

**Metodologia Deep Features para Diagnóstico de Glaucoma****Deep Features Methodology for Glaucoma Diagnosis**

DOI:10.34117/bjdv6n6-589

Recebimento dos originais: 26/05/2020

Aceitação para publicação: 26/06/2020

**Lisle Faray de Paiva**

Estudade de Graduação em Ciência da Computação pela Universidade Federal do Maranhão

Instituição: Universidade Federal do Maranhão

Endereço: Av. dos Portugueses, 1966 - Vila Bacanga, São Luís - MA, 65080-805

E-mail: lisle@nca.ufma.br

**José Mateus Boaro Carvalho**

Estudade de Graduação em Ciência da Computação pela Universidade Federal do Maranhão

Instituição: Universidade Federal do Maranhão

Endereço: Av. dos Portugueses, 1966 - Vila Bacanga, São Luís - MA, 65080-805

E-mail: boaro@nca.ufma.br

**Arthur Guilherme Santes Fernandes**

Estudade de Graduação em Ciência da Computação pela Universidade Federal do Maranhão

Instituição: Universidade Federal do Maranhão

Endereço: Av. dos Portugueses, 1966 - Vila Bacanga, São Luís - MA, 65080-805

E-mail: arthurgsf@nca.ufma.br

**Caio Manfredini da Silva Martins**

Estudade de Graduação em Ciência da Computação pela Universidade Federal do Maranhão

Instituição: Universidade Federal do Maranhão

Endereço: Av. dos Portugueses, 1966 - Vila Bacanga, São Luís - MA, 65080-805

E-mail: caiomanfredini@nca.ufma.br

**Geraldo Braz Junior**

Doutorado em Engenharia Elétrica pela Universidade Federal do Maranhão

Instituição: Universidade Federal do Maranhão

Endereço: Av. dos Portugueses, 1966 - Vila Bacanga, São Luís - MA, 65080-805

E-mail: geraldo@nca.ufma.br

**RESUMO**

O glaucoma é uma doença ocular caracterizada por neuropatia óptica e distúrbio visual que corresponde á escavação no disco óptico e á degeneração das fibras nervosas ópticas. Geralmente é causado pelo aumento na pressão intra-ocular, que danifica o nervo óptico, resultando em perda gradual da visão. Um tratamento eficaz é a redução e controle da pressão intra-ocular (PIO) que deve acontecer o mais precocemente possível de modo a limitar a progressão da doença. Vários trabalhos tem sido propostos para a realização do diagnóstico automático de glaucoma. Assim, é vital o desenvolvimento de uma ferramenta

computadorizada automática para diagnosticar a doença. No entanto, existe ainda grande dificuldade de lidar com uma grande diversidade de imagens. Em razão disso, tais métodos não são viáveis para o uso em programas de triagem. Este trabalho propõe uma metodologia com a finalidade de detectar de uma maneira eficiente o glaucoma, que seja capaz de lidar com imagens diversas, através da extração de características usando Redes Neurais Convolucionais (CNNs). Nesta proposta foram utilizadas CNNs pré-treinadas e Redes Específicas construídas através de uma estratégia de otimização de arquitetura e de hiperparâmetros específica para o problema. Destas redes foram extraídas as características as quais foram utilizadas com o classificador Regressão Logística, apresentando resultados promissores na detecção do Glaucoma. Em experimentos realizados com 1090 imagens de quatro bases de dados foram obtidas acurácias de 86.8% e 86.3%.

**Palavras-chaves:** Glaucoma, Redes Neurais Convolucionais.

### **ABSTRACT**

Glaucoma is an ocular disease characterized by optic neuropathy and visual disturbance which corresponds to the excavation of the optical disc and the degeneration of the optical nerve fibers. Usually caused by an increase in intraocular pressure, which damages the optic nerve, resulting in gradual loss of vision. An effective treatment is the reduction and control of intraocular pressure (IOP) which must happen as early as possible in order to limit the progression of the disease. Several studies have been proposed for the automatic diagnosis of glaucoma. Thus it is vital the development of an automatic computerized tool to diagnose the disease. However, there is great difficulty in dealing with a great diversity of images. As a result, such methods are not viable to use in screening programs. This work proposes a methodology to efficiently detect glaucoma, that is capable of handling diverse images, through feature extraction and Convolutional Neural Networks (CNNs). This proposal used pre-trained CNNs and Specific Networks built through an architecture optimization strategy and specific hyperparameters for the problem. The characteristics that were used with the Logistic Regression classifier were extracted from these networks, showing promising results in the detection of glaucoma. In experiments carried out with 1090 images from four databases, were obtained accuracy's of 86.8% e 86.3%.

