

# Método Automático para Classificação do Glaucoma Usando Análise de Textura, Xgboost e Grid search

Nonato R. de S. Carvalho<sup>1</sup>, Antônio O. de C. Filho<sup>1</sup>,  
Francisco das C. dos A. C. Júnior<sup>1</sup>, Deusimar D. de Sousa<sup>1</sup>, Rafael L. Araújo<sup>1</sup>,  
Maria da C. L. C. Rodrigues<sup>2</sup>, Thiago J. B. Lima<sup>1</sup>, Pablo de A. Vieira<sup>1</sup>

<sup>1</sup>Universidade Federal do Piauí (UFPI)

{franciscojn49, sousadeusimar2, thiagojbl2, pablolukan}@gmail.com

{nrdesales, antoniooseas, rafaluzaraujo}@ufpi.edu.br

<sup>2</sup>Instituto Federal do Piauí (IFPI)

mariacarvalhoadm@gmail.com

**Abstract.** *Glaucoma is an irreversible pathology, generated by increased intra-ocular pressure. Early detection is critical and can prevent total vision loss. Clinical examinations are commonly used to detect the disease. Still, the time and cost of identification is quite high. This paper presents a computational methodology that aims to assist specialists in the discovery of glaucoma through Computer Vision techniques. The proposed methodology consists in the application of several texture descriptors combined with a parameter optimization done through Grid search with the XGBoost classifier. A result was obtained with accuracy of 82.37% and ROC of 82.08%.*

**Resumo.** *O Glaucoma é uma patologia irreversível, gerada pelo aumento da pressão intra-ocular. A detecção precoce é fundamental e pode evitar a perda total da visão. Exames clínicos são comumente utilizados na detecção da doença. Ainda assim, o tempo e o custo gasto na identificação são bastante elevados. Este trabalho apresenta uma metodologia computacional que visa auxiliar especialistas na descoberta do glaucoma por meio de técnicas de Visão Computacional. A metodologia proposta consiste na aplicação de vários descritores de textura combinados com uma otimização de parâmetros feita através do Grid search com o classificador XGBoost. Obteve-se um resultado com Acurácia de 82,37% e ROC de 82,08%.*

## 1. Introdução

O glaucoma pode ser definido como uma neuropatia óptica, a qual pode comprometer toda a estrutura do nervo óptico, causar dano ao sistema nervoso e também aumentar a pressão intraocular [Lim and Goldberg 2010]. A Organização Mundial da Saúde (OMS) informa que o glaucoma é a segunda maior causa de cegueira irreversível no mundo [Resnikoff et al. 2004]. Estudos revelam que em 2020 mais de 79 milhões de pessoas poderão ser portadores do glaucoma [Ayub et al. 2016].

O glaucoma é assintomático em seus estágios iniciais. Muitos pacientes não sabem da doença até que ela alcance estágios avançados, razão pela qual é importante um diagnóstico precoce que possibilite o tratamento no tempo adequado

[de Carvalho Junior et al. 2018]. Estatisticamente o aumento da pressão intraocular não indica a presença do glaucoma, porém a pressão intraocular normal não exclui a presença da doença. Isso implica que o diagnóstico do glaucoma deve ser baseado principalmente na análise do disco óptico por meio de imagens do fundo do olho [Loewen and Tanna 2010].

Diagnósticos de doenças na área da oftalmologia necessitam de análise de grandes quantidades de imagens. O processo da análise de imagens para o diagnóstico do glaucoma ainda é feito manualmente de forma demorada e subjetiva. Além disso os resultados podem variar entre profissionais, tendo uma carga de trabalho bastante elevada [Severo 2014].

Nesse contexto, este trabalho apresenta um método automático que aplica os descritores *Gray-Level Co-Occurrence Matrix* (GLCM) e *Local Binary Pattern* (LBP), combinados com estimador de parâmetros *Grid search* e classificador *Extreme Gradient Boosting* (Xgboost), com intuito de prover uma melhoria na classificação de imagens glaucomatosas e saudáveis.

## 2. Trabalhos Relacionados

Estudos conhecidos sobre o problema da classificação de imagens do fundo do olho vêm se tornando relevantes com o passar dos anos e se popularizando no meio científico. A Tabela 1 mostra um resumo das principais informações dos trabalhos relacionados para a classificação de imagens glaucomatosas.

Tabela 1. Trabalhos Relacionados.

