

Diagnóstico Automático de Glaucoma Utilizando Transfer Learning

João Marcello Mendes Moreira, João Dallyson Souza de Almeida¹, Geraldo Braz Júnior¹

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

Resumo. O glaucoma é uma doença que degrada o nervo óptico causando perda irreversível da visão e cujos sintomas costumam aparecer somente em estágios avançados da doença. Diagnósticos assistidos por computador já são uma realidade e auxiliam especialistas na correta classificação. Assim, este trabalho visa apresentar um método computacional para detecção de glaucoma utilizando Redes Neurais Convolucionais (CNN) e *Transfer Learning*. O método proposto apresentou resultados promissores, com 88,29% de acurácia, 84,27% de sensibilidade e 91,56% de especificidade, utilizando a arquitetura VGG-16 para extração de características e uma CNN para classificação com os hiperparâmetros otimizados.

1. Introdução

O termo glaucoma engloba um conjunto de doenças ópticas com inúmeras causas, porém com características comuns, que formam um quadro clínico semelhante e que levam à perda total e irreversível da visão. São elas: o aumento da pressão intraocular, perdas campimétricas, aumento da escavação e atrofia do nervo óptico. Nos últimos anos, vem crescendo o número de pesquisas envolvendo diagnósticos assistidos por computador, que são ferramentas que realizam a detecção de anomalias em exames de forma automatizada. Nesse contexto, surgem as Redes Neurais Convolucionais (CNN), atualmente o estado da arte em classificação de imagens. Uma das características das CNNs é o fato de exigirem uma grande quantidade de dados rotulados para a etapa de treinamento. Contudo, a aquisição de base de dados médicas rotuladas é, ainda hoje, um processo custoso, e muitas vezes, quase impossível de ser obtido. Nessa circunstância surge o *transfer learning*, técnica que busca melhorar o aprendizado de uma tarefa alvo a partir de uma tarefa fonte já compreendida. Utilizando-se do conhecimento da tarefa fonte, o *transfer learning* nos permite ter um melhor desempenho inicial na tarefa alvo, diminuir o tempo necessário para aprendê-la totalmente e, ainda, melhorar o desempenho final da mesma, quando comparado ao desempenho final sem o *transfer learning*.


Assim, esta pesquisa teve como objetivo avaliar a utilização de técnicas de *transfer learning* para detecção de glaucoma em retinografias utilizando redes neurais convolucionais.

2. Metodologia

O método proposto está organizado em cinco etapas: (1) Aquisição de imagens, (2) Pré-processamento, (3) Extração de características, (4) Definição e treinamento de uma nova rede neural, e (5) Classificação e Validação dos resultados. O conjunto de imagem utilizado neste trabalho inclui imagens de oito bases públicas: RIM-ONE versão 1, 2 e 3, JSIEC, iChallenge-GON, Acrima, Hrf e Dhristhi, totalizando 2086 imagens, todas com a região do disco óptico segmentada, das quais 10% foram separadas para ser utilizada como teste. Na etapa de pré-processamento utilizou-se uma função para normalização de cor, seguida da remoção de ruídos que substitui os pixels de uma imagem com a média das cores de pixels similares, e uma última função que aplica o Clahe, uma equalização de histograma baseada em regiões da imagem. Aplicou-se ainda a extração da média dos

canais de cores e a normalização *min-max*. Em seguida, para utilizar o *transfer learning*, todas as imagens foram passadas para a rede pré-treinada VGG-16 sem as 5 últimas camadas, gerando, para cada imagem, um vetor de dimensões 14x14x512, representando as características das mesmas. Extraídas as características, estas são encaminhadas para uma nova rede neural, que atua como classificador, baseada nas camadas extraídas da VGG-16. No treinamento, utilizou-se o *hyperopt* para estimar os melhores hiperparâmetros e a validação cruzada com 10 *folders*. A rede neural otimizada possui 8 camadas.

3. Resultados



4. Conclusão

Esta pesquisa visou avaliar a utilização do *transfer learning* para o treinamento de CNNs a fim de diagnosticar glaucoma em retinografias. Utilizou-se a VGG-16 como extrator de características e a biblioteca *hyperopt* para estimar os melhores hiperparâmetros e definir a arquitetura de uma CNN treinada para realizar a classificação. Diferentemente da tendência a aumentar a profundidade das redes neurais para melhora dos resultados (como a arquitetura ResNet, que pode chegar a 100 camadas), este estudo mostrou que o uso do *transfer learning* torna possível obter resultados condizentes com a literatura sem aumentar desnecessariamente a profundidade da rede treinada, reduzindo o custo computacional.

A importância de trabalhos como o deste estudo é notável, uma vez que utilizar diagnósticos assistidos por computador para detecção do glaucoma pode acelerar o processo de detecção da doença, reduzir custos e subsidiar a decisão do oftalmologista, além de auxiliar na triagem dos pacientes, diminuindo o tempo de espera dos resultados dos exames e, conseqüentemente, aliviando o sistema público de saúde.

Referências

- PAN, S. J. e YANG, Q. *A Survey on Transfer Learning*. IEEE Transactions On Knowledge And Data Engineering, Vol. 22, No. 10, 2010.
- PAUL, R. et al. *Deep Feature Transfer Learning in Combination with Traditional Features Predicts Survival Among Patients with Lung Adenocarcinoma*. Tomography – A Journal for Imaging Research, 2016.
- SIMONYAN, K. e ZISSERMAN, A. *Very Deep Convolutional Networks For Large-Scale Image Recognition*. Visual Geometry Group, Department of Engineering Science, University of Oxford, ICLR, 2015.