

Comparação das Técnicas de Extração de Características HOG e LBP para Detecção de Glaucoma em Retinografias

Rosana Aurélio de Jesus¹, Karin Satie Komati¹, Sérgio Nery Simões¹

¹Programa de Pós-Graduação em Computação Aplicada (PPComp)
Campus Serra do Instituto Federal do Espírito Santo (Ifes)
Serra - ES - Brasil

ro.aurelio16@gmail.com, {kkomati, sergio}@ifes.edu.br

Abstract. *The World Health Organization (WHO) considers glaucoma as the second major cause of blindness all over the world. There are several machine learning techniques that can assist in the detection of glaucoma through retinal images analyses. In this paper, we evaluated three combinations: ten different color space channels, two feature extractors (HOG and LBP) with three different parameters each one, and six different machine learning algorithms. The best results for the Drishti database were achieved in 4 different combinations, indicating that both the HOG and the LBP discriminate textures, and that the SVM classifier, with kernel RBF or linear, reached an accuracy of 88.23%.*

Resumo. *A Organização Mundial da Saúde (OMS) considera o glaucoma como a doença ocular crônica que é a segunda maior causa de cegueira no mundo. Existem diversas técnicas de aprendizado de máquina que podem auxiliar na detecção do glaucoma. Neste artigo, avaliamos três combinações: dez diferentes canais de espaço de cores, dois extratores de características (HOG e LBP) com três diferentes parâmetros em cada e cinco diferentes algoritmos de aprendizado de máquina. Os melhores resultados na base de dados Drishti foram alcançados em 4 combinações diferentes, indicando que tanto o HOG quanto o LBP discriminam texturas, e que o classificador SVM, com kernel RBF ou linear, atinge acurácia de 88,23%.*

1. Introdução

O glaucoma é uma doença ocular crônica que pode levar à cegueira irreversível e é caracterizado pela lesão das células do nervo óptico e sua progressão causa danos estruturais na retina [Naumann 2012]. É possível verificar estes danos através da imagem de fundo de olho. O disco óptico (DO) aparece como um corpo circular amarelado, apresentando no centro a escavação do disco óptico (CDO), que é uma área ligeiramente mais “brilhante” que o disco óptico [Salam et al. 2016]. O tamanho da escavação aumenta nos olhos glaucomatosos. Na Figura 1 há duas imagens, (a) normal e (b) com glaucoma, com as marcações de DO e CDO, em que é possível verificar que o CDO na imagem com glaucoma ocupa um espaço maior que o CDO de imagem normal. Assim, essas mudanças estruturais são usadas para detectar glaucoma usando fundoscopia.

A imagem de fundo de olho é uma das técnicas não invasivas mais utilizadas pelos oftalmologistas [Chen et al. 2015], os especialistas medem a proporção CDR (*Cup to Disc Ratio*) entre o tamanho da região do DO e do CDO. Na prática, o que os médicos

fazem para determinar se o paciente tem glaucoma, ou não, é estimar visualmente o CDR observando a imagem de fundo de olho, sendo esta uma tarefa subjetiva, que pode levar de 1 a 3 minutos se feita por um médico especialista experiente, mas que pode ser uma tarefa árdua em casos de campanhas de triagem, onde no final os especialistas tem centenas de imagens para analisar [Carrillo et al. 2019].

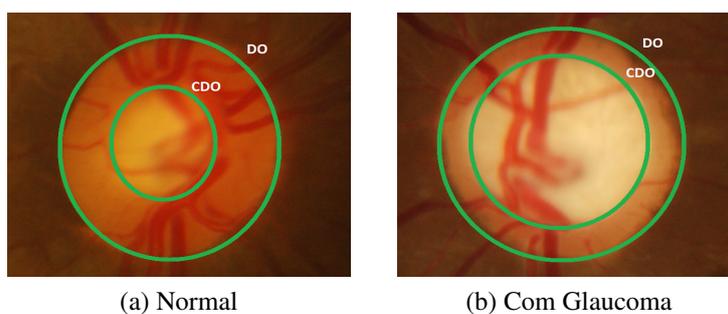


Figura 1. Exemplo de imagens de fundo de olho da base Drishti.