Trabalho	Técnicas usadas	Base	Amostra	Acurácia
[Li et al. 2018]	<i>Deep learning</i>	Variadas clínicas chinesas	48.116	92,9%
[Claro et al. 2018]	Uso de descritores de textura e <i>Convolutional Neural Network</i> (CNN)	DRISHTI e RIM-ONE em suas 3 versões	873	91,06%
[Araujo et al. 2018]	Índices de Diversidade	RIM-ONE versão 2	455	93,41%
[Fernandes et al. 2019]	Decomposição de Imagens e Otimização Bayesiana	RIM-ONE versão 2	455	91,24%

## 3. Metodologia

Nesta seção expomos a metodologia utilizada para desenvolver o método proposto. A Figura 1 apresenta um resumo das etapas seguidas: Aquisição de imagens, Extração de características, Classificação e Métricas de validação.




Figura 1. Metodologia Proposta.

### 3.1. Aquisição das Imagens

A base utilizada para este trabalho foi a RIM-ONE r2 [RIMONE 2015], composta por 455 imagens da retina. O processo de diagnóstico prévio foi realizado por especialistas, que determinaram um conjunto de 200 imagens com glaucoma e 255 imagens saudáveis. Para uso do método proposto, as regiões do Disco Óptico foram segmentadas a partir de máscaras disponibilizadas por especialistas da própria base.

### 3.2. Pré-processamento

Nessa etapa foi utilizada a transformação de intensidade logarítmica para realce de imagens, aumentando o contraste de faixas de intensidades ou até binarizando as imagens. Essa transformação mapeia uma faixa estreita de baixos valores de intensidade de entrada em uma faixa mais ampla de níveis de saída, a qual pode ser expressa na Equação 1 [Gonzalez and Woods 2010] em que, no método proposto,  $C = 80$ .

$$S = C * \log(1 + r) \quad (1)$$

### 3.3. Extração de Características

No método proposto, foram utilizados descritores que extraem informações relacionadas a: distribuição espacial, variação de luminosidade, suavidade, rugosidade, regularidade, estruturas de superfícies e as relações entre os pixels próximos [Oliveira 2016].

O GLCM é um descritor de textura que analisa as concorrências entre pares de pixels, armazenando suas intensidades relativas em uma matriz quadrada. As probabilidades de coocorrências são calculadas entre dois níveis de cinza  $i$  e  $j$ , usando como parâmetros os ângulos ( $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  e  $135^\circ$ ) e uma distância nomeada como espaçamento de pares de pixels [Haralick et al. 1973].

O LBP é empregado na extração de características no processo de reconhecimento e classificação de imagens. Neste método a intensidade de cada pixel de uma imagem é substituída por um vetor binário, determinado pela comparação de cada pixel vizinho com o pixel central, onde o tamanho da vizinhança é de  $3 \times 3$ , constituindo o valor limite padrão. Os valores obtidos por vizinhos são concatenados e o número binário gerado é convertido na base decimal para substituir o valor central [Ojala et al. 1996].

### 3.4. Classificação

Após o processo de caracterização das imagens, aplicamos a classificação das características extraídas. Este processo é feito com e sem a otimização dos parâmetros através do *Grid search* e o classificador *Extreme Gradient Boosting*, utilizando o método de validação cruzada.

**Grid search** implementa um método de "fit" e "score". Também implementa "predict", "predict\_proba", "decision\_function", "transform" e "inverse\_transform" se eles forem implementados no estimador usado. Os parâmetros do estimador usado para aplicar esses métodos são otimizados pela pesquisa de *cross-validated grid search* sobre uma *grid* de parâmetros [Lerman 1980].

**XGBoost** o algoritmo *XGBoost* ou "*Extreme Gradient Boosting*" é baseado na técnica de *gradient boosting machine* (GBM) [Friedman 2001] e pode ser aplicado no contexto de aprendizagem supervisionada. O método utiliza os preditores (árvores) que minimizem a função de perda escolhida. A função de perda é composta por dois fatores: uma taxa de erro calculada sobre a validação e um fator de regularização. *XGBoost* é escalável e seus detalhes estão descritos em [Chen and Guestrin 2016].

**Validação cruzada** é uma técnica computacional intensiva, que usa todos os exemplos disponíveis de amostras de treinamento e teste. Esse tipo de estimativa de desempenho insuficiente carece de eficiência computacional devido ao processo de treinamento ser repetitivo, mas o objetivo final é diminuir a variação da estimativa [Stone 1974].

### 3.5. Métricas de Validação

Para avaliar o desempenho do método proposto serão utilizadas as métricas de avaliação: sensibilidade, especificidade, acurácia [Bland 2015], Kappa [Cohen 1968] e *Receiver Operating Characteristic* (ROC) [MATOS 2017].

## 4. Resultados

Após a aquisição das imagens (Seção 3.1) e o pré-processamento (Seção 3.2), realizamos os testes para avaliação do método proposto. Os testes foram realizados em um conjunto de 455 imagens, sendo 200 glaucomatosas e 255 saudáveis. As Tabelas 2 e 3 apresentam os resultados.

