

Detecção automática de glaucoma através de contornos ativos e características de textura

Danilo Alves Oiveira¹, Edivan de Souza Nunes², Iális Cavalcante de Paula Júnior¹

¹ Programa de Pós-graduação em Engenharia Elétrica e Computação – Universidade Federal do Ceará. (UFC) – Sobral – CE – Brasil

² Graduação em Análise de Sistemas – Universidade Norte do Paraná. (UNOPAR) – Sobral – CE – Brasil

{daniloreriutaba, edivannsouza84}@gmail.com, ialis@sobral.ufc.br

Abstract. *Glaucoma is one of the leading causes of blindness worldwide. This pathology has no cure and its treatment in the early stages is fundamental to avoid loss of vision. In these cases, computer systems can be used to aid diagnosis. Thus, this study aims to develop an efficient method for detecting glaucoma. The proposal uses new approaches to image preparation, active contour segmentation and extraction of Local Binary Pattern (LBP) texture features. Finally, the classification is performed, validating the methodology. The results were significant, showing better metrics to the Artificial Neural Network, with accuracy of 96.13%, sensitivity of 94.17%, specificity of 98.13%, and kappa statistic of 0.922.*

Resumo. *O glaucoma é uma das principais causas de cegueira mundial. Essa patologia não possui cura e seu tratamento em estágios iniciais é fundamental para evitar a perda de visão. Nesses casos, sistemas computacionais podem ser utilizados para auxílio ao diagnóstico. Nesse sentido, este estudo tem como objetivo desenvolver um método eficiente para detecção de glaucoma. A proposta utiliza novas abordagens para preparação da imagem, segmentação com contornos ativos e extração de características de textura Local Binary Pattern (LBP). Por fim, a classificação é realizada, validando a metodologia. Os resultados foram significativos, demonstrando melhores métricas a Rede Neural Artificial, com acurácia de 96,13%, sensibilidade de 94,17%, especificidade de 98,13% e estatística kappa de 0,922.*

1. Introdução

Glaucoma (ou glaucose) é uma doença oftalmológica com numerosas referências na literatura médica antiga. Embora seja estudado desde a antiguidade como um tipo de catarata, continua sendo uma das doenças mais pesquisadas atualmente [Rodrigues 2012].

Esta patologia pode ser definida como uma neuropatia degenerativa progressiva, que resulta na morte das células ganglionares da retina e conseqüente redução no campo visual. Embora não esteja totalmente difundido as causas do glaucoma, existem vários fatores de riscos que estão relacionados ao seu desenvolvimento, tais como genes, etnia, idade e um aumento da pressão intraocular (PIO) [Doucette *et al.* 2015].

É considerado a segunda maior causa de cegueira na população mundial e a mais irreversível no mundo. Segundo dados da Organização Mundial de Saúde (OMS), o glaucoma é responsável por 13% da cegueira global e a cada ano surgem mais 2,4 milhões

de casos novos. O número de pessoas com deficiências visuais tende a crescer globalmente, em 2020 estima-se 38,5 milhões de pessoas e em 2050 esse grupo somará 115 milhões de pessoas [WHO 2012].

Embora exista avanços tecnológicos para a propedêutica do glaucoma, a principal estratégia para a detecção desta enfermidade ainda é por meio de um exame oftalmológico de rotina [Rodrigues *et al.* 1998]. A OMS acredita que em países em desenvolvimento, como o Brasil, 80% da cegueira se detectada e tratada em tempo hábil, poderia ser prevenida ou curada [WHO 2012].

A forma mais comum de identificação é através da análise de imagens da retina, em que o especialista terá que identificar o acúmulo do líquido ao redor do Disco Óptico (DO) e informar se indica ou não Glaucoma [Liu *et al.* 2011]. Para que seja detectado precocemente e evitar a subjetividade do especialista, diversas pesquisas foram desenvolvidas na área de engenharia biomédica. Estas relacionam técnicas computacionais avançadas de Visão Computacional e Inteligência Artificial para a detecção automática do glaucoma, fornecendo sistemas de auxílio ao diagnóstico [Faust *et al.* 2013; Lamani *et al.* 2014].

