

# Meta Aprendizagem Aplicada ao Diagnóstico de Glaucoma

Arthur Guilherme Santos Fernandes<sup>1</sup>, Caio Manfredini da Silva Martins<sup>1</sup>,  
Geraldo Braz Junior<sup>1</sup>, José Mateus Carvalho Boaro<sup>1</sup>, Lisle Faray de Paiva<sup>1</sup>

<sup>1</sup>Laboratório de Visão e Processamento de Imagens - VIPLab  
Núcleo de Computação Aplicada - NCA  
Universidade Federal do Maranhão (UFMA)  
Av. dos Portugueses, 1966 - Bacanga, São Luís - MA, 65080-805, Brazil

{arthurgsf, caiomanfredini, geraldo, boaro, lisle}@nca.ufma.br

**Abstract.** *Glaucoma is an asymptomatic disease that can bring people to blindness if not early detected. Computational intelligence methods have been proposed to provide a computerized diagnosis that can guide patients to the appropriate treatment. However, these techniques face methodology optimization problems, which depends on the choices of many algorithms from different knowledge areas. This paper suggests a solution through meta-learning of pre-processing methods, decomposition and features extraction which have to be used efficiently in order to solve the problem. Current results are promising, reaching 93.40% accuracy after 144 evaluations and it is supposed to improve proportionally to the number of evaluations.*

**Resumo.** *O glaucoma é uma doença silenciosa que pode levar a cegueira caso não seja tratada com urgência. Métodos de diagnóstico que utilizam inteligência computacional têm sido propostos com a finalidade de aumentar a taxa de detecções da doença ainda na sua fase inicial, e proporcionar melhor qualidade de vida aos pacientes. Porém, a descoberta de melhores técnicas e métodos de diagnóstico automatizado, é necessária grande quantidade de testes de diferentes metodologias e abordagens sobre o problema, tornando o processo lento e sujeito a erros. Este trabalho propõe uma solução através da meta aprendizagem de métodos de pré processamento, decomposição, extração de características que devem ser usados de maneira eficiente para solucionar o problema. Os resultados obtidos são promissores, atingindo 93,40% de acurácia após 144 execuções e deve melhorar proporcionalmente à quantidade de testes realizados.*

## 1. Introdução

O glaucoma é uma das causas mais comuns de cegueira e deverá afetar em todo o mundo, cerca de 80 milhões de pessoas até 2020 [Chen et al. 2015]. O Brasil possui atualmente cerca de 1 milhão de pessoas com glaucoma, de acordo com a OMS (Organização Mundial de Saúde) [de Sousa et al. 2017]. Ele é uma doença ocular crônica que pode levar à perda de visão, na qual o nervo óptico é progressivamente danificado devido ao aumento da pressão intra-ocular (IOP, do inglês, *Intraocular Pressure*). o glaucoma não pode ser curado, porém sua progressão pode ser retardada pelo tratamento da IOP. A detecção precoce do glaucoma com a ajuda de imagens de fundo de olho é importante pois permite

que os especialistas ajam contra a doença, a fim de dar ao paciente uma melhor qualidade de vida [Chen et al. 2015].

O impacto da doença, e a incapacidade de triagem eficiente de toda população tem motivado trabalhos de processamento de imagens e aprendizado de máquina [Silva et al. 2018][Silveira et al. 2018] [Acharya et al. 2015][Kawde and Bairagi 2016][Kim et al. 2017] com a finalidade de diagnosticar automaticamente o glaucoma e indicar a necessidade de acompanhamento especializado para tratamento.


Um grande desafio consiste na escolha adequada de técnicas de pré-processamento, decomposição/representação, extração de características e classificação. A combinação ótima destes parâmetros que compõem a metodologia normalmente é descoberta após uma grande bateria de experimentos. O custo para encontrar a melhor combinação de técnicas pode ser reduzido utilizando a Otimização Bayesiana, geralmente aplicável em cenários onde um usuário deseja minimizar uma função escalar cuja execução é muito custosa [Bergstra et al. 2013a]. Tal otimização tem sua eficácia comprovada em modelos de Inteligência Artificial como: Redes Neurais Convolucionais [Lecun et al. 1998], Redes Profundas [Hinton et al. 2006] e classificadores baseados em extração de características como Máquinas Restritas de Boltzmann [Ranzato and Hinton 2010].