Tabela 2. Resultados da classificação aplicando o descritor GLCM e Transformações de Intensidade Logarítmica.

Canal	Sem <i>Grid Search</i>					Com <i>Grid Search</i>				
	A (%)	S (%)	E (%)	ROC (%)	K (%)	A (%)	S (%)	E (%)	ROC (%)	K (%)
Verde	70,27	67,53	73,00	70,27	40,28	71,80	68,18	74,60	71,39	42,74
	69,85	66,00	73,70	69,85	39,77	70,04	65,84	73,41	69,62	39,29
	69,37	66,15	72,58	69,37	38,61	68,94	65,44	71,48	68,46	36,69
Vermelho	75,55	73,29	77,18	75,24	50,16	<b>76,87</b>	<b>75,67</b>	<b>77,69</b>	<b>76,68</b>	<b>52,70</b>
	<b>75,77</b>	<b>75,56</b>	<b>75,89</b>	<b>75,73</b>	<b>50,21</b>	73,78	71,20	75,66	73,34	46,56
	75,77	75,56	75,89	75,73	50,21	73,78	71,20	75,66	73,24	46,56
Azul	70,04	66,84	72,34	69,59	38,90	71,14	69,71	72,04	70,87	40,67
	68,28	65,21	70,37	67,79	35,10	70,48	67,18	72,90	70,04	39,86
	68,28	65,21	70,37	67,79	35,10	68,72	65,42	71,05	68,23	36,13

Com base nos dados apresentados na Tabela 2, utilizando o descritor GLCM o melhor resultado obtido foi no canal vermelho com os parâmetros de: distância = 1 e ângulo = 90°. Sem aplicar o *Grid search*, obteve-se uma acurácia de 75,77% e ROC de 75,73%. Com o *Grid search*, obteve-se uma acurácia de 76,87% e ROC de 76,68%.

Com base nos dados apresentados na Tabela 3, utilizando o descritor LBP o melhor resultado obtido foi no canal verde com os parâmetros: raio = 5 e número de vizinhos = 10. Sem aplicar o *Grid search*, obteve-se uma acurácia de 81,71% e ROC de 81,43%. Com o *Grid search*, obteve-se uma acurácia de 82,37% e ROC de 82,08%.

Os resultados obtidos com o método proposto indicam que a validação cruzada aliada ao *grid search* apresenta melhores resultados nos canais verde e vermelho. Cada canal da imagem do Disco Óptico (DO) é capaz de produzir uma representação diferente

Tabela 3. Resultados da classificação aplicando o descritor LBP e Transformações de Intensidade Logarítmica.

Canal	Sem Grid Search					Com Grid Search				
	A (%)	S (%)	E (%)	ROC (%)	K (%)	A (%)	S (%)	E (%)	ROC (%)	K (%)
Verde	<b>81,71</b>	<b>77,61</b>	<b>85,24</b>	<b>81,43</b>	<b>63,09</b>	<b>82,37</b>	<b>78,74</b>	<b>85,42</b>	<b>82,08</b>	<b>64,37</b>
	80,61	77,33	83,26	80,30	60,72	82,37	79,60	84,58	82,09	64,25
	80,61	80,00	81,04	80,52	60,32	80,39	76,69	83,46	80,08	60,34
Vermelho	76,43	72,54	79,60	76,07	52,26	75,55	72,68	77,69	75,18	50,20
	76,43	72,54	79,60	76,07	52,26	75,11	71,68	78,17	74,73	49,53
	75,77	71,49	79,35	75,42	51,00	74,88	70,33	78,77	74,55	49,28
Azul	77,75	72,68	82,35	77,51	55,23	77,97	72,81	82,70	77,75	55,70
	75,99	72,50	78,74	75,62	51,26	77,75	76,06	78,94	77,50	54,54
	75,55	70,37	80,25	75,31	50,80	77,75	75,78	79,16	77,47	54,59

da anatomia do fundo do olho. O Disco Óptico (DO) e suas bordas são mais visíveis no canal vermelho. Essa propriedade é utilizada para verificar as mudanças causadas pelo glaucoma e que se encontram próximas as bordas do DO. O canal verde apresenta melhor contraste e, assim como no canal azul, a escavação é mais visível, pois seus pixels têm uma intensidade maior (mais brilhosos) que os pixel do restante do DO [de Lima Araujo 2018].