**Key words:** Glaucoma, Convolutional Neural Networks.

## **1 INTRODUÇÃO**

O glaucoma, segundo a Organização Mundial da Saúde, constitui a segunda maior causa de cegueira do mundo, ficando atrás somente da catarata. Considerando que a cegueira causada pela catarata pode ser reversível, provavelmente o glaucoma é a principal causa de cegueira irreversível [Thylefors and Negrel 1994]. De acordo com [Quigley and Broman 2006], deverá afetar cerca de 80 milhões de pessoas até 2020.

Trata-se de uma doença que afeta o nervo óptico em geral devido a um aumento na pressão interocular. Em seus estágios iniciais o glaucoma tende a ser assintomático e seus sintomas só aparecem apenas nos estágios mais avançados da doença. A detecção precoce

desta patologia é imprescindível, pois existem tratamentos que evitam sua progressão e, conseqüentemente, a perda da visão do paciente.

Existem diversas técnicas para capturar imagens da camada de fibras nervosas e disco óptico para exame e diagnóstico de glaucoma. Entre elas podemos citar a oftalmoscopia a laser de varredura confocal (CSLO), tomografia de coerência óptica (OCT) e polarimetria de varredura a laser (SLP) [Raja and Gangatharan 2015]. Uma alternativa a essas técnicas é o exame de imagem do fundo do olho, um exame não invasivo e de baixo custo que pode ser efetivo para o diagnóstico do glaucoma. A análise de imagens de fundo de olho baseada em computador sistemas é uma importante ferramenta detectar e monitorar o desenvolvimento natural da doença.

O diagnóstico de glaucoma pode ser dado a partir da análise de imagens de fundo de olho, uma vez que a quantidade de perda de fibras do nervo óptico tem um efeito direto na configuração da rima neural. À medida que as fibras ópticas nervosas vão morrendo, a escavação(cup) torna-se mais larga em relação ao disco óptico, o que acarreta em um valor da relação Escavação/Disco (Cup to Disc ratio - CDR) aumentado [Mittapalli and Kande 2016].

Os sistemas computacionais e as técnicas baseadas em inteligência artificial tem grande impacto no campo da medicina, ajudado os médicos identificar antecipadamente qualquer anormalidade e realizar um diagnóstico precoce. A análise automatizada da imagem da retina ajuda os oftalmologistas a detectar anormalidades nas estruturas da retina, que incluem o disco óptico e os vasos, diagnosticando doenças retinianas como glaucoma e retinopatia.

Devido ao impacto do glaucoma e a incapacidade de uma triagem eficiente da população tem-se métodos de diagnóstico através do uso de técnicas de aprendizado de máquina a fim de diagnosticar automaticamente e indicar acompanhamento especializado para tratamento.

Neste trabalho é desenvolvido um método para a extração das características utilizando Redes Neurais Convolucionais a fim de detectar o glaucoma, visando contribuir para a área de saúde auxiliando os profissionais para uma triagem eficiente e precisa, uma vez que esta triagem é feita manualmente.

## **2 TRABALHOS RELACIONADOS**

As redes neurais convolucionais (CNNs) foram introduzidas em [LeCun et al. 1989] tendo sido usados em visão computacional e inteligência artificial. As primeiras camadas dessas redes extraem bordas em orientações e locais específicos na imagem. As camadas

intermediárias detectam estruturas compostas de arranjos particulares de arestas e as últimas camadas detectam estruturas mais complexas.

