



Diagnóstico do Glaucoma em Retinografias Usando LBP e SVM

Mayara G. Silva¹, João D. S. de Almeida¹, Jefferson A. de Sousa¹, Geraldo Braz Junior¹, Anselmo Cardoso de Paiva¹

¹Núcleo de Computação Aplicada (NCA), Universidade Federal do Maranhão (UFMA) Caixa Postal 65.085-580 – São Luís – MA – Brazil

{mayaragomys,jdallyson,alves.jefferson27,ge.braz,anselmo.c.paiva}@gmail.com

Abstract. Glaucoma is an optical disease that causes irreversible damage to the optic nerve and is the second leading cause of blindness in the world. This paper aimed to develop a computational methodology to detect glaucoma in retinography using LBP texture descriptor for extraction of characteristics and SVM for classification. The proposed method is organized in four stages: (1) preprocessing, (2) spatial decomposition, (3) feature extraction, and (4) pattern recognition. The results showed that the proposed method was promising, reaching 87.27 % accuracy.

Resumo. O glaucoma é uma doença óptica que causa dano irreversível ao nervo óptico e é a segunda principal causa de cegueira no mundo. Este trabalho teve como objetivo o desenvolvimento de uma metodologia computacional para detectar o glaucoma em retinografias utilizando descritor de textura LBP para extração de características e o SVM para classificação das imagens. O método proposto está organizado em quatro etapas: (1) pré-processamento, (2) decomposição espacial, (3) extração de características, e (4) reconhecimento de padrões. Os resultados obtidos revelaram que o método proposto mostrou-se promissor alcançando 87,27% de acurácia.

1. Introdução

O glaucoma é uma neuropatia óptica que causa dano progressivo e irreversível ao nervo óptico, cujo principal fator de risco é o aumento da pressão intraocular, e pode levar a perda do campo visual [Gonçalves et al. 2013]. De acordo com a Organização Mundial de Saúde, o glaucoma é a segunda principal causa de cegueira; ele é responsável por aproximadamente 5,2 milhões de casos de cegueira (15% do total de cegueira mundial) e vai aumentar para 11,2 milhões de pessoas até 2020 [Anusorn et al. 2013]. Sendo assim, faz-se necessário o diagnóstico precoce de tal patologia.

Uma forma de se diagnosticar doenças como o glaucoma é através do exame do nervo óptico. Um dos principais exames oftalmológicos utilizados para a detecção de glaucoma é a retinografia (fotografia de Fundo de Olho). O diagnóstico do glaucoma também pode ser realizado através de processamento digital de imagens. As principais formas de detecção são por segmentação da região do disco ótico [Pinheiro et al. 2015] e extração de características com técnicas de classificação.

A partir das imagens digitais de fundo de olho, [de Sousa et al. 2017] utilizou o Padrão Binário Local (LBP) para representar a região do disco óptico e funções geoestatísticas para descrever padrões de textura. Uma estratégia similar é a proposta de



[Ramos Neto et al. 2016] que utilizou variantes de padrões locais em imagens digitais para discriminar os padrões de massas malignas e benignas. Esta discriminação se dá através da utilização de operadores locais, das técnicas Local Binary Pattern (LBP), Local Quinary Pattern (LQP), Circular-Symmetric Local Binary Pattern (CS-LBP) e Compound Local Binary Pattern(CLBP), combinando cada uma com as abordagens Cartesian Grid, Grid X, Complete Grid, Abordagem Circular. Por fim, classificando a textura utilizando o Support Vector Machine (SVM). Este artigo é baseado nesta proposta e tem como objetivo o estudo da utilização do LBP com a decomposição espacial juntamente com o SVM aplicado no diagnóstico em retinografia.

2. Métodos

A metodologia é estruturada em quatro etapas: pré-processamento, decomposição espacial, extração de características e reconhecimento de padrões. A Figura 1 apresenta as etapas do método proposto.



Figura 1. Etapas do método proposto

Base de imagens - A base utilizada neste trabalho foi a RIM-ONE [Trucco et al. 2013]. Foi utilizada a versão 2, que possui 455 imagens no formato RGB, e são separadas em duas classes, *Glaucoma and suspicious* (200) e *Normal* (255). A Figura 2 apresenta uma imagem de um indivíduo da classe *Normal* (Figura 2A) e de um paciente da classe *Glaucoma and suspicious* (Figura 2B).



Figura 2. (A) Normal, (B) Glaucoma and suspicious

2.1. Pré-Processamento

A etapa de pré-processamento teve como objetivo amenizar as diferenças de luminosidade entre as imagens e evidenciar características da região do disco óptico e da cavidade do disco óptico, para a fase de extração de características.