## 5. Conclusão

Este trabalho apresentou uma metodologia computacional que visa auxiliar especialistas na quantificação do glaucoma por meio de técnicas de Visão Computacional. A metodologia proposta utiliza LBP e GLCM para caracterização da textura e a otimização de parâmetros utilizando o *grid search* no classificador *Xgboost*. Os testes foram realizados na base RIM-ONE r2 e obtiveram resultados promissores em que o *grid search* apresentou uma considerável melhoria do desempenho da classificação do glaucoma. Para trabalhos futuros, pretende-se avaliar o impacto que o *grid search* tem no desempenho dos resultados de outros classificadores e descritores.

## Referências

- Araujo, J. D. L. et al. (2018). Diagnóstico de glaucoma a partir de imagens de fundo de olho utilizando índices de diversidade.
- Ayub, J., Ahmad, J., Muhammad, J., Aziz, L., Ayub, S., Akram, U., and Basit, I. (2016). Glaucoma detection through optic disc and cup segmentation using k-mean clustering. In *2016 International Conference on Computing, Electronic and Electrical Engineering (ICE Cube)*, pages 143–147. IEEE.
- Bland, M. (2015). *An introduction to medical statistics*. Oxford University Press (UK).
- Chen, T. and Guestrin, C. (2016). Xgboost: A scalable tree boosting system. In *Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining*, pages 785–794. ACM.
- Claro, M. L., Veras, R. d. M. S., Santana, A. M., Vogado, L. H. S., and Sousa, L. P. (2018). Diagnóstico de glaucoma utilizando atributos de textura e cnn's pré-treinadas. *Revista de Informática Teórica e Aplicada*, 25(1):82–89.
- Cohen, J. (1968). Weighted kappa: Nominal scale agreement provision for scaled disagreement or partial credit. *Psychological bulletin*, 70(4):213.

- de Carvalho Junior, A. S. V., Carvalho, E. D., de Carvalho Filho, A. O., de Sousa, A. D., Silva, A. C., and Gattass, M. (2018). Automatic methods for diagnosis of glaucoma using texture descriptors based on phylogenetic diversity. *Computers & Electrical Engineering*, 71:102–114.
- de Lima Araujo, J. D. (2018). Diagnóstico de glaucoma a partir de imagens de fundo de olho utilizando Índices de diversidade. Pós-graduação em ciência da computação, Universidade Federal do Maranhã, São Luís.
- Fernandes, A. G. S., da Silva Martins, C. M., de Moura Lima, A. C., Junior, G. B., de Almeida, J. D. S., and de Paiva, A. C. (2019). Meta aprendizagem de extração de características aplicada ao diagnóstico de glaucoma. In *Anais do XIX Simpósio Brasileiro de Computação Aplicada à Saúde*, pages 342–347. SBC.
- Friedman, J. H. (2001). Greedy function approximation: a gradient boosting machine. *Annals of statistics*, pages 1189–1232.
- Gonzalez, R. C. and Woods, R. C. (2010). *Processamento digital de imagens*. Pearson Educación.
- Haralick, R. M., Shanmugam, K., et al. (1973). Textural features for image classification. *IEEE Transactions on systems, man, and cybernetics*, (6):610–621.
- Lerman, P. (1980). Fitting segmented regression models by grid search. *Journal of the Royal Statistical Society: Series C (Applied Statistics)*, 29(1):77–84.
- Li, Z., He, Y., Keel, S., Meng, W., Chang, R. T., and He, M. (2018). Efficacy of a deep learning system for detecting glaucomatous optic neuropathy based on color fundus photographs. *Ophthalmology*, 125(8):1199–1206.
- Lim, R. and Goldberg, I. (2010). Glaucoma in the twenty-first century. In *The Glaucoma Book*, pages 3–21. Springer.
- Loewen, N. A. and Tanna, A. P. (2010). Glaucoma risk factors: Intraocular pressure. *The Glaucoma Book: A Practical, Evidence-Based Approach to Patient Care*, page 35.
- MATOS, C. E. F. (2017). Diagnosis of breast cancer in images mammography through local features and invariants.
- 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.
- Oliveira, W. E. B. e. F. S. R. (2016). Classificacao de padroes em imagens usando descritores de textura.
- Resnikoff, S., Pascolini, D., Etya’Ale, D., Kocur, I., Pararajasegaram, R., Pokharel, G. P., and Mariotti, S. P. (2004). Global data on visual impairment in the year 2002. *Bulletin of the world health organization*, 82:844–851.
- RIMONE, M. I. A. G. (2015). Rim-one r2.
- Severo, E. B. (2014). Quantificação automática do glaucoma utilizando imagens de fundo do olho.
- Stone, M. (1974). Cross-validatory choice and assessment of statistical predictions. *Journal of the Royal Statistical Society: Series B (Methodological)*, 36(2):111–133.