Na maioria dos casos o glaucoma é assintomático no início e vai, progressivamente, causando uma lesão irreversível no nervo. Quando a pessoa começa perceber os sintomas a doença já está em estágios mais avançados e compromete, primeiramente, a visão periférica e se não tratada, o campo visual vai se estreitando, transformando-se numa visão tubular, até a perda total da visão [Križaj 2019]. Entretanto, é possível reverter a doença quando a mesma é tratada nos estágios iniciais [Jae Kim et al. 2017]. Estima-se que o número de pessoas com glaucoma no mundo chegará a 111,8 milhões em 2040 [Tham et al. 2014] e que aproximadamente 50% dos acometidos não sabem que são portadores da doença.

Uma das abordagens para o diagnóstico automático é o pré-processamento de imagens, seguido da extração de características e por fim a classificação. Neste artigo, é feito um estudo comparativo da variação de algumas técnicas e parâmetros em cada uma das etapas. No pré-processamento avaliamos qual é o melhor canal dentre os espaços de cores [Haleem et al. 2013]: RGB, HSV e Lab. Na segunda etapa, foram comparados dois métodos de extração de característica: LBP (do inglês *Local Binary Pattern*, em português Padrões Locais Binários) e HOG (do inglês *Histograms of Oriented Gradient*, em português Histograma de Gradientes Orientados) variando seus parâmetros, onde foram utilizados diferentes valores para o raio e vizinhança do descritor LBP e diferentes valores de célula e bloco para o HOG. Na terceira e última etapa, comparamos cinco classificadores [Ceravolo et al. 2019]: (i) Naive-Bayes (NB), (ii) KNN (do inglês *k-Nearest Neighbors*, em português k-Vizinhos mais próximos), (iii) GP (do inglês *Gaussian Processes* em português processo gaussiano), SVM (do inglês *Support Vector Machine*, em português Máquinas de Vetores de Suporte) com (iv) *kernel* linear e (v) com *kernel* RBF. A base de dados dos experimentos é a Drishti [Sivaswamy et al. 2014].

No que se refere à estrutura do artigo, na seção 2 são apresentados alguns trabalhos correlatos ao tema. A metodologia empregada é descrita na seção 3, formando a base para a apresentação e análise dos resultados na seção 4. A seção 5 encerra o artigo com os comentários finais e conclusões.

2. Trabalhos Correlatos

Se detectado precocemente, é possível retardar ou frear a progressão do glaucoma a partir de tratamentos adequados. A abordagem deste trabalho é pela extração de características com técnica de aprendizado de máquina.

Salam e colegas [Salam et al. 2016] propuseram uma abordagem que combina características estruturais (uso de técnicas de processamento de imagens para estimar as elipses do DO e do CDO e cálculo do CDR) e não estruturais (extração de características e classificador). A classificação das características de intensidade e textura foram feitas usando extratores de características (Wavelets, Multiwavelets, LBP, *Gray level cooccurrence matrix* - GLCM, Haralick, Momentos de cromaticidade e *Autocorrelogram*) e o classificador foi o SVM. Resultados obtidos em uma base de dados privada foram de sensibilidade e especificidade médias de 100% e 87%, respectivamente. Uma das contribuições deste artigo foi que o resultado final da imagem é classificado em três tipos: imagem normal, com glaucoma e, com suspeita de glaucoma. O último tipo, com suspeita, foi um diferencial frente à outros artigos.

Kim e colegas [Jae Kim et al. 2017] propuseram um estudo que utilizou os algoritmos C5.0, RF, SVM e KNN para verificar a acurácia na detecção de glaucoma. A diferença entre DO e CDO e o campo visual foram utilizados como indicadores da classificação. A base de dados usada nos experimentos é privada, obtida de pacientes do hospital Universitário Dankook e do Hospital da Universidade Nacional Gyeongsang, com 100 imagens de fundo de olho para testes e 399 para treinamento e validação dos modelos. Os modelos foram analisados considerando precisão, sensibilidade, especificidade e razão de verossimilhança. O algoritmo RF mostrou melhor performance, C5.0, SVM e KNN mostraram precisão similar.

