



UNIVERSIDADE ESTADUAL DE FEIRA DE SANTANA

Autorizada pelo Decreto Federal nº 77.496 de 27/04/76
Recredenciamento pelo Decreto nº 17.228 de 25/11/2016



PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
COORDENAÇÃO DE INICIAÇÃO CIENTÍFICA

XXVI SEMINÁRIO DE INICIAÇÃO CIENTÍFICA DA UEFS **SEMANA NACIONAL DE CIÊNCIA E TECNOLOGIA - 2022**

Avaliação da influência do espaço de cor no desempenho de classificadores de lesão glomerular do projeto PathoSpotter.

Daniel Alves Costa¹; Angelo Amâncio Duarte²

1. Bolsista PIBIC/CNPq, Graduando em Engenharia da Computação, Universidade Estadual de Feira de Santana, e-mail: dancostafsa@hotmail.com
2. Orientador, Departamento de Tecnologia, Universidade Estadual de Feira de Santana, e-mail: angeloduarte@uefs.br

PALAVRAS-CHAVE: computational pathology; computational vision; image retrieval, nephropathology.

INTRODUÇÃO

Com o avanço da computação e a sua constante parceria com a área da medicina, a qualidade e confiabilidade dos diagnósticos está sendo impactada. Cada néfron presente nos rins de um ser humano, possui um grupo de capilares glomerulares chamado *glomérulo*, este funcionando como um filtro de líquidos presentes no sangue (Guyton & Hall, 2017). Algumas patologias podem acometer esses glomérulos, resultando em problemas na saúde das pessoas. Devido a isso, o sistema PathoSpotter foi desenvolvido, este possuindo a capacidade para classificar imagens de glomérulos renais que apresentem, ou não, glomerulopatias (Barros et al., 2016).

Ganesan et al. (2019) dizem que, *espaços de cor* são representações matemáticas que servem para descrever como as cores são percebidas e representadas em um sistema de cores, com cada espaço de cor possuindo um conjunto de coordenadas que descrevem as cores dentro do mesmo. Estudos já mostram que alterar o espaço de cor de amostras de redes neurais pode impactar positivamente o seu resultado (Gowda & Yuan, 2019)(Podpora et al., 2014).

Com esses estudos já realizados é notável que é possível conseguir uma melhora no desempenho de classificadores quando o espaço de cor do conjunto de imagens utilizadas é alterado. A partir disto, este projeto possui o objetivo de avaliar o desempenho de classificadores de lesões glomerulares, já presentes no projeto PathoSpotter, quando diferentes espaços de cor, selecionados para este trabalho, são aplicados na base de dados utilizada.

MATERIAL E MÉTODOS OU METODOLOGIA (ou equivalente)

Para a realização deste trabalho foram definidas etapas para que seguisse um critério e os resultados da pesquisa não fossem enviesados. Essas etapas foram divididas da seguinte forma:

1. Montagem do conjunto de dados

Com um total de 2.588 imagens digitais de glomérulos, disponibilizado pelo projeto PathoSpotter. Estas separadas em seis diferentes diagnósticos de glomérulos, e, dentro dessas classificações, possuindo cinco diferentes corantes, porém de forma desbalanceada entre elas, ficando algumas classificações sem algum corante.

Devido a algumas classes só possuírem a coloração do tipo HE, foi definido, como forma de testagem para este trabalho, que só seriam utilizadas as imagens do corante HE de todas as classes, para que, com isso o classificador seja formado por uma quantidade de dados mais balanceado e igualitário com relação aos tipos de lesões. Finalizando um conjunto de dados total para o treinamento de 1.373 imagens de glomérulos com lesões e saudáveis.

Após essa separação com relação aos corantes, o projeto foi dividido de forma binária, entre lesionados e normais, com 50,25% de imagens de glomérulos normais e o restante pertencente a glomérulos com lesão.

2. Conversão das imagens

Para a conversão do espaço de cor RGB, padrão inicial das imagens, para os outros espaços de cor foi utilizada a biblioteca Scikit-Image (Van Der Walt et al., 2014), a qual já disponibiliza métodos prontos para realizar essa conversão. A partir de outros estudos relacionados a área de classificação de imagens, nos quais a alteração do espaço de cor obteve resultados consideráveis, foram selecionados os espaços: HED (Hematoxylin, Eosin, Diaminobenzidina), HSV (Hue, Saturation e Value), LAB (Luminescence, A=red/green e B=blue/yellow), LUV (Luminescence, Saturation e Hue Angle), RGB (Red, Green, Blue) e YCbCr (Y=Luminescence, Cb=Blue-difference chroma, Cr=Red-difference chroma) para o desenvolvimento deste projeto (Ganesan et al., 2019)(Barros et al., 2016)(Gowda & Yuan, 2019).

3. Treinamento das redes neurais

Como forma de buscar os resultados para realizar a avaliação de desempenho, foi utilizado o treinamento de classificadores já existentes em conjunto com a técnica de *Transfer Learning*, buscando melhorar a aprendizagem dos classificadores, na qual consiste em utilizar um extrator de características de uma rede neural já treinada em um novo classificador. Numa pesquisa realizada em busca de redes neurais que pudessem ser utilizadas neste projeto se destacaram os seguintes modelos: InceptionV3 (Szegedy, 2016), a VGG16 (Simonyan & Zisserman, 2014) e a EfficientNetB7 (Tan & Le, 2019).

