retinal images from the use of descriptors for the automatic detection of glaucoma. These methods are constructed from the use of bag of words, which are robust forms of representation, and the texture descriptors Binary Pattern Place and Grey Level Co-occurrence Matrix (GLCM).

Keywords— Retinal images; classification; features extraction; detecting diseases.

I. INTRODUÇÃO

O glaucoma é uma doença ocasionada pelo aumento da pressão dentro do olho, gerando uma perda progressiva do campo de visão de maneira irreversível [1].

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 assim 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.

De acordo com a Organização Mundial de Saúde (*World Health Organization*) [2], 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) [3], 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 o *Speed Up Robust Features* (SURF) [4], o *Local Binary Pattern* (LBP) [5] e a *Grey Level Co-occurrence Matrix* (GLCM) [6] para extração de características das imagens de fundo de olho e a detecção automática do glaucoma.

II. TRABALHOS RELACIONADOS

Rocha *et al.* (2012) [7], 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%.

O trabalho de Araújo *et al.* (2013) [8], tinha 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 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%.

Simonthomas *et al.* (2014) [9], tinha 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.

Silva *et al.* (2014) [10], 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 classificação foram usados 471 imagens de motociclistas e três classificadores, dentre eles, o que mais se destacou foi *Naive Bayes*, obtendo uma acurácia superior 92%.

Ali *et al.* (2014) [11], tinha como objetivo a 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 LBP. 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 foram utilizadas 13 imagens com glaucoma e 28 não glaucomatosas, sendo que, dessas 28 algumas continham 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.

III. MATÉRIAS E MÉTODOS

Nesta Seção são apresentados os materiais utilizados na metodologia para detecção automática do glaucoma, de modo a esclarecer os recursos utilizados para alcançar o resultado demonstrado a seguir neste trabalho.

A. Base de Imagens

As imagens utilizadas neste trabalho foram retiradas da base RIM-ONE [12]. 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. A base é separada por categorias, ou seja, 118 saudáveis e 40 glaucomatosas, que foi essa característica que à adequou a nosso trabalho, pois outras bases não forneciam essa distinção de imagens. A Figura 1 apresenta duas imagens da base RIM-ONE.




Figura 1. a) retina saudável com a escavação do disco óptico normal, b) retina glaucomatosa, evidenciando uma escavação mais avançada.

B. SURF

O SURF é um descritor local que identifica os pontos de interesse com base na matriz Hessiana. 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. O processamento realizado pelo descritor retornará como saída um vetor de atributos que evidenciará os pontos característicos mais importantes da imagem.

Os algoritmos descritores utilizam-se de critérios para formular padrões, tais como cor, textura, tonalidade, estrutura, dentre outros, que irão contribuir para a extração dos pontos característicos. Contudo 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.

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 conseguem trabalhar bem com representações geradas pelos descritores locais [13]. 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. A única informação considerada é a aparência da região [14]. 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 [8].

C. 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. Suas principais vantagens a não influência das variações de iluminação, baixa complexidade computacional, capacidade de codificar detalhes e permitir realizar análise local das informações [15].

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, foi gerado uma nova matriz 3x3 contendo como pesos valores baseados em potências de 2. Os valores da matriz binária foram multiplicados por os valores da matriz de peso, e após isso foram somados os resultados da

multiplicação, sendo esse resultado armazenado em um histograma de 0 a 255. A Figura 2 mostra o funcionamento do descritor de textura LBP.

D. GLCM

O *Grey Level Co-occurrence Matrix* (GLCM) [6] ou Matriz de Co-ocorrência 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.

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 [16].

Para o cálculo das probabilidades de co-ocorrência entre dois níveis de cinza i e j , dada uma certa distância d e uma orientação Θ (theta), que pode assumir os valores de 0° , 45° , 90° e 135° [17].

