

Diagnóstico do Glaucoma em Imagens de Fundo de Olho Usando Matriz de Coocorrência e SVM

Mayara Gomes Silva¹, Nelia Cantanhede Reis¹, João Dallyson Sousa de Almeida¹

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

{mayara, nelia.reis, joao.dallyson}@nca.ufma.br

Abstract. *Glaucoma is an eye disease that causes damage to the optic nerve and visual field, can lead to blindness. With the objective of diagnosing glaucoma based on retinography images, this work was elaborated by a methodology, with the RGB, LAB and YCrCb color standard. In order to extract the characteristics a Gray Level Co-Occurrence Matrix was used and as Halarick characteristics, the contrast; dissimilarity; homogeneity; energy; and angular momentum (ASM), and the SVM to classify as images. The results obtained are promising, the YCrCb space gave the best result with an accuracy of 88.04%.*

Resumo. *O glaucoma é uma doença ocular que provoca lesão no nervo óptico e campo visual, podendo levar à cegueira. Com o objetivo de diagnosticar o glaucoma baseado em imagens de retinografia, este trabalho desenvolveu uma metodologia, utilizando teste em três espaços de cores, o RGB, LAB e YCrCb. Para extrair as características foi utilizado a Matriz de Coocorrência de Níveis de Cinza e as características de Halarick, o contraste; dissimilaridade; homogeneidade; energia; correlação e segundo momento angular (ASM), e o SVM para classificar as imagens. Os resultados obtidos são promissores, o espaço YCrCb foi o que apresentou melhor resultado com acurácia de 88.04%.*

1. Introdução

O glaucoma é uma doença ocular que causa dano ao nervo óptico, cujo principal fator de risco é o aumento da pressão intraocular. Por ser uma doença progressiva e irreversível, se não for tratada leva gradativamente a perda total do campo visual [Gonçalves et al. 2013].

De acordo com a Organização Mundial de Saúde, o glaucoma é uma das principais causas de cegueira no mundo, sendo responsável por aproximadamente 5,2 milhões de casos de cegueira que equivale a 15% do total de cegueira mundial, e até 2020 pode chegar a 11,2 milhões de casos [Anusorn et al. 2013].

O glaucoma geralmente tende a ser hereditário sendo prevenido com acompanhamento da medição da pressão intraocular (pressão dentro do olho). A retinografia (fotografia de fundo de olho) é uma forma de se diagnosticar algumas doenças oculares como o glaucoma através do nervo óptico, sendo um dos principais exames oftalmológicos utilizados para a detecção de glaucoma. Esse diagnóstico do glaucoma também pode ser realizado através de um método computacional, realizado com processamento digital de imagens. O objetivo do processamento digital de imagens médicas consiste em melhorar o aspecto visual de certas feições estruturais para o analista humano, gerando novas imagens que podem novamente ser submetidas a outros processamentos [Sousa 2017]. As

principais formas de detecção são por segmentação da região do disco óptico e extração de características com técnicas de classificação.

A partir das imagens digitais de fundo de olho, Sousa (2017) propôs uma metodologia para diagnosticar o glaucoma utilizando funções geoestatísticas como: semivariograma, semimadograma, covariograma, correlograma. Inicialmente as imagens passaram por um pré-processamento no qual foram convertidas para nível de cinza e em seguida equalizadas. Para a representação da região do disco óptico foi aplicado o Padrão Binário Local (LBP) e funções geoestatísticas para descrever os padrões de textura.

Já Araújo et al. (2017) propôs um método de diagnóstico do glaucoma também com imagens de fundo de olho utilizando índices de diversidade de Shannon e McIntosh como descritores dos padrões de textura e support vector machine (SVM) para classificação. A aplicação dos índices de Shannon e McIntosh como descritores de textura mostrou-se eficaz alcançando como melhor resultado uma acurácia de 88,35%.

Este artigo teve como objetivo o estudo de uma metodologia computacional usando espaços de cores e Matriz de Coocorrência, para o auxílio do diagnóstico de glaucoma em imagens de retinografia.

2. Metodologia

Esta seção apresenta o método proposto para diagnosticar o glaucoma em imagens de retinografia. A metodologia é estruturada em três etapas: (1) pré-processamento, (2) extração de características, (3) classificação e validação. A Figura 1 apresenta as etapas da metodologia.