Nesse sentido, este trabalho apresenta um método de detecção automática de glaucoma, através do processamento das imagens de retina. Utilizando a técnica de contornos ativos para segmentação do DO, extração de características de textura com *Local Binary Pattern* (LBP) e a classificação dos atributos com algoritmos de aprendizagem de máquina, buscando validar o desempenho do método.

2. Trabalhos Relacionados

Diversas pesquisas foram realizadas buscando sistemas automáticos capazes de identificar o glaucoma. A seguir são apresentados alguns trabalhos com este propósito.

Faust *et al.* (2013) desenvolveram um sistema para identificação automática de classes glaucomosas, utilizando características de espectro de ordem superior (HOS), transformação de traço (TT) e transformada em onda discreta. Além disso, propuseram um novo índice integrado, chamado Índice de Risco de Glaucoma (GRI), que é composto pelas características extraídas. O sistema utiliza classificação final com o classificador *Support Vector Machine* (SVM) e apresenta Acurácia de 91,67%, Sensibilidade de 90% e Especificidade de 93,33%.

Lamani *et al.* (2014) propuseram um método de classificação de camadas fibrosas de retina como glaucomatosas ou não glaucomatosa. Na proposta, foram utilizados descritores de textura e fractal, obtidos do canal vermelho da imagem RGB. Após essas técnicas, é realizada a classificação utilizando o algoritmo SVM, e obteve-se que, mesmo com 40% de perda, ainda é possível detectar Glaucoma na proposta.

Sengar *et al.* (2017) propuseram um algoritmo para detectar regiões suspeitas de Glaucoma, usando a presença ou ausência de hemorragias em uma região perto do disco óptico. A abordagem utiliza limitações adaptativas e características de geometria para segmentar a região buscada. Os resultados apresentaram Acurácia de 93,57% na base testada.

Pela revisão de literatura, percebe-se que o desenvolvimento de sistemas para auxílio ao diagnóstico do glaucoma tem sido um tema de interesse e busca recente da comunidade científica.

3. Fundamentação Teórica

Nesta seção, são abordadas as bases teóricas dos procedimentos utilizados na pesquisa, justificando a metodologia aplicada. Apresenta-se a técnica de contornos ativos, a característica de textura LBP e fundamentos de aprendizagem de máquina.

3.1. Contornos Ativos

Os contornos ativos são métodos variacionais de segmentação, baseados em modelos deformáveis e funcionais de energia. Possuem como objetivo a redução de uma função de custo, diferindo na definição da continuidade e suavidade do contorno [Henriques 2015].

Um destes métodos é o de Chan-Vese, neste modelo é buscado a minimização de energia em uma curva, para atingir a fronteira que separa o domínio da imagem na região externa e interna da curva [Chan e Vese 2001]. Sendo F a energia funcional, u a imagem com domínio dividido pela curva nas regiões internas Ω_1 e externas Ω_2 , a funcional é calculada como:

$$F = \int_{\Omega_1} |u(x, y) - c_1|^2 dx dy + \int_{\Omega_2} |u(x, y) - c_2|^2 dx dy, \quad (1)$$

onde c_1 e c_2 são os valor médios de pixels da região Ω_1 e Ω_2 , respectivamente.

3.2. Local Binary Patterns

O LBP é um algoritmo que busca representar matematicamente a textura de uma imagem. É considerado robusto em termos das variações de cinza e pode ser obtido através de algumas operações na área de vizinhança do pixel analisado. [Ojala *et al.* 2002].

Este operador detecta padrões binários locais uniformes em vizinhanças circulares, independente da quantização do espaço. Um código LBP é um número binário gerado através de uma análise simples da vizinhança de cada pixel na imagem. Este é a descrição de textura que atribui uma etiqueta para cada pixel. Utilizando esse número binário, é conferido o padrão uniforme, verificando se o número possui no máximo duas transições de bits 0-1 ou vice-versa [Ojala *et al.* 2002].