Haralick *et al.* (1973) [6], 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, para esse trabalho foram utilizados os cálculos dos seguintes atributos de textura:

Contraste (*Con*)

$$Con = \sum_{i,j=0}^{N_g-1} |i - j|^k (c_{ij})^l,$$

Correlação (*Cor*)

$$Cor = \sum_{i,j=0}^{N_g-1} \frac{ijc_{ij} - \mu_i\mu_j}{\sigma_i\sigma_j},$$

Homogeneidade (*Hom* ou *Mdi*)

$$Mdi = \sum_{i,j=0}^{N_g-1} \frac{c_{ij}}{1 + |i - j|},$$

Energia (*Ene*)

$$Ene = \sum_{i,j=0}^{N_g-1} (c_{ij})^2.$$

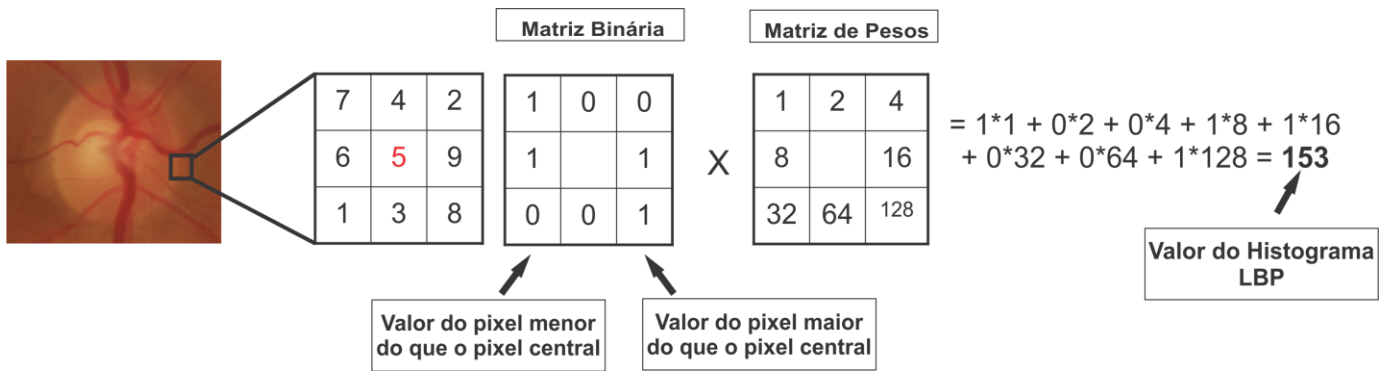


Figura 2. Ilustração do funcionamento do descritor de textura LBP.

IV. MÉTODO PROPOSTO

O fluxograma apresentado na Figura 3 ilustra todos os passos realizados neste trabalho.

Na etapa de Extração de Características com o SURF, as imagens tiveram seus histogramas equalizados e 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.

Na etapa de Criação dos Dicionários Visuais as duas matrizes com os atributos extraídos passaram por um processo de agrupamento. O algoritmo utilizado para agrupamento foi o k-means. Esse algoritmo dividiu a matriz em 128, e logo após selecionou os atributos que melhor representaram cada um

desses clusters. A Figura 4 apresenta de forma ilustrativa os passos seguidos na formação do dicionário visual.

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 Extraídos 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.

