

Teste automático de Bruckner utilizando Redes Neurais Convolucionais

Antônio M. Pinto¹, João D. S. Almeida¹, Geraldo Braz Júnior¹, Italo F. S. Silva¹

¹ Universidade Federal do Maranhão – São Luís, MA – Brasil
Laboratório de Visão e Processamento de Imagens - VIPLab

{antoniomp, jdallyson, geraldo, francyles}@nca.ufma.br

Resumo. *Este trabalho propõe novas formas de utilização de redes neurais convolucionais, com o objetivo de classificar pacientes submetidos ao teste de Bruckner. Foi possível alcançar 83,2% de acurácia na detecção de problemas oculares, em 128 imagens.*

1. Introdução

O teste de Bruckner, conhecido como "teste do olhinho", consiste na observação do reflexo vermelho da retina do paciente com o auxílio de um oftalmoscópio. Com este teste, é possível detectar de maneira precoce, sutis opacidades e assimetria entre os reflexos gerados na pupila, indicando possíveis patologias oculares.

Tradicionalmente, o teste de Bruckner não é realizado sem a presença de um especialista e o equipamento apropriado. Com a finalidade de promover mais qualidade de vida e detecção precoce de doenças oculares, este trabalho propõe um método para a execução do teste através de modelos de inteligência artificial, utilizando processamento de imagens, redes neurais, árvores de decisão, segmentação semântica e *data augmentation*.

Com objetivo semelhante, Silva et al. (2018) propuseram um método para realizar o teste de Bruckner em imagem utilizando métodos de classificação clássicos, como *Support Vector Machines*, histogramas de cores, matrizes de co-ocorrência e entre outros. Diferente deste, propomos um novo método baseado em redes neurais convolucionais.

2. Metodologia

Neste trabalho foi utilizada a mesma base de imagens de Silva et al. (2018). Esta base é organizada da seguinte forma: 88 imagens de olhos saudáveis e 30 imagens de olhos com problemas. Para cada imagem, também há uma máscara da região de interesse. O modelo foi testado utilizando validação cruzada com 10 *splits*.

Com a finalidade de estender o tamanho da base de dados de treinamento, ela foi ampliada através de técnicas de processamento de imagem. As amostras normais foram ampliadas em 10 vezes o seu tamanho original e as amostras problemáticas em 30, para que houvesse mais balanceamento entre as informações. Foram aplicadas transformações que não distorcessem a morfologia do olho, como translações, rotações, espelhamento e mudanças de resolução.

O modelo utilizado é uma união entre o classificador *random forest* e uma rede neural siamesa. Esta rede neural foi treinada a partir da função de perda *triplet-loss*, que

é fundamental para que uma rede convolucional consiga aprender informações novas em uma base de tamanho pequeno [Dong and Shen 2018].

A rede neural, foi treinada por 150 épocas, parando o treino caso não houvesse convergência em 15 épocas consecutivas, com um *batch* de tamanho igual a 4 e o otimizador adam. Devido à maneira como a *triplet-loss* se comporta, baseada em distância, a camada de ativação final foi substituída pela norma l2.

Após seu treino, a rede neural produziu novas características às imagens. Então, o classificador *random forest* utilizou-as junto às características como: matrizes de co-ocorrência, histograma de cores global, momentos de Zernike e momentos de Hu. Foram testados diferentes espaços de cores, como RGB, HSV, HLS, YCrCb e Lab.

3. Resultados preliminares

O melhor resultado, entre as combinações de testes, foi obtido com a utilização da rede neural siamesa combinada com o classificador *random forest*, junto ao histograma de cores global da imagem, como pode ser visto na tabela 1. O experimento conseguiu alcançar, em média, 83,2% de acurácia, usando o espaço de cores RGB. Este experimento alcançou 84,1% de especificidade e 80,0% de sensibilidade, que é uma métrica valiosa considerando que o objetivo é produzir um sistema de triagem.

	Acurácia	Acurácia Balanceada	Sensibilidade	Especificidade
RGB	83,2%	82,0%	80,0%	84,1%
HSV	76,8%	80,0%	86,6%	73,3%
YCrCb	76,0%	67,4%	50,0%	84,8%
HLS	72,7%	60,8%	36,6%	85,0%
Lab	68,7%	57,2%	33,3%	81,1%

Tabela 1. Resultados com histograma de cores global e CNN

4. Conclusão

Este trabalho conseguiu alcançar resultados promissores, porém ainda não supera os métodos clássicos apresentados pelo trabalho de Silva et al. (2018). Contudo, espera-se que com este trabalho seja possível estabelecer novas formas de utilizar redes neurais convolucionais para classificação, mesmo com poucas instâncias para treinamento, visando métricas adequadas às proporções da base.

Como trabalhos futuros, espera-se utilizar meta-classificadores para aprimorar o uso das características geradas pela rede.

Referências

- Dong, X. and Shen, J. (2018). Triplet loss in siamese network for object tracking. In *The European Conference on Computer Vision (ECCV)*.
- Silva, I. F., Almeida, J. D., Teixeira, J. A., Junior, G. B., and de Paiva, A. C. (2018). Teste automático de brückner baseado em imagens. In *Anais Principais do XVIII Simpósio Brasileiro de Computação Aplicada à Saúde*. SBC.