Na composição do histograma de características são utilizados somente os padrões uniformes. O cálculo do LBP é representado na equação 3, em que g_c é o valor de cinza do pixel central, g_p é o valor de seus vizinhos, p é o valor do vizinho corrente, R é a medida do raio da vizinhança e s é a função de limiarização.

$$LBP_{P,R} = \sum_{p=0}^{p-1} s(g_p - g_c) 2^p \quad (2)$$

$$s = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (3)$$

3.3. Aprendizagem de Máquina

O Aprendizado de Máquina é um ramo da Inteligência Artificial que busca processar e agrupar dados, buscando a classificação das informações e o reconhecimento de padrões. Existem diversos métodos de aprendizado, entre eles a aprendizagem por hábito, em que o algoritmo associa o modelo dos dados através da experiência, com o que foi informado anteriormente [Coppin 2010]. Este é conhecido como aprendizagem supervisionada.

Nesse método, os dados são conhecidos *a priori* com classes e atributos rotulados, o algoritmo deve extrair o modelo do conhecimento a partir desses exemplos. Com isso, espera-se que a representação formulada consiga fornecer saídas corretas para entradas não apresentadas antes [Pellucci *et al.* 2011].

4. Metodologia

Para atingir a proposta desse trabalho é necessário segmentar o DO, a fim de extrair as características de textura e utilizar os classificadores para identificar o glaucoma. Essa metodologia é realizada com o software MATLAB, suas etapas são demonstradas na Figura 1.




Figura 1. Metodologia da proposta.

4.1. Aquisição de Imagens

As imagens para o projeto foram obtidas através do banco RIM-ONE na versão 1, a mais utilizada na literatura. Este repositório público apresenta 169 exames digitais de fundo de olho da retina. Neles indicam exames saudáveis e com glaucoma, retirados de pacientes do Hospital Universitário de Canarias, Hospital Clínico San Carlos e Hospital Universitário Miguel Servet.

4.2. Segmentação

A segmentação é realizada com o algoritmo de contornos ativos, para isso é necessária uma máscara inicial com a região de interesse interna. Dessa forma, a fim de obter essa máscara, é utilizado uma alteração de contraste na imagem original, como demonstra a Figura 2(a).




Figura 2. Segmentação do DO.

Esse ajuste de contraste utiliza saturação de 1% e baseia-se no padrão do DO ser mais claro que o fundo da retina, assim essa diferença se torna mais evidente. Com isso, são verificadas linhas e colunas dos quatro lados da imagem, buscando a maior

intensidade de pixels brancos. A interseção dessas marcações fornece a máscara da segmentação, ilustrada na Figura 2(b).

Na região dessa máscara é aplicado o algoritmo de contornos ativos de Chan-Vese, e obtido a segmentação do DO. A Figura 2(c) demonstra a interseção das imagens.

4.3. Extração de atributos

As imagens segmentadas são processadas e a partir destas, são extraídos os atributos de textura LBP. A janela utilizada para a composição dos histogramas é de 21x21, com ela é realizando a convolução na imagem. Através das interações obtidas 76000 amostras, que são utilizadas como dados para treino e teste dos algoritmos de classificação.

4.4. Classificação

Com as características obtidas na etapa anterior, os dados são fornecidos para classificação. Os algoritmos utilizados são a Rede Neural Artificial do tipo *Multilayer Perceptron* (MLP) com ativação sigmóidal e 30 neurônios na camada oculta, o *K-Nearest Neighbors* (KNN) com $k=5$, e o *Support Vector Machine* (SVM) com função de *kernel* gaussiana. O treinamento é realizado com 70% dos dados para treino e 30% para teste e validação.

As métricas avaliadas na pesquisa são a Acurácia, que é a proporção total de acertos da amostra, a Sensibilidade, que representa a capacidade de classificar corretamente amostras doentes, e a Especificidade, representando a capacidade de classificar corretamente amostras saudáveis. Também é avaliado o índice Kappa, uma métrica baseada no número de respostas concordantes dos dados observados.

5. Resultados

Os algoritmos foram executados 20 vezes, com amostras aleatórias, e a percentagem dos resultados médios obtidos são apresentados na Tabela 1.