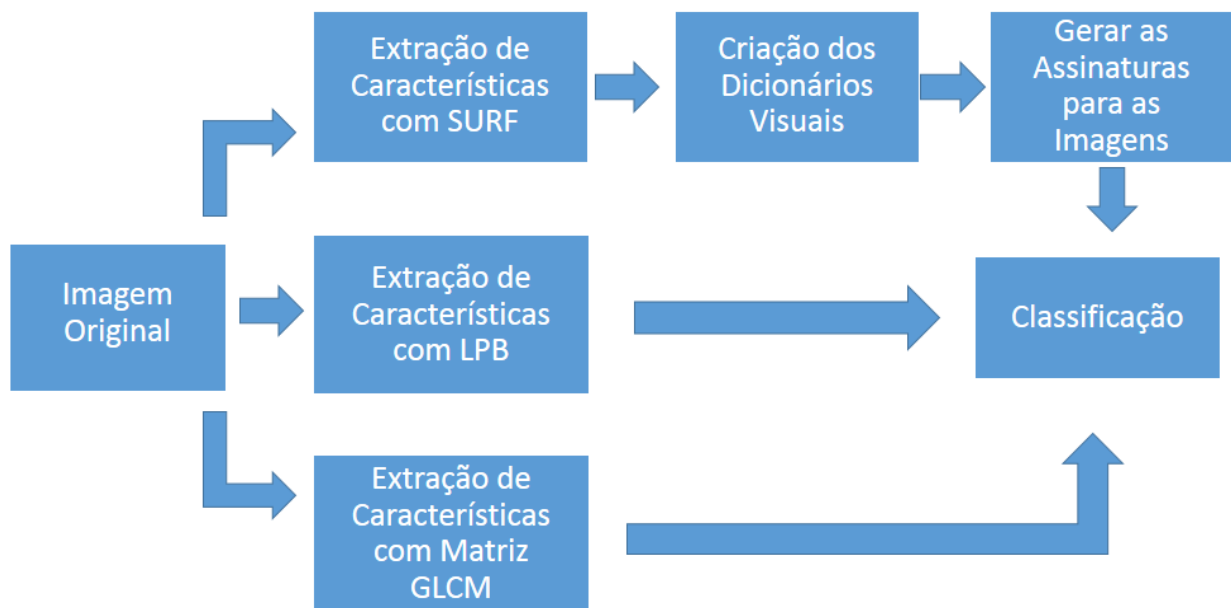


Figura 3. Fluxograma contendo os passos do método proposto neste trabalho.

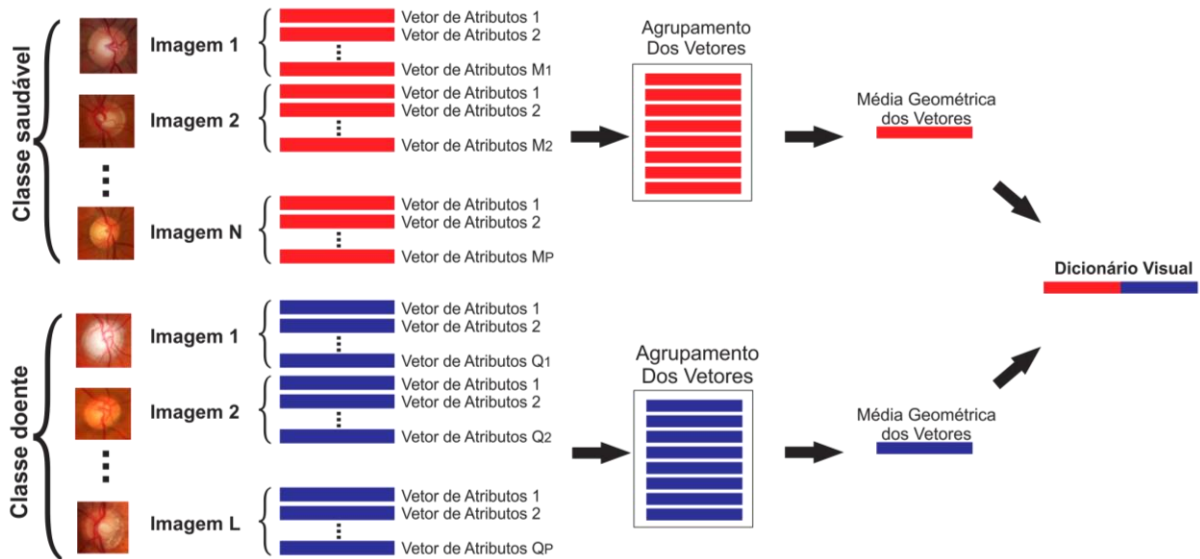


Figura 4. Formação dos dicionários visuais

A fase 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 do 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, onde cada característica conterá quatro, um para cada orientação e característica.

Por fim, para realizar a classificação das imagens, foram concatenados as assinaturas geradas, juntamente com o histograma obtido de cada imagem por meio do LBP e os atributos do GLCM, gerando um vetor de 528 atributos.

V. RESULTADOS E DISCUSSÕES

Nesta seção serão descritos os resultados encontrados no desenvolvimento da metodologia desse trabalho.

A. Critérios de Avaliação

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.

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 1, 2, 3 e 4.

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

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

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

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

Outras duas medidas utilizadas foram a Área Sob a Curva ROC (AUC) e o índice Kappa. A AUC é a representação da sensibilidade de um classificador dada pela taxa de VP em função da taxa de FP. Quanto maior a AUC mais preciso é o classificador. O índice Kappa 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 [18].