Treinar CNNs a partir do zero não é uma tarefa fácil. Este treinamento exige uma quantidade enorme de dados rotulados. Como alternativa a este problema podemos ajustar uma CNN treinada para uma aplicação diferente e depois utilizá-los em imagens médicas, como apresentado em [Dhungel et al. 2016]. Em [Tajbakhsh et al. 2016] é apresentado um conjunto de experimentos para quatro aplicações de imagens médicas, mostrando o uso da CNN pré-treinada realizada e comparando com com uma CNN treinada do zero.

Uma outra alternativa consiste em usar uma CNN treinada como extrator de características e então usar essas características para treinar um novo classificador, como máquinas de vetores de suporte (SVM), árvores de decisão ou Naive Bayes. Em [Bar et al. 2015] CNNs pré-treinadas que foram usadas como extrator de características para identificação de doenças pulmonares.

Para diagnóstico de glaucoma, também existem vários trabalhos na literatura que empregam CNNs. Em [Raghavendra et al. 2018] é utilizada uma CNN com 18 camadas e apresentado como melhor resultado uma acurácia de 98.13%. Em [Abbas 2017] é apresentado um sistema conhecido como Glaucoma-Deep. Este sistema consiste em uma arquitetura CNN não supervisionada que extrai automaticamente características das imagens de fundo de olho.

Posteriormente, ele usa uma Deep-belief Network (DBN) para selecionar os recursos mais discriminativos. Em seu trabalho, são usados quatro bancos de dados. Seu trabalho apresenta bons resultados (especificidade: 0,9801 e sensibilidade: 0,8450). Em [Orlando et al. 2017] foi apresentado como duas CNNs diferentes, OverFeat e VGG-S, poderiam ser usadas como extratores de recursos.

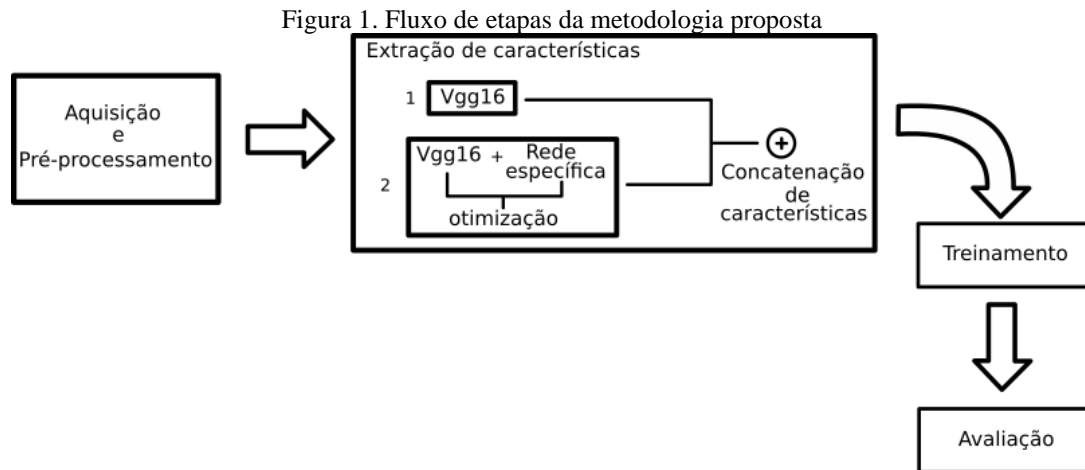
Em [Diaz-Pinto et al. 2019] é apresentada uma análise de cinco arquiteturas CNN diferentes treinadas pela ImageNet usadas como classificador de glaucoma, obtendo como melhor resultado especificidade média de 0.8580 e uma sensibilidade média de 0.9346

Observa-se, portanto, que a utilização de múltiplas CNNs para extração de características pode ser um importante meio para melhorar os resultados dos métodos de diagnóstico de glaucoma a partir de imagens de fundo de olho.

### **3 METODOLOGIA**

Este trabalho apresenta uma metodologia para o diagnóstico de glaucoma baseado na extração de características usando Redes Neurais Convolucionais. Primeiramente as imagens

da base de dados são alimentadas para duas arquiteturas: a VGG161 pré-treinada com os pesos da Imagenet e a VGG16 ajustada com rede específica com parâmetros otimizados. Após o treinamento, são extraídos os vetores características de cada rede e concatenados. Esses vetores por sua vez serão passados para um classificador para realizar o diagnóstico. A Figura 1 ilustra o método proposto com o fluxo das etapas. Cada uma das etapas são descritas em detalhes nas subseções seguintes.