Tabela 1. Resultados dos classificadores

Classificador	Acurácia	Sensibilidade	Especificidade	Kappa
MLP	96,13%	94,17%	98,13%	0,922
KNN	92,71%	91,20%	94,31%	0,854
SVM	95,04%	97,83%	92,24%	0,900

Com base nesta, podemos observar que a rede neural MLP apresentou maior eficiência na maioria das métricas analisadas. Denotando Acurácia de 96,3%, que representa o total de acertos geral, Sensibilidade de 94,17%, demonstrando a habilidade de identificar corretamente amostras glaucomosas, e Especificidade de 98,78%, demonstrando a habilidade de identificar amostras saudáveis.

O SVM apresentou a segunda melhor classificação, com valor de Acurácia próximo ao da RNA e Sensibilidade superior aos demais. O KNN obteve Especificidade superior ao SVM, mas nas demais estatísticas apresentou os menores percentuais, demonstrando que o critério de considerar proximidades no espaço não aplica-se bem ao problema. Pela estatística Kappa, todos os classificadores obtiveram concordância excelente entre as 20 observações, possuindo valores acima de 0,8.

6. Conclusões e Trabalhos Futuros

Neste trabalho, apresentou-se um método para detecção automática de glaucoma, com técnicas de contornos ativos e característica de textura LBP. Alguns algoritmos clássicos de aprendizagem de máquinas foram utilizados para validação da proposta, com a MLP obtendo os melhores percentuais. Os resultados foram promissores, demonstrando que o método proposto é adequado para a detecção do glaucoma.

Para trabalhos futuros, pretende-se realizar mais observações com outros classificadores e aprimorar o método em um sistema funcional gráfico, para uso clínico.

Referências

- Chan, T., Vese, L. (2001) “Active contours without edges”, IEEE Trans. Image Processing, v. 10, p. 266–277.
- Coppin, Ben. (2010) “Inteligência artificial”, Rio de Janeiro: LTC.
- Doucette, L. P., Rasnitsyn, A., Seifi, M., Walter, M. A. (2015) “The Interactions of Genes, Age, and Environment in Glaucoma Pathogenesis”. Survey of Ophthalmology, v. 60, n. 4, p. 310-326.
- Faust, O., Mookiah, M. R. K. (2013) “Automated glaucoma detection using hybrid feature extraction in retinal fundus images”, Journal of Mechanics in Medicine and Biology, v. 13, n. 1.
- Henriques, H. A. M. (2015) “Caraterização do fluxo sanguíneo de uma bifurcação da artéria carótida comum com estenose”, Dissertação, Universidade do Porto.
- Lamani, D., Manjunath, T., Mahesh, M., Nijagunarya, Y. (2014). “Early detection of glaucoma through retinal nerve fiber layer analysis using fractal dimension and texture feature. International Journal of Research in Engineering and Technology”, v. 3, n. 10, p. 158-163.
- Liu, J., Yin, F., Wong, D., Zhang, Z., Tan, N., Cheung, C., Baskaran, M., Aung, T. and Wong, T. (2011). “Automatic glaucoma diagnosis from fundus image”, Engineering in Medicine and Biology Society, EMBC, Annual International Conference of the IEEE, p. 3383–3386.
- Pellucci, P. R. S., Paula, R. R. de, Silva, W. B. de O., Ladeira, A. P. (2011) “Utilização de técnicas de aprendizado de máquina no reconhecimento de entidades nomeadas no português”, E-xacta, v. 4, n. 1, p. 73-81.
- Rodrigues, A. C., Silva, M. R. B. M., Schellini, A. S. (1998) “Número de olhos cegos por glaucoma detectados em primeira consulta num hospital universitário”. Arquivos Brasileiros de Oftalmologia, v. 61, n. 5, p. 573-578.
- Rodrigues, L., T., R. (2012) “Glaucoma e sua componente genética”, Dissertação, Universidade da Beira Interior.
- Sengar, N., Dutta, M. K., Burget, R., Ranjoha, M. (2017) “Automated detection of suspected glaucoma in digital fundus images”, 40th International Conference on Telecommunications and Signal Processing (TSP), p. 749-752.
- WHO. (2012) “Global data on visual impairments 2010”. World Health Organization. Geneva.