O índice Kappa é um coeficiente de concordância para escalas nominais que mede o relacionamento entre a concordância, além da casualidade, e a discordância esperada [18]. O índice Kappa pode ser encontrado com base na Equação

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

Neste caso, entenda-se por “observado” o valor global para a percentagem 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 1, de acordo com o estabelecido por Landis et al. (1977) [19].

TABELA 1. NÍVEL DE EXATIDÃO DE UMA CLASSIFICAÇÃO, CONFORME O VALOR DO KAPPA.

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

B. Resultados

O software utilizado para classificação foi o *Waikato Environment for Knowledge Analysis* (WEKA) [20]. Os algoritmos testados nesse trabalho foram: *Random Forest*

[21], *C4.5* [22] *Radial Basis Function* (RBF) *Classifier* [23], *Logistic Model Trees* (LMT) [24], *Random Tree* [25], e *LibLinear* [26]. Para avaliação dos resultados foram utilizados os seguinte critério: VP, FP, FN, VN, precisão, *recall*, FM, acurácia e Kappa. Foram utilizadas 15 imagens saudáveis e 20 doentes para construção do dicionário visual, e para verificar o desempenho do algoritmo foram usadas 103 imagens saudáveis e 20 doentes. Vale destacar que as imagens utilizadas para o teste do algoritmo foram diferentes das utilizadas para a formação do dicionário.

Inicialmente foram executados testes separados com cada um dos descritores, a saber: SURF, LBP e GLCM. Os resultados obtidos são apresentados na Tabela 2, onde inicialmente são mostrados os resultados com os atributos extraídos pelo SURF, logo em seguida os resultados obtidos após a extração pelo LBP e por fim com a GLCM. Os parâmetros utilizados para classificação foram os padrões do WEKA e o critério de avaliação foi o *k-fold cross-validation* (com $k = 10$).

TABELA 2. RESULTADOS ENCONTRADOS PELA EXTRAÇÃO DE CARACTERÍSTICAS COM O SURF E O LBP SEPARADAMENTE.

		VP	FP	FN	VN	P	R	FM	A	Kappa
SURF	<i>Random Forest</i>	1	19	0	103	87,00	84,60	78,20	84,55	0,08
	<i>Random Tree</i>	6	14	19	84	75,70	73,20	74,30	73,17	0,10
	C4.5	4	16	10	93	76,10	78,90	77,30	78,86	0,11
	<i>RBF</i>	0	20	0	103	70,10	83,70	76,30	83,74	0
	LMT	1	19	6	97	72,30	79,70	75,40	79,67	-0,01
	LibLinear	4	16	11	92	75,70	78,00	76,70	78,04	0,10
LBP	<i>Random Forest</i>	17	23	12	106	76,20	77,00	76,60	77,84	0,35
	<i>Random Tree</i>	12	28	21	97	67,20	69,00	67,10	68,35	0,10
	<i>C4.5</i>	11	29	21	97	66,20	68,40	67,10	68,35	0,10
	<i>RBF</i>	2	38	1	117	73,30	75,30	66,40	75,31	0,05
	LMT	11	29	13	105	70,10	73,40	70,90	73,41	0,19
	LibLinear	15	25	12	106	74,50	76,60	74,90	76,58	0,30
GLCM	<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
	<i>C4.5</i>	3	35	14	104	62,25	69,00	64,70	68,99	0,01
	<i>RBF</i>	0	40	0	118	55,80	74,70	63,90	74,68	0
	LMT	3	35	6	112	68,40	74,10	68,10	74,05	0,10
	LibLinear	0	40	0	118	55,80	74,70	63,90	74,68	0

Pela análise dos resultados da classificação apresentados na Tabela 2, podemos concluir que ambos descritores de modo individual não produzem bons resultados. Os melhores resultados foram produzidos pela C4.5, *RandomForest* e *Random Tree* para os atributos do SURF, LBP e GLCM respectivamente, com Kappa de 0,11, 0,35 e 0,17. De acordo com a Tabela 1 esses resultados são classificados apenas como “razoáveis”.