### 3.1 AQUISIÇÃO E PRÉ-PROCESSAMENTO

A primeira etapa da metodologia consiste na aquisição da base de dados. A base de dados é composta pela junção de quatro bases já existentes: Rim-One r1 [Fumero et al. 2011], Rim-One r2 [Fumero et al. 2011], iChallenge Gon [of Technology 2018], Kaggle 1000 fundus image [linchundan 2018]. Esta possui no total 1090 imagens, sendo 303 imagens de olhos glaucomatosos e 787 imagens de olhos normais.

Por se tratar de uma base de dados desbalanceada, inicialmente é realizado geração sintética das imagens com a finalidade de distribuir os quantitativos de imagens pelas classes. Os parâmetros escolhidos para gerar variações das imagens originais foram: intervalo de cisalhamento, variação de largura e altura, variação do ângulo de rotação, variação de zoom, preenchimento lateral com 0 e rotação 180°, os quais foram aplicadas aleatoriamente.


Na Figura 2, pode-se observar a diferença na imagem original e a imagem sintética. Para cada imagem de glaucoma, são geradas 10 imagens sintéticas, enquanto que para cada imagem de olho normal são geradas 4 imagens. A diferença na quantidade de imagens geradas com glaucoma para as normais é a maneira escolhida para balancear a base. Após a geração de imagens sintéticas é realizado o redimensionamento das imagens para altura 612 e largura 900,

com a finalidade de padronizar a entrada da CNN que, por sua vez, só recebe imagens de mesmo tamanho.

### 3.2 EXTRAÇÃO DE CARACTERÍSTICAS

Após o pré-processamento, realiza-se a extração de características. Este processo consiste na retirada da última camada da rede (seu classificador) e obter a saída da camada de

Figura 2. (a) Imagem normal; (b) Imagem sintética



*pooling* logo após a última camada de convolução. Neste trabalho são extraídos 2 vetores característicos de duas arquiteturas: a rede VGG16 [Han et al. 2015] original e a VGG16 com fine tuning estimado pelo otimizador. A rede neural VGG16 foi escolhida para este trabalho por ser uma rede de arquitetura simples, assim dando maior destaque para o método. A extração de cada um será explicada mais a fundo nas subseções a seguir.

Após a extração, ocorre a concatenação dos vetores característicos da rede VGG16 propriamente dita e o vetor da VGG16 com a rede específica estimada pelo otimizador. Com a concatenação dos dois vetores, o classificador tem uma maior quantidade de características mais proeminentes com o intuito de obter melhores resultados. Assim existem 2 vetores de características, o primeiro gerado pela rede genérica e o segundo gerado pela rede específica.


Uma Rede Neural Convolutiva (CNN, do inglês Convolutional Neural Network) é uma classe de rede neural artificial do tipo feed-forward, que vem sendo aplicada com sucesso no processamento e análise de imagens digitais. As redes convolucionais são inspiradas nos processos biológicos [Matsugu et al. 2003]. Nelas o padrão de conectividade entre os neurônios é inspirado na organização do córtex visual dos animais. Neurônios corticais individuais respondem a estímulos apenas em regiões restritas do campo de visão conhecidas como campos receptivos. Os campos receptivos de diferentes neurônios se sobrepõem parcialmente de forma a cobrir todo o campo de visão.

Uma CNN demanda mínimo pre-processamento quando comparada a outros algoritmos de classificação de imagens. Isso significa que a rede "aprende" os filtros que em um algoritmo tradicional precisariam ser implementados manualmente. Essa independência de um conhecimento a priori e do esforço humano no desenvolvimento de suas funcionalidades básicas pode ser considerada a maior vantagem de sua aplicação.

Para este trabalho, foi escolhida a CNN VGG16, nomeada pelo grupo Visual Geometry Group que a desenvolveu. A rede proposta por [Han et al. 2015] tem sua arquitetura demonstrada na Figura 3, composta por convoluções seguidas por pooling.