O RGB é um dos espaços mais utilizados para processamento de imagem. Porém, não é perceptivelmente uniforme [Bratkova et al. 2009]. Por esta razão foi utilizado a teoria de cores opostas [Hering 1880], para evidenciar as características da imagem. Esta teoria afirma que existem três pares de cores que nunca são vistas juntas no mesmo lugar ao mesmo tempo e são chamados de cores opostas. São vermelho *versus* verde (O1), verde *versus* vermelho (O2) e azul *versus* amarelo (O3) [Penedo et al. 2014]. Usar cores oponentes para analisar a textura implica calcular os três canais adversários da imagem de entrada em RGB, que são definidos como [Van De Sande et al. 2010]:

$$O1 = \frac{(R-G)}{\sqrt{2}},$$
$$O2 = \frac{((R+G)-2B)}{\sqrt{6}},$$
$$O3 = \frac{(R+G+B)}{\sqrt{3}}.$$

Inicialmente, da imagem original (RGB) foram separados os canais e aplicada a função de cores opostas. Em seguida as imagens foram equalizadas [Gonzalez et al. 2004]. A Figura 3 apresenta um exemplo de cada cor oposta resultante, a *azul-amarelo*, *verde-vermelho* e *vermelho-verde*.



Figura 3. (A) azul-amarelo, (B) verde-vermelho, (C) vermelho-verde

2.2. Decomposição Espacial

Esta etapa tem como objetivo aplicar na imagem da imagem da região de interesse (ROI) uma técnica de representação visando análise de textura local. A abordagem de decomposição espacial utilizada foi a *Cartesian Grid*, que divide a imagem como uma grade. A ROI é dividida em sub-regiões dada por uma função parametrizada de m e n, m é o número de divisões horizontais e n é o número de divisões verticais [Ahmed et al. 2011]. Neste trabalho, utilizamos *Cartesian Grid* 3x3. A Figura 4 representa uma das imagems com grid 3x3.





Figura 4. Exemplo de Cartesian Grid 3x3

2.3. Extração de Características

Na etapa de extração de características utilizou-se a Local Binary Pattern (LBP) para descrever a textura das regiões do disco óptico. O LBP é um descritor de textura e tem sido amplamente utilizado em várias aplicações [Ahonen et al. 2006].

O operador LBP foi aplicado em sua forma padrão, com o cálculo feito em uma janela 3x3 e com número de 8 vizinhos. Em seguida gerados histogramas parciais (aplicado em cada sub-região resultante do Cartesian Grid) que foram normalizados e concatenados, formando o vetor de 9945 características.

2.4. Reconhecimento de Padrões

Esta etapa tem o objetivo de realizar o reconhecimento das imagens, classificando as imagens em saudáveis e glaucomatosas utilizando a SVM. Esse classificador mapeia os dados para um espaço e em seguida encontra um hiperplano de separação linear com margem para dividir em classes diferentes [Rivera et al. 2012].

Na realização dos experimentos, foram utilizadas as 455 imagens da base. A classificação foi realizada seguindo as classes atribuídas na base de imagens. Para os experimentos, foi utilizado o método de aprendizagem de máquina com divisão proporcional da base para treino e teste, utilizando as proporções respectivamente, de 50/50, 60/40, 70/30 e 80/20.

3. Resultados e Discussão

O método proposto teve como meta detectar a presença ou não de Glaucoma em imagens digitais da retina. Para isso, foi analisada as características de cor e textura da imagem. A classificação foi realizada seguindo as classes atribuídas na base de imagens. Para todas as proporções de treino e teste foram realizados 5 repetições de teste, com instâncias geradas aleatoriamente.

Para avaliação dos resultados foram utilizadas as medidas de Acurácia, Sensibilidade e Especificidade. A Sensibilidade é o número de imagens corretamente classificadas como glaucomatosas; Especificidade é o número de imagens classificadas como saudáveis corretamente; Acurácia é a proporção total dos resultados corretos [Chimieski and Fagundes 2013]. A Tabela 1 apresenta a média do resultado dessas execuções, informando a Acurácia, Sensibilidade e Especificidade.



142014 11 10010 40 041100141 gill 0110 0011 ==1				
Treino-Teste	Acurácia	Sensibilidade	Especificidade	nVS
50-50	$84{,}298\pm0{,}01$	$78,2\pm0,04$	$89,062\pm0,01$	182
60-40	$84,175 \pm 0,03$	$78{,}5\pm0{,}06$	$88,\!627\pm0,\!02$	206
70-30	$83,795 \pm 0,02$	$79,666 \pm 0,05$	$87,\!012\pm0,\!01$	226
80-20	$87,252 \pm 0,01$	$86,5\pm0,03$	$87,\!843\pm0,\!01$	273
* nVS - quantidade de vetores de suporte.				

Tabela 1. Teste do Cartesian grid 3X3 com LBP

Os resultados obtidos mostram que o método utilizado é bastante promissor. Pela análise da Tabela 1, percebe-se que à medida que a proporção de treino/teste foi aumentando ocorreu um aumento da acurácia que equivale à média de acertos de imagens com glaucoma e sem glaucoma, obtendo um melhor resultado para a acurácia e sensibilidade na proporção treino/teste 80/20, apresentando valores respectivamente de 87,25% e 86,5%. Porém a especificidade decaiu um pouco até a proporção 70/30, subindo um pouco na proporção 80/20. A proporção de 80/20 mesmo obtendo um valor de especificidade menor que a de 50/50 não foi significativa, continuando com um percentual melhor que a sensibilidade. Os resultados demonstram, ainda, que inicialmente, através do baixo desvio padrão resultante entre as proporções de treino/teste que existe um poder de generalização do método empregado, embora novas investigações devam ser realizadas afim de verificar a complexidade do modelo gerado.