Dessa maneira, buscando melhorar os resultados da classificação, os atributos extraídos pelos descritores SURF, LBP e GLCM foram concatenados, formando um vetor único para melhor descrever as imagens. A Tabela 3 mostra os resultados obtidos pela nova classificação utilizando esses atributos.

Pela análise da Tabela 3 percebe-se que todos os classificadores obtiveram resultados melhorados em relação a classificação anterior, contudo o que mais se destacou foi o *LibLinear*, por ter alcançado os melhores índices, com acurácia de mais 96% e Kappa de 0,87. De acordo com a Tabela 1 o Kappa obtido pela *LibLinear* foi considerado “excelente”. Os resultados comprovam a eficiência da extração de características pelo SURF, LBP e GLCM, atingindo índices considerados bons segundo literaturas [19]

VI. CONCLUSÃO E TRABALHOS FUTUROS

O glaucoma é uma patologia que merece atenção, pois causa sérios danos a visão. Por ser assintomático, quanto mais cedo for detectado maior são as chances do paciente não perder a visão, porém seu diagnóstico é caro. Uma alternativa mais barata é a detecção por Processamento Digital de Imagens (PDI). O PDI está evoluindo rapidamente tornando-se uma ferramenta de auxílio em todas as áreas. Na medicina o diagnóstico de doenças por PDI traz rapidez, confiabilidade e redução de custo, já que não é necessário um profissional da área.

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 e o LBP e a matriz GLCM. Seus resultados foram avaliados separadamente, entretanto não foram aceitáveis. Com isso

foram concatenados os atributos obtidos pelos dois descritores e os resultados obtidos foram bastante satisfatórios, onde o classificador *LibLinear* atingiu cerca de 96% de acurácia, totalizando um kappa de 0.87.

Como trabalho futuro espera-se utilizar novos descritores para a extração das características das imagens e algoritmos de seleção de atributos para filtrar somente os atributos mais significativos, também serão avaliados outros classificadores e testados com outras bases de imagens. Por fim, serão implementados métodos de detecção automática do glaucoma em imagens de retina existentes na literatura e comparados com o método proposto nesse trabalho.

REFERÊNCIAS

- [1] Weinrb, R. N. e Khaw, P. T. (2004) “Primary opne-angle glaucoma”. *The Lancet*.
- [2] WHO. “World health organization (WHO)”. Disponível em: <http://apps.who.int/ghodata/?vid=5200>, 2014, acessado em Setembro de 2014.
- [3] Quigley, H. A. e Broman, A. T. (2006) “The number of people with glaucoma worldwide in 2010 and 2020”. *Br J Ophthalmol*. 90(3): p. 262-7.
- [4] Bay, H., Ess, A., Tuytelaars, T. e Gool, L. V. (2008) “SURF: Speeded Up Robust Features”, *Computer Vision and Image Understanding (CVIU)*, Vol. 110, No. 3, pp. 346–359.
- [5] Ojala, T., Pietikinen, M. e Harwood, D. (1996). “A comparative study of texture measures with classification based on featured distributions”, *Pattern Recognition* 26(1): 51–59.
- [6] Haralick, R., Shanmugam, K. e Dinstein, I. (1973) “Textural features for image classification”. *Systems, Man and Cybernetics, IEEE Transactions on, SMC-3*, n. 6, p. 610–621. ISSN 0018-9472.
- [7] Rocha, A., Carvalho, T., Jelinek, H., Goldenstein, S., and Wainer, J. (2012) “Points of interest and visual dictionaries for automatic retinal lesion detection”. *IEEE Transactions on Biomedical Engineering*, 59(8):2244–2253.
- [8] Araújo, F., Silva, R., Macedo, A., Aires, K. e Veras, R. (2013) “Automatic Identification of Diabetic Retinopathy in Retinal Images Using Ensemble Learning”. *Workshop de Informática Médica, Maceió, Alagoas, Brasil*.
- [9] Simonthomas, S., Thulasi, N., e Asharaf, P. (2014) “Automated diagnosis of glaucoma using Haralick texture features”. In *Information Communication and Embedded Systems (ICICES)*, International Conference on (pp. 1-6). IEEE.
- [10] Silva, R., Aires, K., Santos, T., Abdalla, K. e Veras, R. (2014) “Helmet Detection on Motorcyclists Using Image Descriptors and Classifiers”. *XXVII SIBGRAPI Conference on Graphics, Rio de Janeiro, Brasil*.