### 3.2.1 Extração de Características com VGG16 pré treinada

A extração das características usando a VGG16 pré treinada consiste inicialmente em carregar a arquitetura juntamente dos pesos da Imagenet, com a finalidade de aproveitar o treinamento básico de suas características. Depois é removido seu classificador e inserido uma camada de Global Average Pooling para a saída da rede ser um vetor de características.



### 3.2.2 Extração de Características com VGG16 otimizada

Este método também implementa extração de características da rede VGG16 otimizada para o problema específico.

O processo de otimização consiste em analisar resultados de modelos anteriores para sugerir novos parâmetros para um próximo modelo. Assim, a cada novo modelo, o resultado tende a ser mais positivo. Os parâmetros que o algoritmo de otimização pode escolher são determinados em um espaço de busca referenciado na Tabela 1.



Tabela 1. Espaço de Busca

Parâmetros	Opções de Busca		
	0	1	2
Quantidade de convoluções	0	1	2
Camada de saída	block5 convolução 3	block5 convolução 2	
Pooling	Average Pooling	Max Pooling	
Quantidade de neurônios	256	128	
Quantidade de denses	1	2	
Classificador	Sigmoid	Softmax	
Dropout	0.5	0.4	0.3
Class weight	TRUE	FALSE	

O otimizador foi implementado sobre a biblioteca HyperOpt que disponibiliza o algoritmo Tree-Structured Parzen Estimator (TPE) [Bergstra et al. 2013]. Segundo [Fernandes et al. 2019], o algoritmo TPE se 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.

Após a estimação do melhor modelo, utiliza-se o melhor modelo estimado para extração das características. A extração das características da VGG16 com fine tuning é um processo similar ao da rede pura, explicado na seção anterior. A suposição é que as características geradas de maneira específica podem incluir informações complementares para determinar os padrões nas imagens.

### 3.3 TREINAMENTO

Após ter as características extraídas e armazenadas, seguiu-se para a etapa de classificação. Nesta fase, é utilizado o classificador Regressão Logística [Yu et al. 2011]. Este foi escolhido por trabalhar bem com características lineares, as quais são esperadas como saída das redes utilizadas.

Na regressão logística, a probabilidade de ocorrência de um evento pode ser estimada diretamente. No caso da variável dependente  $Y$  assumir somente dois possíveis estados e haver um conjunto de  $p$  variáveis independentes  $X_1, X_2, \dots, X_p$  o modelo de regressão logística pode ser escrito da seguinte forma:



$$P(Y = 1) = \frac{1}{1 + e^{-g(x)}} \quad (1)$$

onde,  $g(x) = B_0 + B_1X_1 + \dots + B_pX_p$ .

Os coeficientes  $B_0, B_1, \dots, B_p$  são estimados a partir do conjunto de dados, pelo método da máxima verossimilhança, em que encontra uma combinação de coeficientes que maximiza a probabilidade da amostra ter sido observada. Considerando uma certa combinação de coeficientes  $B_0, B_1, \dots, B_p$  e variando os valores de  $X$ , observa-se que a curva logística tem um comportamento probabilístico no formato da letra S.

Por causa de seu comportamento, a Regressão Logística é muito utilizada para classificação de classes discretas, como no caso do glaucoma. Para esta base é definido glaucoma como 1 e normais como 0. Assim classificando as características de acordo, com  $> 0,5$  como 1 e  $< 0,5$  como 0.

Utilizando a regressão logística, metodologia proposta realiza 3 experimentos de classificação. O primeiro usando apenas as características da VGG16 original, o segundo usando as características da VGG16 otimizada e o terceiro concatenando os dois conjuntos de características.

Os três experimentos foram conduzidos com a base dividida em treino, teste e validação, sendo que 70% foi para o treino e 30% para validação e teste. Após a divisão o classificador é treinado e testado, tendo as métricas de avaliação armazenadas.

### 3.4 AVALIAÇÃO

Com a extração e classificação concluídas, começa a etapa de avaliação das métricas. As métricas avaliadas são: sensibilidade, precisão, especificidade, fscore e acurácia.