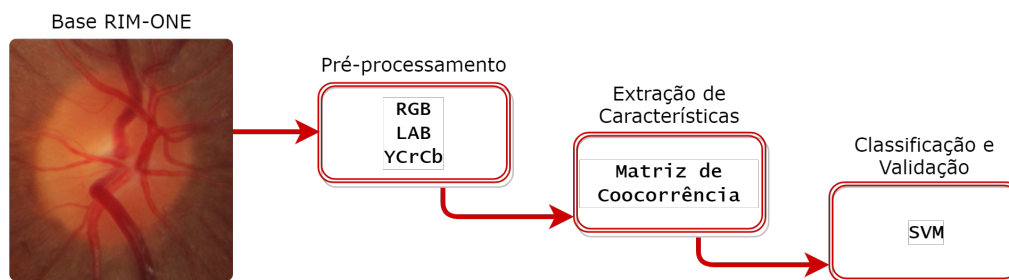


Figura 1. Etapas do método proposto

Base de imagens - A base utilizada neste trabalho foi a RIM-ONE [Trucco et al. 2013], que é disponibilizada com imagens fornecidas por três hospitais: Hospital Universitário de Canarias, Hospital Clínico San Carlos e Hospital Universitário Miguel Servet. 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).

2.1. Pré-processamento

A etapa de pré-processamento teve como objetivo evidenciar as características da região do disco óptico (DO) e da cavidade do disco óptico (CDO), como preparação para a fase




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

de extração de características. Então com a imagem original foram testados os esquemas de cores RGB, Lab e YCrCb. Para cada espaço de cor foram utilizados os canais separadamente, assim obtendo três imagens em níveis de cinza.

2.2. Extração de Características

Após o pré-processamento as imagens foram submetidas a extração de características. Essas características, ou seja, atributos são propriedades presentes em objetos registrados nas imagens, que podem ser usados como descritores da imagem [Silva et al. 2017]. Existem várias técnicas para a extração dessas características, neste trabalho foi utilizada a Matriz de Coocorrência de Níveis de Cinza (do inglês Grey-Level Co-occurrence Matrix (GLCM)) para descrever a textura das regiões do disco óptico.

A GLCM é uma técnica com base na análise de textura de imagens, que utiliza imagens em nível de cinza, analisando as coocorrências existentes entre pares de pixels através de algum padrão [Haralick et al. 1973]. Os cálculos da matriz são obtidos através da probabilidades de coocorrências entre dois níveis de cinza i e j , utilizando uma orientação Q (0° , 45° , 90° e 135°) e uma distância (espaçamento entre pares de pixels) [Silva et al. 2017]. Para cada relacionamento espacial possível (distância e orientação) existe uma matriz de coocorrência. Assim, as informações sobre a textura da imagem estarão contidas nessa matriz [Baraldi and Parmiggiani 1995]. A partir da matriz gerada pode-se extrair algumas características significativas. Haralick (1973) definiu 14 características para a GLCM, sendo que utilizando apenas algumas dessas características pode gerar melhor desempenho do que a utilização de todas.

Assim, através de testes empíricos os melhores parâmetros em relação a orientação foram de 0° , 45° , 90° e 135° . Para cada grau são extraídas as seguintes características: contraste, dissimilaridade, homogeneidade, energia, correlação e segundo momento angular (ASM). Após a extração de características geradas das três imagens resultantes dos espaços de cores, todas as informações obtidas foram agrupadas em um vetor de escalares denominado vetor de características, resultando 72 atributos para cada instância.

2.3. Classificação

Esta etapa tem o objetivo de realizar o reconhecimento das imagens, classificando-as em saudáveis e glaucomatosas. Após o pré-processamento e a extração de características, os dados são fragmentados em dois subconjuntos, denominados base de treinamento e base de testes. Para tal, utilizou-se a técnica de Validação Cruzada que consiste em dividir a base de dados em x partes (folds), sendo destas, $x-1$ partes são utilizadas para o

treinamento e uma serve como base de testes [Santos et al. 2004]. Para a classificação foi utilizado a Máquina de Vetor de Suporte, do inglês Support Vectors Machine - SVM [Cortes and Vapnik 1995].

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 validação cruzada, com k-folds 10. O SVM foi utilizado com Função de Base Radial (RBF), os parâmetros C e gama foram estimados pelo *grid search* (busca exaustiva).

2.4. Validação dos Resultados

O objetivo dessa etapa consiste em medir o desempenho e promover a validação dos resultados obtidos. Segundo Barradas e Viegas (2018) os parâmetros de avaliação para métodos de classificação são baseados em taxas obtidas da matriz de confusão. Para avaliação dos resultados foram utilizadas as medidas de Acurácia, Sensibilidade, Especificidade, Precisão e Kappa. A Sensibilidade é o número de imagens corretamente classificadas como glaucomatosas; Especificidade é o número de imagens classificadas corretamente como saudáveis; Acurácia é a proporção total dos resultados corretos [Chimieski and Fagundes 2013]; a precisão indica o quão bom esse teste é para identificar padrões malignos; e o Kappa [Landis and Koch 1977].