TABELA 3. RESULTADOS ENCONTRADOS PELA CONCATENAÇÃO DOS ATRIBUTOS EXTRAÍDOS PELO SURF, LBP E A GLCM.

	VP	FP	FN	VN	P	R	FM	A	Kappa
<i>Random Forest</i>	13	7	0	103	94,70	94,30	93,80	94,30	0,75
<i>Random Tree</i>	10	10	7	96	85,40	86,20	85,70	86,18	0,46
<i>C4.5</i>	12	8	8	95	87,70	87,00	87,00	86,99	0,52
<i>RBF</i>	13	7	0	103	94,70	94,30	93,08	94,30	0,76
LMT	12	8	3	100	90,50	91,10	90,50	91,06	0,63
LibLinear	16	4	0	103	96,90	96,70	96,60	96,74	0,87

- [11] Ali, M. A., Hurtut, T., Faucon, T., & Cheriet, F. (2014) "Glaucoma detection based on local binary patterns in fundus photographs". In *SPIE Medical Imaging* (pp. 903531-903531). International Society for Optics and Photonics.
- [12] Trucco, E., Ruggeri, A., Karnowski, T., Giancardo, 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. (2013) "Validating Retinal Fundus Image Analysis Algorithms": Issues And A Proposal. *Invest. Ophthalmol. Vis. Sci.*, vol. 54, no. 5, pp. 3546–3559.
- [13] Carvalho, T. J. (2010) "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, Instituto de Computação, Universidade Estadual de Campinas, Campinas, Brasil.
- [14] Tinne, T., Gool, L. V., Bay, H. e Andreas, E. (2008) "Speeded-up robust features (SURF)". *Computer Vision Image Understand*, 110(3):346–359, 2008.
- [15] Nanni, L., Lumini, A. e Brahnam, L. (2012) "Survey on lbp based texture descriptors for image classification," *Expert Syst. Appl.*, vol. 39, no. 3, pp. 3634–3641.
- [16] Silva, M. A. T. (2013). "Uso de matrizes de co-ocorrências para classificação automática de imagens de cana-de-açúcar". Monografia de Graduação em Ciência da Computação, Universidade Federal de Lavras, Minas Gerais, Brasil.
- [17] Baraldi, A. e Parmiggiani, F. (1995) "An investigation of the textural characteristics associated with gray level cooccurrence matrix statistical parameters". *Geoscience and Remote Sensing, IEEE Transactions on*, v. 33, n. 2, p. 293–304. ISSN 0196-2892.
- [18] Rosenfield, G. H. e Fitzpatrick-lins, K. A. (1986). "A coefficient of agreement as a measure of thematic classification accuracy". *Photogrammetric Engineering and Remote Sensing*, 52:223–227.
- [19] Landis, J. e Koch, G. (1977) "The measurement of observer agreement for categorical data." *Biometrics*, pp. 159-174.
- [20] Witten, I. H., Frank, E., e Hall, M. A. (2011). "DATA MINING": Practical Machine Learning Tools and Techniques. Morgan Kaufmann, 3 edition.
- [21] Breiman, L. (2001) "Random forests". *Machine Learning*, 45(1):5–32.
- [22] Quinlan, J. R. (1986). "Induction of decision tree". *Machine Learning*, pgs. 81–106.
- [23] Frank, E. (2014) "Fully supervised training of Gaussian radial basis function networks in WEKA". Department of Computer Science, The University of Waikato.
- [24] Landwehr, N., Hall, M. e Frank, E. (2005). Logistic model trees. *Machine Learning*, 59(1-2):161–205.
- [25] Aldous, D. (1991) "The continuum random tree". *Ann. Probab.*, 21(1):248–289.
- [26] Fan, R. E., Chang, K. W., Hsieh, C. J., Wang, X. R. e Lin, C. J. (2008) "LIBLINEAR: A library for large linear classification". *Journal of Machine Learning Research* 9, 1871-1874.