Primeiramente é calculada a matriz de confusão. A partir dos índices da matriz, são calculadas as métricas demonstradas nas equações abaixo:

$$\text{Sensibilidade} = \frac{tp}{tp + fn} \quad (2)$$

$$\text{Precisão} = \frac{tp}{tp + fp} \quad (3)$$

$$\text{Especificidade} = \frac{tn}{tn + fp} \quad (4)$$

$$\text{Acurácia} = \frac{tp + tn}{tn + tp + fn + fp} \quad (5)$$

$$\text{F 1 score} = 2 \frac{\text{Precisão} \cdot \bar{\text{Sensibilidade}}}{\text{Precisão} + \bar{\text{Sensibilidade}}} \quad (6)$$

onde tp = verdadeiro positivo, tn = verdadeiro negativo, fp = falso positivo, fn = falso negativo.

#### 4 RESULTADOS

Neste trabalho é desenvolvido um método para diagnóstico de glaucoma baseado em extração de características utilizando Redes Neurais Convolucionais. São extraídas as características de duas redes: a VGG16 original e a VGG16 otimizada para o problema específico do diagnóstico. Após a extração são realizados três experimentos, sendo eles a classificação do vetor das características da VGG16 pré-treinada, do vetor da VGG16 com fine tuning e da concatenação dos dois vetores.

Para o aperfeiçoamento da VGG16, foi executado um total de 35 testes ao longo de 5 dias. O melhor modelo gerado atingiu a acurácia de 88,22% e os parâmetros escolhidos pelo otimizador estão referenciados na Tabela 2.

Tabela 2. Melhores parâmetros escolhidos

Parâmetros	Opções escolhidas
Quantidade de convoluções	1
Camada de saída	block5 convolução 3
Pooling	Average Pooling
Quantidade de neurônios	256
Quantidade de denses	2
Classificador	Sigmoid
Dropout	0.3
Class weight	TRUE

Utilizando o modelo gerado, foram realizados os três experimentos que combinam características geradas por cada rede. Os resultados obtidos são apresentados na Tabela 3.

Tabela 3. Resultados da classificação das características

Características	Sensibilidade	Especificidade	Precisão	F-score	Acurácia
VGG16 original	0,510	0,814	0,688	0,586	0,679
VGG16 fine tuning	0,863	0,868	0,835	0,849	0,863
Concatenação	0,868	0,868	0,848	0,857	0,868

Ao analisar os resultados, observamos que os melhores resultados acontecem com a concatenação de características, mesmo que a diferença seja pequena em relação a rede estimada. As melhoras acontecem em todos os índices verificados. Esta melhora se dá ao fato de a base de dados do classificador ter sido bem maior em relação aos outros dois experimentos, já que, enquanto que no primeiro e segundo experimento a base utilizada pelo classificador foi um vetor de características, no terceiro sua base foi a concatenação dos dois vetores. Embora melhores, os resultados da concatenação são similares aos da rede específica, isso se dá pelo fato do classificador ter aprendido o mesmo tanto na concatenação quanto na rede específica.

Verifica-se que a otimização da VGG16 para o problema específico do glaucoma atingiu métricas melhores do que a VGG16 original. Assim evidenciado pela discrepância em precisão com a original tendo uma precisão de 68.88% e a VGG16 com fine tuning obtendo uma precisão de 83.56%. A VGG16 original teve uma certa dificuldade em classificar os olhos glaucomatoso e normais, porque seus pesos originais são da base de dados Imagenet que não inclui imagens de olhos glaucomatosos ou normais. Já a rede especificada pelo otimizador teve a chance de treinar utilizando a base de dados de glaucoma assim tendo seus pesos ajustados para o problema específico e obtendo um melhor desempenho.

## 5 CONCLUSÃO

Neste trabalho foi proposto um método baseado em extração de características utilizando Redes Neurais Convolucionais com a finalidade de diagnosticar imagens de fundo de olhos e detectar glaucoma. O método consiste na extração de características de 2 redes diferentes sendo elas a VGG16 original e uma rede VGG16 com parametrização otimizada para problema específico.