O trabalho de Silva e colegas [Silva et al. 2018] apresentou um método computacional utilizando descritores de textura e o classificador SVM. Os descritores de textura utilizados foram LBP e três variações do LBP: LQP, CS-LBP e CLBP. O método proposto é dividido em quatro etapas: pré-processamento, decomposição espacial, extração de característica e reconhecimento de padrões. O pré-processamento teve como objetivo amenizar as diferenças da luminosidade e evidenciar características do disco óptico e cavidade do disco. As imagens foram separadas nos canais de cores RGB e em seguida foram aplicadas transformações de cores opostas nos três canais, resultando em três novos canais. É feita a equalização das imagens e depois a decomposição espacial, com divisão da imagem em 9 partes, para então realizar a extração de características. Utilizando o classificador SVM alcançou resultados de 90,70% de acurácia, obtido com o CLBP, na segunda versão da base de dados RIM-ONE.

Tal como nos trabalhos de Salam et al. e de Silva et al. usa-se o extrator de texturas LBP. No entanto, este trabalho estuda as variações dos parâmetros do LBP (raio e vizinhança) e ainda o compara com outro descritor de características, o HOG (com variações de tamanho de célula e bloco). Assim como nos três trabalhos citados, usa-se o classificador SVM, mas com duas variações de *kernel* e ainda compara-se com outros quatro classificadores clássicos. Através do trabalho de Haleem e colegas [Haleem et al. 2013], que traça uma extensa revisão de vários trabalhos de extração de características para diagnóstico de glaucoma, verifica-se que os espaços de cores mais utilizados são o RGB, HSV e Lab, que são os escolhidos para este trabalho.

3. Materiais e Métodos

A abordagem deste trabalho usa extração de características para verificar os aspectos das imagens saudáveis e com glaucomas e, um conjunto de classificadores para categorizar a imagem em “Normal” e “Glaucoma”. As etapas da arquitetura são apresentadas na Figura 2: obtenção de cada canal dos espaços de cores (etapa de pré-processamento), extração de características e classificação. Este trabalho utiliza a base de dados Drishti

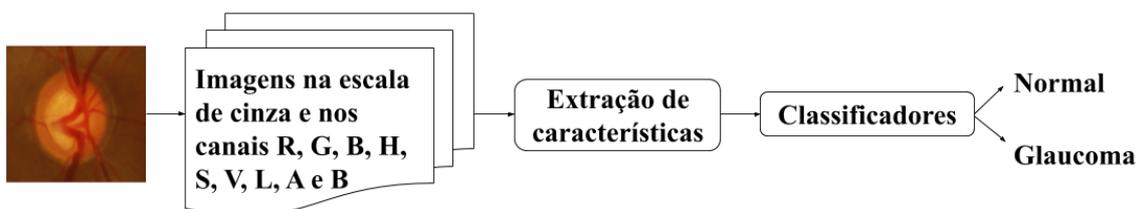


Figura 2. Arquitetura proposta.

[Sivaswamy et al. 2014]. As imagens foram coletadas no hospital dos olhos Aravind, em Madurai, na Índia, com o consentimento dos pacientes. Os pacientes selecionados tinham idade entre 40 e 80 anos de idade, sendo aproximadamente metade entre homens e mulheres. Para cada imagem, foram coletadas marcações manuais de quatro especialistas com experiência de 3, 5, 9 e 20, respectivamente, para identificar o CDO e DO.

A base conta com 101 imagens, sendo dividida da seguinte forma: 50 imagens de treinamento (sendo 32 com glaucoma e 18 normais) e 51 imagens de testes (sendo 38 com glaucoma e 13 normais). Portanto, é um cenário de base de dados desbalanceada, tanto para o treino quanto os testes. Para o trabalho, foi feito um recorte manual para obtenção da região de interesse (disco óptico). Através dos três espaços de cores foram gerados 9 canais: canais vermelho (R), verde (G) e Azul (B) do espaço RGB, canais matiz (H), saturação (S), valor (brilho) do sistema HSV e canais de luminosidade (L), coordenada vermelho/verde (A) e coordenada amarelo/azul (B) do sistema Lab. Além dos 9 canais também foi usada a imagem em escala de cinza, totalizando dez canais processados. Para cada uma, separadamente, é feita a extração de características LBP e HOG, que mensuram as micro-texturas da imagem. Os classificadores serão treinados e testados, independentemente, com os vetores de características obtidos para cada canal de cores.