3. Resultados e Discussão

O método proposto teve como objetivo 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, glaucomatosas e suspeitas ou normais. Para todos os testes de validação cruzada foram realizados 5 repetições. A Tabela 1 apresenta a média do resultado dessas execuções, informando a Acurácia (ACU), Sensibilidade (SEN), Especificidade (ESP), Precisão (P) e Kappa.

Tabela 1. Resultados do método proposto

Espaço	ACU	SEN	ESP	P	Kappa
RGB	85.22 ± 0.25	83.70 ± 0.77	85.63 ± 0.83	85.20 ± 0.27	0.69 ± 0.01
Lab	85.93 ± 0.36	85.14 ± 0.40	86.52 ± 0.60	85.80 ± 0.61	0.70 ± 0.01
YCrCb	88.04 ± 0.43	86.98 ± 0.60	89.54 ± 0.99	88.04 ± 0.42	0.75 ± 0.01

Pela análise dos resultados da classificação apresentados na Tabela 1, podemos concluir que a acurácia com o melhor resultados foi o YCrCb com 88.04%. Considerando a sensibilidade e especificidade, este também obteve melhor desempenho comparando aos outros espaços de cores, e observa-se que tende a classificar melhor as imagens saudáveis, pois a especificidade (89.54%) foi relativamente melhor que a sensibilidade (86.98%). O desvio padrão foi consistentemente baixo para todas as métricas em todos os espaços de cores RGB e Lab. Enquanto para YCrCb a sensibilidade, a acurácia e a precisão foi um pouco maior em relação aos outros espaços de cores, mostrando uma variação maior entre os dados.

A precisão de todos os métodos tiveram bons resultados, acima de 80%, mostrando que a metodologia proposta é promissora para identificar padrões malignos. De

acordo com o nível de exatidão do índice Kappa estabelecido por Landis et al. (1977), os resultados de todos os espaços de cores são considerados muito bom, pois estão entre 0.6 a 0.8, assim provando a eficiência da extração de características.

4. Considerações Finais

Esse trabalho apresentou uma forma de detecção automática do glaucoma em imagens do fundo de olho da retina utilizando os espaços de cores RGB; LAB; YCrCb e extraíndo características com a GLCM. Seus resultados foram avaliados separadamente, e obtiveram resultados aceitáveis. Onde o classificador SVM atingiu cerca de 88% de acurácia, totalizando um kappa de 0.75 no espaço de cor YCrCb.

Como trabalhos futuros, a fim de ampliar e melhorar os resultados, pretendemos buscar outras bases de retinografia como a Drishti-GS; utilizar outros métodos de pré-processamento como as cores opostas; usar outros descritores de características de Haralick; testar outros métodos de aprendizagem de máquina como o Random Forest.

Referências

- 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.
- Araujo, J. D. L., de Paiva, A. C., de Almeida, J. D. S., Silva, S. Neto, O. P. a. A. C., de Sousa, J. A., Junior, G. B., and Gattass (2017). Diagnóstico de glaucoma em imagens de fundo de olho utilizando os índices de diversidade de shannon e mcintosh. *XVII Workshop de Informática Médica*.
- Baraldi, A. and Parmiggiani, F. (1995). An investigation of the textural characteristics associated with gray level cooccurrence matrix statistical parameters. *IEEE Transactions on Geoscience and Remote Sensing*, 33(2):293–304.
- Barradas Filho, A. O. and Viegas, I. M. A. (2018). Applications of artificial neural networks in biofuels. In *Advanced Applications for Artificial Neural Networks*. In-Tech.
- 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).
- Cortes, C. and Vapnik, V. (1995). Support-vector networks. *Machine learning*, 20(3):273–297.
- 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.
- Haralick, R. M., Shanmugam, K., Dinstein, I., et al. (1973). Textural features for image classification. *IEEE Transactions on systems, man, and cybernetics*, 3(6):610–621.

- Landis, J. R. and Koch, G. G. (1977). The measurement of observer agreement for categorical data. *biometrics*, pages 159–174.
- Santos, L. D. M., Mikami, R., Vendramin, A. C. B. K., and Kaestner, C. A. A. (2004). Procedimentos de validação cruzada em mineração de dados para ambiente de computação paralela.
- Silva, R. R., Lopes, J. G., and Araújo, F. H. (2017). Visão computacional em python utilizando as bi-bibliotecas scikit-image e scikit-learn. pages 407–428.
- Sousa, J. A. d. (2017). Diagnóstico de glaucoma em retinografias utilizando funções geoestatística. Dissertação (Mestrado) - Universidade Federal do Maranhão, Curso de Pós Graduação em Ciência da Computação, São Luís, MA.
- 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 proposal validating retinal fundus image analysis algorithms. *Investigative ophthalmology & visual science*, 54(5):3546–3559.