4. Validação Cruzada ou Cross-Validation

Buscando melhores resultados e redução ao máximo de overfitting foi utilizado o método de reamostragem chamado de *validação cruzada*, sendo um dos mais utilizados para estimar a previsão verdadeira dos erros de um modelo e busca ajustar seus parâmetros (Berrar, 2019). A partir disso, foi determinado, a partir do conjunto de dados disponível, a divisão em 80% dos dados para treino e validação e 20% para teste. Por fim, o conjunto final de dados ficou com: conjunto de dados de treino, variado conforme *validação cruzada*, conjunto de dados de validação, variado conforme *validação cruzada* e o conjunto de dados de teste, sendo fixo.

RESULTADOS E/OU DISCUSSÃO (ou Análise e discussão dos resultados)

Para melhor entendimento os resultados foram divididos em três subseções: 1 - Sem Cross-Validation, 2 - Com Cross-Validation e 3 - Avaliação Comparativa. A subseção 1 abordará os resultados obtidos do primeiro experimento, ou seja, redes neurais quando não utilizada a técnica de cross-validation. A 2 mostrará os resultados dos experimentos das redes neurais quando utilizado o cross-validation. Já a 3 busca comparar e analisar os resultados obtidos anteriormente.

1. Sem Cross-Validation

Para o experimento sem a técnica de cross-validation, os resultados da acurácia obtida para cada rede em cada espaço de cor se encontram na tabela abaixo.

Tabela 1: Acurácia de cada classificador sem cross-validation em cada espaço de cor

Classificador	Espaço de cor					
	HED	HSV	LAB	LUV	RGB	YCbCr
InceptionV3	0.388	0.498	0.380	0.608	0.278	0.593
VGG16	0.725	0.183	0.816	0.183	0.816	0.475
EfficientNetB7	0.710	0.703	0.710	0.703	0.597	0.597

A partir dos resultados desse experimento, observados na Tabela 1, podemos iniciar concluindo que os espaços HED e LAB resultam em um melhor desempenho dos classificadores. Buscando uma melhor validação desse resultado, o cross-validation foi aplicado e os resultados se encontram logo abaixo.

2. Com Cross-Validation

Com os resultados do cross-validation foram aplicados o total de três folds para a realização do experimento, após isso, para obter o valor da acurácia dessas redes foi feita uma média aritmética com os valores obtidos nos experimentos, esses valores podem ser observados na Tabela 2.

Tabela 2: Média das acurácias de cada classificador com cross-validation em cada espaço de cor

Classificador	Espaço de cor					
	HED	HSV	LAB	LUV	RGB	YCbCr
InceptionV3	0.677	0.748	0.748	0.539	0.639	0.569
VGG16	0.435	0.816	0.605	0.675	0.601	0.380
EfficientNetB7	0.816	0.816	0,707	0,743	0,743	0,743

3. Avaliação Comparativa

Com esses dois resultados anteriores podemos comprovar a validade da utilização da técnica de cross-validation, mostrando que ela retorna melhores resultados para o tipo de problema abordado neste projeto. E que, em questão de performance de cada espaço

de cor, não devemos considerar somente a média entre eles, a quantidade de vezes em que ele foi maior em cada fold de treinamento também deve ser levada em consideração. A partir disso, se resulta nos espaços HED e HSV aparecendo como melhores em cinco ocasiões e os espaços LUV e RGB em quatro.

CONSIDERAÇÕES FINAIS (ou Conclusão)

Com a realização deste projeto foi possível identificar que a utilização do espaço de cor HED e HSV pode resultar em melhores resultados para o conjunto de dados utilizados na confecção de classificadores de lesão glomerular, obtendo uma quantidade maior de resultados, cinco vezes, do valor de acurácia, diferente do atual espaço de cor utilizado, RGB, o qual só apareceu quatro vezes como melhor resultado. Com isso é possível dizer que em uma futura implementação do projeto PathoSpotter, é válido a troca do espaço de cor rgb das imagens recebidas no projeto para o espaço HED ou HSV, para se obter uma identificação mais precisa e confiável.

REFERÊNCIAS

- GUYTON, A.C.; HALL, J.E. 2017. Tratado de fisiologia médica. 13 ed. Rio de Janeiro: Elsevier.
- VAN DER WALT, S. et al. 2014. scikit-image: image processing in Python. PeerJ, v. 2, p. e453.
- BARROS, G.; DUARTE, A.; SANTOS, W. 2016. Pathospotter: Um sistema para classificação de glomerulopatias a partir de imagens histológicas renais. SIBGRAPI.
- GANESAN, P.; SATHISH, B.S.; VASANTH, K.; SIVAKUMAR, V.G.; VADIVEL, M.; RAVI, C.N. 2019. A Comprehensive Review of the Impact of Color Space on Image Segmentation. 5th International Conference on Advanced Computing & Communication Systems (ICACCS), Coimbatore, India, pp. 962-967.
- GOWDA, S.N.; YUAN, C. 2019. ColorNet: Investigating the importance of color spaces for image classification. In: Computer Vision–ACCV 2018: 14th Asian Conference on Computer Vision, Perth, Australia, December 2–6, 2018, Revised Selected Papers, Part IV 14. Springer International Publishing. p. 581-596.
- PODPORA, M.; KORBÁS, G.; KAWALA-JANIK, A. 2014. YUV vs RGB – Choosing a Color Space for Human-Machine Interaction. Annals of Computer Science and Information Systems.
- SZEGEDY, C. et al. 2016. Rethinking the inception architecture for computer vision. In: Proceedings of the IEEE conference on computer vision and pattern recognition. p. 2818-2826.
- SIMONYAN, K.; ZISSERMAN, A. 2014. Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556.
- TAN, M.; LE, Q. 2019. Efficientnet: Rethinking model scaling for convolutional neural networks. In: International conference on machine learning. PMLR. p. 6105-6114.
- BERRAR, D. 2019. Cross-validation. Encyclopedia of bioinformatics and computational biology, v. 1, p. 542-545.