A técnica de extração de característica LBP [Ojala et al. 1996], utiliza a intensidade dos pixels vizinhos (circularmente simétrico) para calcular a textura da imagem. Para lidar com imagens com texturas em diferentes escalas, o operador pode trabalhar com vizinhanças de tamanhos diferentes, desde que seja definida como um conjunto de pontos uniformemente espaçados em um círculo centralizado no pixel a ser rotulado, permitindo assim qualquer raio e números de pontos vizinhos. A técnica de extração de característica HOG [Dalal and Triggs 2005], criada inicialmente para detecção de pedestres, propõe a ideia de se obter informações da imagem a partir da distribuição de gradientes das intensidades dos pixels. Na prática, a imagem é dividida em pequenas regiões (células), onde para cada célula é armazenado um histograma dos gradientes. O descritor pode ser definido em quatro partes: normalização da imagem, cálculo do gradiente de primeira ordem no eixo vertical e horizontal da imagem, criação do histograma de orientações do gradiente de cada célula, agrupamento das células em regiões denominadas blocos, onde os histogramas das células são concatenados e é feita

normalização local dos mesmos e por último a concatenação dos histogramas dos blocos obtidos na etapa anterior, gerando o vetor de características da imagem. A parametrização se concentra no tamanho das células e dos blocos [da Silva et al. 2017].

Os classificadores utilizados foram KNN, SVM Linear, SVM RBF, GP e NB. A avaliação dos classificadores foi feita via *hold-out*, já que a base de dados já é fornecida em treino/testes separadamente. Todas as matrizes de confusão dos testes foram armazenadas, mas devido à limitação de páginas do artigo, apresentam-se apenas a acurácia como métrica de avaliação de desempenho.

4. Experimentos, Resultados e Discussão

Todo o ambiente de experimentos foi desenvolvido em Python. A apresentação dos resultados é dividido em duas partes, primeiro os resultados do LBP, seguidos dos resultados do HOG.

Para o LBP, varia-se o número de pontos e o tamanho do raio. Foram utilizadas três configurações para os experimentos: LBP com 8 pontos e raio 1 (Tabela 1), LBP com 16 pontos e raio 3 (Tabela 2) e LBP com 24 pontos e raio 8 (Tabela 3). Em cada tabela, a primeira linha é a imagem em escala de cinza e as demais, cada canal de cada um dos três espaços de cores: RGB, HSV e Lab. Cada coluna representa um dos 6 modelos de classificadores e cada célula é a acurácia do modelo num determinado canal. Para todas as variações de parâmetros do LBP o mesmo gerou vetor de característica de tamanho 256.

Como pode ser visto na Tabela 1, para o LBP com 8 pontos e raio 1, a maior acurácia de 76,47% foi alcançada no classificador SVM Linear para o canal vermelho do sistema RGB e para o canal brilho (V), do espaço HSV. A Tabela 2 mostra que para o LBP com 16 pontos e raio 3 a acurácia alcançada foi de 78,43%, no classificador SVM RBF, com a imagem em escala de cinza. Como mostra a Tabela 3, o melhor resultado de acurácia foi em torno de 88,23%, para o LBP com 24 pontos e raio 8 no classificador SVM RBF, no canal verde do RGB. Verifica-se que, na base de dados utilizada, para o extrator de características LBP, o espaço de cores Lab sempre apresentou resultados menores que os outros espaços de cores. Os melhores resultados sempre foram com o classificador SVM, seja com *kernel* linear ou RBF.

No caso do descritor HOG, foram variados os parâmetros células e blocos. Foram utilizadas três configurações: tamanho da célula 8x8 com tamanho do bloco 1x1 (Tabela 4), que gerou vetor de característica com 197.136 posições, tamanho da célula 8x8 com tamanho do bloco 2x2 (Tabela 5), o qual gerou vetor com 12.321 posições e tamanho da célula 16x16 com tamanho do bloco 1x1 (Tabela 6), que gerou vetor de característica com 1.296 posições. Em cada tabela a primeira linha é a imagem em escala de cinza e as demais cada canal dos espaços de cores RGB, HSV e Lab. Cada coluna e cada célula é a acurácia do modelo num determinado canal.