4. Considerações Finais

O uso de processamento de imagens está sendo muito utilizado em várias áreas, como na medicina, servindo de auxílio ao médico. Este trabalho visa uma abordagem capaz de prover um mecanismo que auxilie o médico a diagnosticar imagens de retinografia em saudáveis e glaucomatosas.

Os resultados obtidos revelaram que o descritor LBP e o classificador SVM juntos com o pré-processamento das cores opostas são bastante promissores atingindo um índice de 87% de acerto.

Como trabalhos futuros, a fim de ampliar e melhorar os resultados, pretendemos buscar outras bases de retinografia como a Drishti-GS [Pinheiro et al. 2015]; usar outras variações do LBP como o LQP, CLBP, CS-LBP; buscar outras formas de representação da decomposição espacial, a decomposição circular, Grid X; testar outros métodos de aprendizagem de máquina como o Random Forest.

Referências

- Ahmed, F., Hossain, E., Bari, A. H., and Shihavuddin, A. (2011). Compound local binary pattern (clbp) for robust facial expression recognition. In *Computational Intelligence* and Informatics (CINTI), 2011 IEEE 12th International Symposium on, pages 391– 395. IEEE.
- Ahonen, T., Hadid, A., and Pietikainen, M. (2006). Face description with local binary patterns: Application to face recognition. *IEEE transactions on pattern analysis and machine intelligence*, 28(12):2037–2041.



- Anusorn, C. B., Kongprawechnon, W., Kondo, T., Sintuwong, S., and Tungpimolrut, K. (2013). Image processing techniques for glaucoma detection using the cup-to-disc ratio. *Thammasat International Journal of Science and Technology*, 18(1):22–34.
- Bratkova, M., Boulos, S., and Shirley, P. (2009). orgb: a practical opponent color space for computer graphics. *IEEE Computer Graphics and Applications*, 29(1).
- Chimieski, B. F. and Fagundes, R. D. R. (2013). Association and classification data mining algorithms comparison over medical datasets. *Journal of health informatics*, 5(2).
- de Sousa, J. A., de Paiva, A. C., de Almeida, J. D. S., Silva, A. C., Junior, G. B., and Gattass, M. (2017). Texture based on geostatistic for glaucoma diagnosis from fundus eye image. *Multimedia Tools and Applications*, pages 1–18.
- Gonçalves, M. R., Guedes, M. d. M. R., Chaves, M. A. P. D., Pereira, C. C. d. L., and Otton, R. (2013). Analysis of risk factors and epidemiology of blindness prevention campaign by glaucoma in joão pessoa, paraíba. *Revista Brasileira de Oftalmologia*, 72(6):396–399.
- Gonzalez, R. C. E., Woods, S. L., Gonzalez, R. E. R. E. R. C., Woods, R. E., and Eddins, S. L. (2004). *Digital image processing using MATLAB*. Number 04; TA1637, G6.
- Hering, E. (1880). Zur Erklärung der Farbenblindheit aus der Theorie der Gegenfarben, volume 1. Tempsky.
- Penedo, M. G., Remeseiro, B., Ramos, L., Barreira, N., García-Resúa, C., Yebra-Pimentel, E., and Mosquera, A. (2014). Automatization of dry eye syndrome tests. *Image Analysis and Modeling in Ophthalmology*, page 293.
- Pinheiro, A. F., Almeida, J. D., Júnior, G. B., and Silva, A. C. (2015). Metodologia computacional para detecç ao automática do glaucoma em imagens de fundo de olho. *Biblioteca Digital Brasileira de Computação*.
- Ramos Neto, G. M., Junior, G. B., and Gattass (2016). Estudo de Variantes de Padrões Locais Binários para o Diagnóstico de Câncer de Mama. Monografia (Bacharel em Ciência da Computação), UFMA (Universidade Federal do Maranhão), São Luís, Brasil.
- Rivera, A. R., Castillo, J. A. R., and Chae, O. (2012). Recognition of face expressions using local principal texture pattern. In *Image Processing (ICIP)*, 2012 19th IEEE International Conference on, pages 2609–2612. IEEE.
- Trucco, E., Ruggeri, A., Karnowski, T., Giancardo, L., Chaum, E., Hubschman, J. P., Al-Diri, B., Cheung, C. Y., Wong, D., Abramoff, M., et al. (2013). Validating retinal fundus image analysis algorithms: Issues and a proposalvalidating retinal fundus image analysis algorithms. *Investigative ophthalmology & visual science*, 54(5):3546–3559.
- Van De Sande, K., Gevers, T., and Snoek, C. (2010). Evaluating color descriptors for object and scene recognition. *IEEE transactions on pattern analysis and machine intelligence*, 32(9):1582–1596.