Portanto, neste trabalho é proposta uma metodologia que realiza a meta aprendizagem da escolha de técnicas existentes para pré-processamento, decomposição e extração, visando a minimização do valor de retorno de uma função de classificação  $f(x)$ , utilizada para computar o erro do classificador, onde "x" são as possibilidades existentes em cada etapa de processamento.

## 2. Metodologia Proposta

Este trabalho propõe a utilização da Otimização Bayesiana de maneira generalista para estimar uma combinação ótima de técnicas em cada um dos estágios de processamento. A metodologia é proposta para o diagnóstico de glaucoma utilizando imagens de fundo de olho.

A Figura 1 ilustra a metodologia proposta com o fluxo de execução do sistema de otimização e cada uma das etapas de processamento, que serão detalhadas nas seções seguintes.



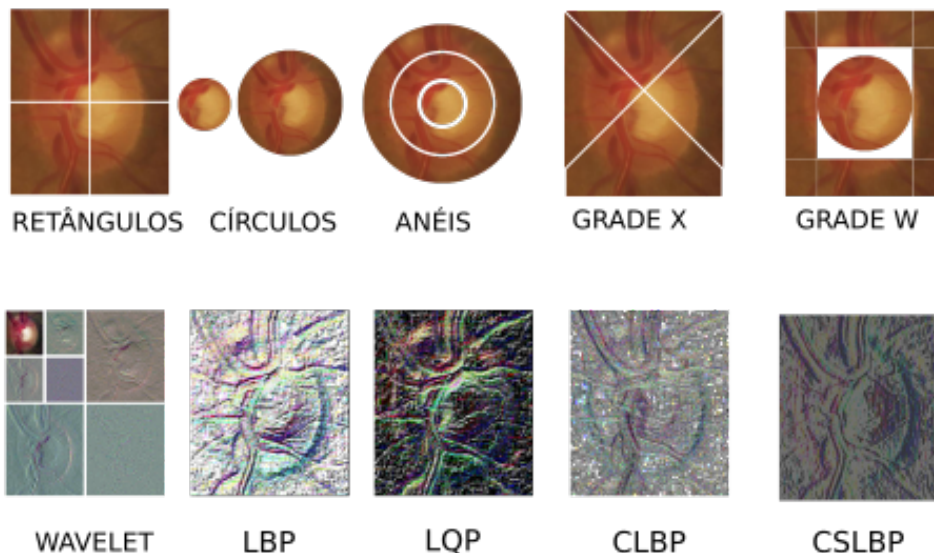
**Figura 1. Fluxo de etapas da metodologia proposta**

## 2.1. Pré-Processamento

O processo de realce e filtragem torna a imagem resultante mais adequada para análise que a original em aplicações diversas [Gonzalez and Woods 2010]. O sucesso do pré-processamento aplicado depende do objeto estudado, o que ratifica a importância de testar o seu impacto no resultado final quando aplicado ou combinado com outras técnicas. Foram selecionadas 4 técnicas de pré-processamento para serem aplicadas em conjunto. As opções implementadas são: *Contrast Limited Adaptive Histogram Equalization* (CLAHE) [Pizer et al. 1987] para o enriquecimento de características e redistribuição da luminosidade da imagem, Realce Logarítmico para aumentar o contraste em regiões em que os valores de cinza são muito baixos, *Histogram of Oriented Gradients* (HOG) [Freeman and Roth 1994] para gerar imagens gradiente e Realce Negativo para tornar as regiões claras em escuras e vice-versa.

## 2.2. Decomposição

Esta etapa busca representar a imagem de maneira mais eficiente para o extrator de características isolando o objeto de interesse ou selecionando pequenas partes das imagens. Um procedimento de decomposição de imagens bem-sucedido aumenta as chances de sucesso em problemas que requerem que certas localizações sejam individualmente analisadas [Gonzalez and Woods 2010]. No caso do glaucoma, a região de interesse é a do disco óptico e seus componentes.



**Figura 2. Decomposições aplicadas à uma imagem de fundo de olho.**

A figura 2 ilustra as possibilidades de decomposição implementadas neste trabalho: regiões de Retângulos, Círculos, Anéis, Grade X, Grade W e decomposição Wavelet [Meyer 1993], onde a quantidade de retângulos ou círculos e ainda o nível de decomposição (no caso da wavelet) são parâmetros decididos automaticamente durante a otimização. E ainda Local Binary Patterns (LBP) [T. Ojala 1996], Local Quinary Patterns (LQP) [Nanni et al. 2010], Compound Local Binary Patterns (CLBP) [Faisal et al. 2011]

e Center-Symmetric Local Binary Patterns (CSLBP) [Heikkilä et al. 2009], que não necessitam de parâmetros.