Para célula de tamanho 8x8 e bloco 1x1, como mostra Tabela 4, a melhor acurácia foi de aproximadamente 88,2%, no classificador SVM Linear nos canais vermelho do RGB e brilho (V) do HSV. Para célula de tamanho 8x8 e bloco 2x2, a melhor acurácia foi de 86,27%, Tabela 5, no canal luminosidade do sistema de cores Lab, no classificador SVM Linear. Para célula de tamanho 16x16 e bloco 1x1, a maior acurácia foi de 88,23%, Tabela 6, para a imagem em escala de cinza.

Tabela 1. Acurácia para LBP com 8 pontos e raio 1.

	KNN	SVM Linear	SVM RBF	GP	NB
cinza	60,78%	74,51%	74,51%	74,51%	72,55%
RGB - R	58,82%	76,47%	72,55%	60,78%	72,55%
RGB - G	72,55%	74,51%	74,51%	74,51%	70,59%
RGB - B	64,71%	74,51%	70,59%	74,51%	70,59%
HSV - H	58,82%	54,90%	62,75%	58,82%	35,29%
HSV - S	64,71%	74,51%	72,55%	74,51%	60,78%
HSV - V	58,82%	76,47%	72,55%	60,78%	72,55%
LAB - L	64,71%	74,51%	72,55%	74,51%	74,51%
LAB - A	58,82%	74,51%	68,63%	66,67%	43,14%
LAB - B	64,71%	64,71%	64,71%	66,67%	58,82%

Tabela 2. Acurácia para LBP com 16 pontos e raio 3.

	KNN	SVM Linear	SVM RBF	GP	NB
cinza	66,67%	74,51%	78,43%	74,51%	70,59%
RGB - R	54,90%	74,51%	62,75%	50,98%	41,18%
RGB - G	68,63%	74,51%	76,47%	74,51%	74,51%
RGB - B	62,75%	74,51%	70,59%	74,51%	47,06%
HSV - H	62,75%	62,74%	68,63%	62,75%	52,94%
HSV - S	56,86%	74,51%	70,59%	74,51%	43,14%
HSV - V	54,90%	74,51%	62,75%	50,98%	41,18%
LAB - L	64,71%	74,51%	74,51%	74,51%	50,98%
LAB - A	60,78%	74,51%	56,86%	74,51%	43,14%
LAB - B	52,94%	62,75%	66,67%	64,71%	54,90%

Tabela 3. Acurácia para LBP com 24 pontos e raio 8.

	KNN	SVM Linear	SVM RBF	GP	NB
cinza	52,94%	74,51%	80,39%	74,51%	49,02%
RGB - R	66,67%	74,51%	70,59%	56,86%	49,02%
RGB - G	58,82%	82,35%	88,23%	74,51%	78,43%
RGB - B	72,55%	70,59%	74,51%	74,51%	35,29%
HSV - H	49,02%	54,90%	70,59%	54,90%	45,10%
HSV - S	54,90%	74,51%	72,55%	74,51%	35,29%
HSV - V	66,67%	74,51%	70,59%	56,86%	49,02%
LAB - L	66,67%	74,51%	84,31%	64,71%	52,94%
LAB - A	54,90%	74,51%	68,63%	74,51%	50,98%
LAB - B	54,90%	60,78%	70,59%	74,51%	66,67%

Ao final dos experimentos do HOG, o canal vermelho do espaço de cor RGB, bem como o canal de brilho do espaço HSV, são mais discriminantes em textura caracterizadas pelo HOG com célula 8x8 e bloco 1x1 com SVM Linear. O canal vermelho do RGB ser mais discriminante é coerente com o conteúdo da imagem que possui mais esta cor. Para o LBP com 24 pontos e raio 8, o melhor resultado foi para o canal verde do RGB, no classificador SVM RBF. O canal verde apresentar bons resultados, pode ser devido ao fato de ser o canal o qual possui informações mais significantes do CDO, que tem uma cor mais amarelada/laranja que o restante da imagem que é mais avermelhada. O fato do SVM linear, no geral, apresentar acurácia melhor que a sua versão RBF, ao utilizar o HOG, leva a supor que o conteúdo do vetor de características é linear para sua separação.