O método proposto obteve como melhor resultado a sensibilidade de 0,868 e uma especificidade de 0,848. Ressalte-se que esses resultados foram obtidos com uma base de dados complexa e algo grau de diversidade constituída pela junção de vários datasets. Verifica-se que esses resultados são comparáveis aos melhores resultados publicados como em [Diaz-

Pinto et al. 2019]. Nosso trabalho apresenta especificidade melhor e um balanceamento entre sensibilidade e especificidade muito bom.

Pretende-se explorar como trabalhos futuros outras arquiteturas de redes convolucionais mais complexas como a DenseNet pro exemplo e uma estimação mais ampla da rede especializada como forma de melhoria dos resultados. Além disso, pretende-se aumentar a base de dados através do adicional de mais bases públicas como a base ACRIMA [Diaz-Pinto et al. 2019].

## REFERÊNCIAS

Abbas, Q. (2017). Glaucoma-deep: detection of glaucoma eye disease on retinal fundus images using deep learning. *Int J Adv Comput Sci Appl*, 8(6):41–5.

Bar, Y., Diamant, I., Wolf, L., and Greenspan, H. (2015). Deep learning with non-medical training used for chest pathology identification. In *Medical Imaging 2015: Computer-Aided Diagnosis*, volume 9414, page 94140V. International Society for Optics and Photonics.

Bergstra, J., Yamins, D., and Cox, D. D. (2013). 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.

Dhungel, N., Carneiro, G., and Bradley, A. P. (2016). The automated learning of deep features for breast mass classification from mammograms. In *International Conference on Medical Image Computing and Computer-Assisted Intervention*, pages 106–114. Springer.

Diaz-Pinto, A., Morales, S., Naranjo, V., Kohler, T., Mossi, J. M., and Navea, A. (2019). Cnns for automatic glaucoma assessment using fundus images: an extensive validation. *Biomedical engineering online*, 18(1):29.

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.

Fumero, F., Alayón, S., Sanchez, J., Sigut, J., and Gonzalez-Hernandez, M. (2011). Rim-one: An open retinal image database for optic nerve evaluation. pages 1 – 6.

Han, S., Mao, H., and Dally, W. J. (2015). Deep compression: Compressing deep neural networks with pruning, trained quantization and Huffman coding. arXiv preprint arXiv:1510.00149.

LeCun, Y. et al. (1989). Generalization and network design strategies. *Connectionism in perspective*, 19:143–155.

linchundan (2018). 1000 fundus images with 39 categories.

Matsugu, M., Mori, K., Mitari, Y., and Kaneda, Y. (2003). Subject independent facial expression recognition with robust face detection using a convolutional neural network. *Neural Networks*, 16(5-6):555–559.

Mittapalli, P. S. and Kande, G. B. (2016). Segmentation of optic disk and optic cup from digital fundus images for the assessment of glaucoma. *Biomedical Signal Processing and Control*, 24:34–46.

of Technology, B. I. (2018). *ichallenge-gon*.

Orlando, J. I., Prokofyeva, E., del Fresno, M., and Blaschko, M. B. (2017). Convolutional neural network transfer for automated glaucoma identification. In 12th international symposium on medical information processing and analysis, volume 10160, page 101600U. International Society for Optics and Photonics.

Quigley, H. A. and Broman, A. T. (2006). The number of people with glaucoma worldwide in 2010 and 2020. *British journal of ophthalmology*, 90(3):262–267.

Raghavendra, U., Fujita, H., Bhandary, S. V., Gudigar, A., Tan, J. H., and Acharya, U. R. (2018). Deep convolution neural network for accurate diagnosis of glaucoma using digital fundus images. *Information Sciences*, 441:41–49.

Raja, C. and Gangatharan, N. (2015). A hybrid swarm algorithm for optimizing glaucoma diagnosis. *Computers in biology and medicine*, 63:196–207.

Tajbakhsh, N., Shin, J. Y., Gurudu, S. R., Hurst, R. T., Kendall, C. B., Gotway, M. B., and Liang, J. (2016). Convolutional neural networks for medical image analysis: Full training or fine tuning? *IEEE transactions on medical imaging*, 35(5):1299–1312.

Thylefors, B. and Negrel, A. (1994). The global impact of glaucoma. *Bulletin of the World Health Organization*, 72(3):323.

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.