### 2.3. Extração

O processo de extração de características é uma maneira de mensurar determinados aspectos de uma imagem para que os algoritmos de inteligência computacional possam distinguir uma imagem da outra. Existem descritores de forma, dimensão, cor, textura, e outros.

Os algoritmos da metodologia proposta foram selecionados de acordo com sua eficiência em problemas semelhantes, são eles:

- Índices de Diversidade [Magurran 2004], que são conceitos utilizados em ecologia como maneira de mensurar a distribuição de diferentes espécies em determinada comunidade;
- Matrizes de Co-ocorrência : *Gray Level Cooccurrence Matrix* (GLCM) [Haralick et al. 1973], *Gray Level Run Length Matrix* (GLRLM) [Tustison and Gee 2011], *Gray Level Size Zone Matrix* (GLSZM) [Thibault et al. 2009], *Neighbouring Gray Tone Difference Matrix* (NGTDM) [Amadasun and King 1989] e *Gray Level Dependence Matrix* (GLDM) [Sun and Wee 1983], que analisam as relações espaciais entre pixels de mesma intensidade em escala de cinza;
- HOG para extração de características a partir dos gradientes gerados [Freeman and Roth 1994];
- Deep Features extraídas com as redes *Xception* [Chollet 2017], *Vgg 16* e *Vgg 19* [Simonyan and Zisserman 2014], *Resnet 50* [He et al. 2016], *Inception V3* [Szegedy et al. 2016b], *Inceptionresnet V2* [Szegedy et al. 2016a], *Densenet 121*, *Densenet 169* e *Densenet 201* [Huang et al. 2017].

### 2.4. Otimização

A etapa de otimização consiste em analisar resultados de classificações anteriores para sugerir novos parâmetros para outra classificação. Desta maneira, à cada nova classificação, o resultado tende a ser mais assertivo.

Os parâmetros dentre os quais o algoritmo de otimização pôde escolher foram definidos em um espaço de busca equivalente ao domínio da função que desejou-se aprimorar. Tal espaço foi construído em 4 possibilidades para pré processamento; 1 possibilidade para decomposição e 9 possibilidades de extratores de características. Dentre todas as possibilidades citadas anteriormente, existia também a chance da escolha nula, exceto para o extrator de característica, onde no mínimo um deveria ser escolhido.

Para avaliar o *fitness* de cada solução construída durante a otimização foram utilizados os algoritmos de: Regressão Logística [Yu et al. 2011], *Random Forest* [Breiman 2001] e *XGBOOST* [Chen and Guestrin 2016], que também foram selecionados automaticamente na etapa de otimização.

O otimizador foi implementado sobre a biblioteca *HyperOpt* que disponibiliza o algoritmo *Tree-Structured Parzen Estimator* (TPE) [Bergstra et al. 2013b]. O algoritmo TPE utiliza de decisões bayesianas para escolha de parâmetros, tendo como principal característica, a convergência mais rápida para a solução ótima se comparado com a decisão aleatória ou em *grid*.

### 3. Resultados Preliminares

Para implementar a metodologia proposta foi utilizado o acervo público de imagens de fundo de olho RIM-ONE R2 [Fumero et al. 2011] composta de 255 imagens de olhos normais e 200 com glaucoma. A base foi dividida usando *hold-out* em 70% para treino e 30% para teste. Foram realizados um total de 144 testes com o *HyperOpt*, executados durante 2 semanas paralelamente em duas máquinas Intel Core i7 7700T, @2.90 GHz x 4 e memória RAM de 16 GB.




Figura 3. Curva ROC gerada pelos testes realizados.

A Figura 3 apresenta a curva ROC (*Receiver Operating Characteristic*) gerada pelos testes, as combinações ótimas estão localizadas no canto superior direito e as melhores acurácias estão destacadas em vermelho. A Tabela 1 sumariza dentre os testes realizados, as 5 melhores soluções geradas. A melhor configuração obteve acurácia de 93,40% e sensibilidade de 99,01%. A tabela também apresenta os parâmetros sugeridos pelo otimizador para cada uma destas soluções.

Tabela 1. Cinco melhores combinações de parâmetros de acordo com a acurácia.