Uma valor que aparece repetidamente é a acurácia de 74,51%, e aparece para todas colunas das tabelas de HOG para o SVM RBF. Isto se deve ao fato de que ou a quantidade de imagens de treinamento não foi suficiente ou o vetor de características não foi discriminante o suficiente. O modelo sempre responde que todas as 51 imagens de testes estão com glaucoma, com a seguinte matriz de confusão $\begin{pmatrix} 38 & 0 \\ 13 & 0 \end{pmatrix}$.

Os melhores resultados em termos de acurácia geral, em torno de 88%, deve-se à um acerto de 45 dentre as 51 imagens de testes. No entanto, do ponto de vista de acerto de imagens saudáveis, que nesta base é a minoria das imagens, a configuração de RGB-G usando LBP (24 pontos e raio 8) com NB, apresentou a seguinte matriz de confusão

Tabela 4. Acurácia para HOG com células 8x8 e bloco 1x1.

	KNN	SVM Linear	SVM RBF	GP	NB
cinza	76,47%	86,27%	74,51%	78,43%	82,35%
RGB - R	74,51%	88,23%	74,51%	72,55%	86,27%
RGB - G	74,51%	86,27%	74,51%	72,55%	84,31%
RGB - B	76,47%	80,39%	74,51%	68,63%	74,51%
HSV - H	68,63%	76,47%	74,51%	78,43%	74,51%
HSV - S	74,51%	76,47%	74,51%	66,67%	74,51%
HSV - V	74,51%	88,23%	74,51%	72,55%	86,27%
LAB - L	78,43%	86,27%	74,51%	84,31%	82,35%
LAB - A	70,59%	74,51%	74,51%	68,63%	72,55%
LAB - B	72,55%	74,51%	74,51%	72,55%	70,59%

Tabela 5. Acurácia para HOG com células 8x8 e bloco 2x2.

	KNN	SVM Linear	SVM RBF	GP	NB
cinza	74,51%	84,31%	74,51%	76,47%	76,47%
RGB - R	70,59%	84,31%	74,51%	64,71%	80,39%
RGB - G	72,55%	82,35%	74,51%	74,51%	76,47%
RGB - B	72,55%	76,47%	74,51%	68,63%	74,51%
HSV - H	68,63%	74,51%	74,51%	76,47%	74,51%
HSV - S	74,51%	76,47%	74,51%	74,51%	74,51%
HSV - V	70,59%	84,31%	74,51%	64,71%	80,39%
LAB - L	76,47%	86,27%	74,51%	84,31%	80,39%
LAB - A	72,55%	76,47%	74,51%	68,63%	72,55%
LAB - B	78,43%	80,39%	74,51%	60,78%	72,55%

Tabela 6. Acurácia para HOG com células 16x16 e bloco 1x1.

	KNN	SVM Linear	SVM RBF	GP	NB
cinza	76,47%	78,43%	74,51%	74,51%	88,23%
RGB - R	72,54%	80,39%	74,51%	70,59%	76,47%
RGB - G	74,51%	80,39%	74,51%	72,54%	82,35%
RGB - B	74,51%	78,43%	74,51%	76,47%	70,59%
HSV - H	72,54%	70,59%	74,51%	70,59%	68,63%
HSV - S	72,54%	72,54%	74,51%	76,47%	68,63%
HSV - V	72,54%	80,39%	74,51%	70,59%	76,47%
LAB - L	78,43%	80,39%	74,51%	82,35%	86,27%
LAB - A	64,71%	72,54%	74,51%	70,59%	72,54%
LAB - B	76,47%	80,39%	74,51%	76,47%	72,54%

$\begin{pmatrix} 12 & 26 \\ 0 & 13 \end{pmatrix}$, com acurácia geral baixa, mas acertando todas as imagens saudáveis. Uma possibilidade de trabalho futuro seria a fusão de resultados, colocando a configuração de RGB-G usando LBP (24 pontos e raio 8) com NB indicando imagens saudáveis e a configuração RGB-G usando LBP (24 pontos e raio 8) com SVM RBF para indicar imagens com glaucoma.