Pré-Processamento	Decomposição	Extração	Classificação	Acurácia (%)	Sensibilidade (%)	Precisão (%)	F1 (%)
Equalização + CLAHE + Realce Logarítmico	CLBP	Índices de Diversidade + GLCM + HOG + INCEPTIONRESNETV2 + INCEPTIONV3 + RESNET50 + VGG16 + XCEPTION	XGBOOST	93,40	99,01	92,66	95,73
Realce Logarítmico + CLAHE	CLBP	Índices de Diversidade + NGTDM + GLCM + DENSENET121 + DENSENET201 + INCEPTIONRESNETV2	Regressão Logística	93,04	97,54	93,42	95,44
Equalização + CLAHE + Realce Logarítmico	CLBP	Índices de Diversidade + GLCM + HOG + INCEPTIONRESNETV2 + INCEPTIONV3 + RESNET50 + VGG16 + XCEPTION	XGBOOST	92,67	99,01	91,81	95,28
Equalização + CLAHE + Realce Logarítmico	CLBP	Índices de Diversidade + GLCM + HOG + INCEPTIONRESNETV2 + INCEPTIONV3 + RESNET50 + VGG16 + XCEPTION	Regressão Logística	92,67	99,01	93,39	95,28
Equalização + CLAHE + Realce Logarítmico	CLBP	Índices de Diversidade + GLCM + HOG + INCEPTIONRESNETV2 + INCEPTIONV3 + RESNET50 + VGG16 + XCEPTION	Random Forest	91,94	100	90,26	94,88

A obtenção de melhores resultados com a decomposição CLBP sugere que esta decomposição facilita a extração das características mais relevantes para o diagnóstico de

glaucoma. Também foi possível verificar que as técnicas de extração baseadas em Índices de Diversidade, GLCM e nas redes *InceptionResNetV2*, *Xception*, *VGG16* e *ResNet50* aparecem com frequência dentre os testes com maior acurácia, o que poderá nortear futuros testes para melhorar os resultados já obtidos.

#### 4. Conclusão e Trabalhos Futuros

Neste trabalho foi utilizada a otimização bayesiana para estimar a melhor combinação de técnicas de pré-processamento, decomposição e extração de características quando aplicadas ao problema da detecção de glaucoma em imagens de fundo de olho. Tal metodologia é extensível para outros problemas, pois novas abordagens, independentemente da etapa à qual pertence, podem ser acopladas e sua eficácia será testada através da Meta Aprendizagem proposta.

A presença constante da decomposição CLBP entre os melhores resultados demonstra a relevância da técnica para este problema específico, de maneira que outras abordagens para o diagnóstico de glaucoma utilizando processamento de imagem poderão passar a considerá-la em seus testes.

Como trabalhos futuros, poderá ser adicionado o processo de aumento de dados na base, também conhecido como *Data Augmentation*, que facilitará a classificação ao aumentar a quantidade de dados disponíveis para treino do classificador. Além disso, novos descritores de textura e extratores de características poderão ser adicionados ao processo de otimização.

#### Referências

- Acharya, U. R., Ng, E., Eugene, L. W. J., Noronha, K. P., Min, L. C., Nayak, K. P., and Bhandary, S. V. (2015). Decision support system for the glaucoma using gabor transformation. *Biomedical Signal Processing and Control*, 15(Supplement C):18 – 26.
- Amadasun, M. and King, R. (1989). Textural features corresponding to textural properties. *IEEE Transactions on Systems, Man, and Cybernetics*, 19(5):1264–1274.
- Bergstra, J., Yamins, D., and Cox, D. D. (2013a). Hyperopt: A python library for optimizing the hyperparameters of machine learning algorithms. In van der Walt, S., Millman, J., and Huff, K., editors, *Proceedings of the 12th Python in Science Conference*, pages 13 – 20.
- Bergstra, J., Yamins, D., and Cox, D. D. (2013b). Hyperopt: A python library for optimizing the hyperparameters of machine learning algorithms. In *Proceedings of the 12th Python in science conference*, pages 13–20. Citeseer.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1):5–32.
- Chen, T. and Guestrin, C. (2016). Xgboost. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining - KDD '16*.
- Chen, X., Xu, Y., Wong, D. W. K., 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, Milan, Italy. IEEE.

- Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 1251–1258.
- de Sousa, J. A., de Paiva, A. C., Sousa de Almeida, J. D., 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*, 76(18):19173–19190.
- Faisal, A., Emam, H., A.S.M., H. B., and Hossen, S. (2011). Compound local binary pattern (clbp) for rotation invariant texture classification.
- Freeman, W. T. and Roth, M. (1994). Orientation histograms for hand gesture recognition. Technical Report TR94-03, MERL - Mitsubishi Electric Research Laboratories, Cambridge, MA 02139.
- Fumero, F., Alayon, S., Sanchez, J. L., Sigut, J., and Gonzalez-Hernandez, M. (2011). RIM-ONE: An open retinal image database for optic nerve evaluation. In *2011 24th International Symposium on Computer-Based Medical Systems (CBMS)*, pages 1–6, Bristol, UK. IEEE.
- Gonzalez, R. C. and Woods, R. E. (2010). *Processamento Digital de Imagens*. Pearson, 3<sup>a</sup> edition.
- Haralick, R., Shanmugam, K., and Dinstein, I. (1973). Texture features for image classification. *IEEE Transactions on Systems, Man, and Cybernetics*, 3(6).
- He, K., Zhang, X., Ren, S., and Sun, J. (2016). Deep residual learning for image recognition. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
- Heikkilä, M., Pietikäinen, M., and Schmid, C. (2009). Description of interest regions with local binary patterns. *Pattern Recognition*, 42(3):425 – 436.
- Hinton, G. E., Osindero, S., and Teh, Y.-W. (2006). A fast learning algorithm for deep belief nets. *Neural Comput.*, 18(7):1527–1554.
- Huang, G., Liu, Z., Maaten, L. v. d., and Weinberger, K. Q. (2017). Densely connected convolutional networks. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
- Kawde, M. M. and Bairagi, V. K. (2016). Early detection of glaucoma disease using image processing. *Indian Journal of Science and Technology*, 9(30).
- Kim, S. J., Cho, K. J., and Oh, S. (2017). Development of machine learning models for diagnosis of glaucoma. *PLOS ONE*, 12(5):1–16.
- Lecun, Y., Bottou, L., Bengio, Y., and Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11):2278–2324.
- Magurran, A. (2004). *Measuring Biological Diversity*, volume 29.
- Meyer, Y. (1993). *Wavelets and Operators*, volume 1 of *Cambridge Studies in Advanced Mathematics*. Cambridge University Press.
- Nanni, L., Lumini, A., and Brahmam, S. (2010). Local binary patterns variants as texture descriptors for medical image analysis. *Artificial Intelligence in Medicine*, 49(2):117 – 125.

- Pizer, S. M., Amburn, E. P., Austin, J. D., Cromartie, R., Geselowitz, A., Greer, T., ter Haar Romeny, B., Zimmerman, J. B., and Zuiderveld, K. (1987). Adaptive histogram equalization and its variations. *Computer Vision, Graphics, and Image Processing*, 39(3):355 – 368.
- Ranzato, M. and Hinton, G. E. (2010). Modeling pixel means and covariances using factorized third-order boltzmann machines. In *2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pages 2551–2558.
- Silva, M. G., Pessoa, A. C., de Almeida, J. D., Junior, G. B., and de Paiva, A. C. (2018). Diagnóstico do glaucoma em imagens de retinografia usando variantes de padrões locais binários. In *18º Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS 2018)*, volume 18. SBC.
- Silveira, R. M., Almeida, J. D., Teixeira, J. A., Maia, I. M., Paiva, A. C., and Júnior, G. B. (2018). Dispositivo de baixo custo para detecção de patologias da visão. In *18º Simpósio Brasileiro de Computação Aplicada à Saúde (SBCAS 2018)*, volume 18. SBC.
- Simonyan, K. and Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- Sun, C. and Wee, W. G. (1983). Neighboring gray level dependence matrix for texture classification. *Computer Vision, Graphics, and Image Processing*, 23(3):341 – 352.
- Szegedy, C., Ioffe, S., Vanhoucke, V., and Alemi, A. (2016a). Inception-v4, inception-resnet and the impact of residual connections on learning.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., and Wojna, Z. (2016b). Rethinking the inception architecture for computer vision. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*.
- T. Ojala, M. Pietikainen, D. H. (1996). A comparative study of texture measures with classification based on featured distribution. *Pattern Recognit*, 29:51–59.
- Thibault, G., FERTIL, B., Navarro, C., Pereira, S., Lévy, N., SEQUEIRA, J., and MARI, J.-L. (2009). Texture indexes and gray level size zone matrix application to cell nuclei classification.
- Tustison, N. and Gee, J. (2011). Run-length matrices for texture analysis.
- Yu, H.-F., Huang, F.-L., and Lin, C.-J. (2011). Dual coordinate descent methods for logistic regression and maximum entropy models. *Machine Learning*, 85(1):41–75.