5. Considerações Finais

O objetivo deste trabalho foi fazer um estudo da variação de alguns parâmetros nas técnicas de extração de características HOG e LBP seguido de técnicas de aprendizado de máquina para detecção de glaucoma. O estudo analisou três variações: diferentes canais de espaço de cores, dois extratores de características, variando seus parâmetros, e diferentes algoritmos de aprendizado de máquina.

Ao final, foi possível se alcançar acurácia de mais de 88% usando apenas um único canal de cor, seguido de um único extrator de características e uma técnica clássica de classificação. Chega-se em uma proposta simples, com resultados próximos às técnicas bem mais elaboradas de trabalhos correlatos.

Como outros trabalhos futuros, serão consideradas outras técnicas de extração de características, fazendo um estudo dos parâmetros e das famílias wavelets, bem como o uso de fusão de classificadores e de classificadores mais recentes, tal como o XGBoost.

Deve-se levar em consideração técnicas e métricas que trabalhem melhor com bases desbalanceadas de dados.

Referências

- Carrillo, J., Bautista, L., Villamizar, J., Rueda, J., Sanchez, M., et al. (2019). Glaucoma detection using fundus images of the eye. In *2019 XXII Symposium on Image, Signal Processing and Artificial Vision (STSIVA)*, pages 1–4. IEEE.
- Ceravolo, I., Brasil, A. A., and Komati, K. (2019). Classifying readers with dyslexia from eye movements using machine learning and wavelets. In *ENIAC 2019 (XVI Encontro Nacional de Inteligência Artificial e Computacional)*.
- Chen, X., Xu, Y., Kee Wong, D. W., Wong, T. Y., and Liu, J. (2015). Glaucoma detection based on deep convolutional neural network. In *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pages 715–718.
- da Silva, R. L., Chevtchenko, S., de Moura, A. A., Macario, V., and Cordeiro, F. R. (2017). A study of swimmers detection in beach images. In *Anais do XIII Workshop de Visão Computacional*, pages 106–111.
- Dalal, N. and Triggs, B. (2005). Histograms of oriented gradients for human detection. In *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*, volume 1, pages 886–893 vol. 1.
- Haleem, M. S., Han, L., Van Hemert, J., and Li, B. (2013). Automatic extraction of retinal features from colour retinal images for glaucoma diagnosis: a review. *Computerized medical imaging and graphics*, 37(7-8):581–596.
- Jae Kim, S., Jin Cho, K., and Oh, S. (2017). Development of machine learning models for diagnosis of glaucoma. *PLoS ONE*, 12.
- Križaj, D. (2019). *What is glaucoma?* University of Utah Health Sciences Center.
- Naumann, G. O. (2012). *Pathology of the Eye*. Springer Science & Business Media.
- Ojala, T., Pietikäinen, M., and Harwood, D. (1996). A comparative study of texture measures with classification based on featured distributions. *Pattern Recognition*, 29(1):51 – 59.
- Salam, A. A., Khalil, T., Akram, M. U., Jameel, A., and Basit, I. (2016). Automated detection of glaucoma using structural and non structural features. *SpringerPlus*, 5(1):1519.
- Silva, M., Pessoa, A., de Almeida, J., Júnior, G. B., and de Paiva, A. (2018). Diagnóstico do glaucoma em imagens de retinografia usando variantes de padrões locais binários. In *Anais do XVIII Simpósio Brasileiro de Computação Aplicada à Saúde*, Porto Alegre, RS, Brasil. SBC.
- Sivaswamy, J., Krishnadas, S., Joshi, G., Jain, M., and Tabish, A. (2014). Drishti-gs: Retinal image dataset for optic nerve head(ONH) segmentation. pages 53–56.
- Tham, Y.-C., Li, X., Wong, T.-Y., Quigley, H., Aung, T., and Cheng, C.-y. (2014). Global prevalence of glaucoma and projections of glaucoma burden through 2040: A systematic review and meta-analysis. *Ophthalmology*, 121:2081–2090.