



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

XXV SEMINÁRIO DE INICIAÇÃO CIENTÍFICA DA UEFS SEMANA NACIONAL DE CIÊNCIA E TECNOLOGIA - 2021

Classificador de lesão glomerular por amiloidose

Ellen Chalegre Aguiar¹; Angelo Amâncio Duarte²

1. Bolsista FAPESB, Graduando em Engenharia de Computação, Universidade Estadual de Feira de Santana, e-mail:

chalegreaguiar@gmail.com

2. Orientador, Departamento de Tecnologia, Universidade Estadual de Feira de Santana, e-mail:

angeloduarte@uefs.br

PALAVRAS-CHAVE: Patologia Computacional; Glomerulopatia; Amiloidose.

INTRODUÇÃO

O reconhecimento de lesões histológicas relevantes em diferentes enfermidades tem sido aprimorado a partir de correlações clinicopatológicas baseadas em espécimes de necropsia ou biópsias (VIRCHOW, 2009). A integração de novos conhecimentos faz emergir novas categorias de lesão, requerendo validação como marcadores de diagnóstico e prognóstico dos pacientes. Sistemas computacionais que permitam correlações clinicopatológicas em larga escala poderiam indicar novos marcadores histológicos de diagnóstico e prognóstico, pelo reconhecimento de novas lesões e pela reinterpretção do significado de lesões já conhecidas (SOCIETY et al., 2009; WEENING et al., 2004). Foi com base nessa premissa que pesquisadores do Centro de Pesquisa Gonçalo Moniz e da Universidade Estadual de Feira de Santana iniciaram o desenvolvimento do sistema PathoSpotter, um sistema computacional que propõe a utilização de técnicas de Inteligência Artificial para auxiliar no diagnóstico e prognóstico de doenças renais. Dando continuidade ao desenvolvimento do PathoSpotter, foi desenvolvido um classificador para identificação de lesões por amiloidose.

METODOLOGIA

As amiloidoses são um grupo diverso e heterogêneo de distúrbios caracterizados pelo achado comum de depósitos amiloides em vários tecidos e órgãos (HAWKINS, 1994). Monteiro e Diz declaram que a amiloidose é uma doença rara (MONTEIRO, 2015).

A. Conjunto de Dados

A partir da colaboração possível a partir do Projeto PathoSpotter, foram obtidas um total de 774 imagens digitais de glomérulos. Estas são de seis diferentes colorações, porém, de forma desbalanceada entre as mesmas. Para completar o conjunto de dados para o treinamento, ainda foram adicionadas 766 imagens de glomérulos normais.

B. Auto Machine Learning

O sucesso do uso de aprendizagem de máquina em várias áreas de aplicações levou a uma demanda crescente por sistemas que podem ser utilizados por pessoas que não especialistas (FEURER, 2019). Isto fez com que surgisse no ramo de aprendizagem de máquina a área que Hutter chama de AutoML (HUTTER, 2019). Esta procura remover a necessidade de um conhecimento profundo da área para a construção de modelos

eficientes. De acordo com Hutter et al., os métodos atuais de AutoML já superaram os especialistas em aprendizagem de máquina em diversas tarefas.

C. Transferência de Aprendizagem

Transfer learning é uma técnica utilizada para melhorar a aprendizagem em uma nova tarefa através de transferência de conhecimento de uma função anteriormente aprendida (TORREY; SHAVLIK, 2010). Assim é possível utilizar redes treinadas com abundância de dados em outro contexto para lidar com uma nova tarefa específica.

Numa pesquisa sobre redes neurais que generalizassem bem para outras tarefas, se destacaram a InceptionV3 (SZEGEDY, 2016), a ResNet50 (HE, 2016), a VGG16 (SIMONYAN; ZISSERMAN, 2014) e a Xception (CHOLLET, 2017). Considerou-se que, visto que não se sabe o que o Auto Machine Learning irá fazer, seria de bom-tom ter como comparar seus resultados com técnicas conhecidas. Desta forma, foram realizados experimentos de *transfer learning* nas quatro redes anteriormente citadas.

D. Solução do *overfitting*

Um dos problemas que pode-se enfrentar quando estamos lidando com um conjunto escasso de dados é o *overfitting*, que acontece quando uma rede neural aprende uma função com variância muito alta, de modo a modelar perfeitamente os dados de treinamento (SHORTEN; KHOSHGOFTAAR, 2019). Um dos sinais deste fenômeno é que a rede obtém ótimo resultado em seu conjunto de dados de treino e generaliza de forma péssima ou ruim para novos dados. É inadequado utilizar o conjunto de validação para teste, pois a rede é treinada para minimizar o erro nessas amostras; assim, estes autores propõem a criação de um terceiro grupo independente para validar o modelo (BURDEN, 1997). Com base nisso, o conjunto de dados foi dividido em 70% para treino e validação e 30% para teste. Outra solução para o *overfitting* foi o aumento de dados ou *data augmentation*, que engloba uma série de técnicas que aumentam o tamanho e a qualidade dos conjuntos de dados de treinamento (SHORTEN, 2019).

RESULTADOS E DISCUSSÃO

No experimento de Auto Machine Learning realizado com a biblioteca AutoKeras, foram observadas diversas métricas consideradas importantes para esta categoria de rede, isto é, com predição binária. A lista de parâmetros de avaliação e seus resultados para a melhor rede podem ser observados na Tabela 1. Foi feito um trecho de código para resumir as camadas da rede neural confeccionada. Nesta, pôde-se observar uma camada de nome EfficientNetB7 (TAN, 2019). Esta descoberta sugere que o AutoKeras (JIN, 2019) aplica a técnica de transferência de aprendizagem. Ainda foi observado no resumo que existem algumas camadas de rede cujo propósito é tratar os dados antes que estes sejam ensinados à rede neural.

Na Figura 1, percebe-se imediatamente que o terceiro fold do classificador baseado na ResNet50 tem a melhor acurácia categórica. Também é mais fácil observar que todas as redes mostraram dados pelo menos levemente diferentes, mostrando que foi significativa a aplicação da técnica de validação cruzada.

Tabela 1. Resultado das métricas observadas.

Métrica	Resultado
Perda	0.40616
Acurácia Binária	0.92424
Área Abaixo da Curva	0.96254
Precisão	0.88845
Recall	0.96957




Figura 1: acurácia de validação dos cinco k-folds das quatro redes que serviram de extrator de características.

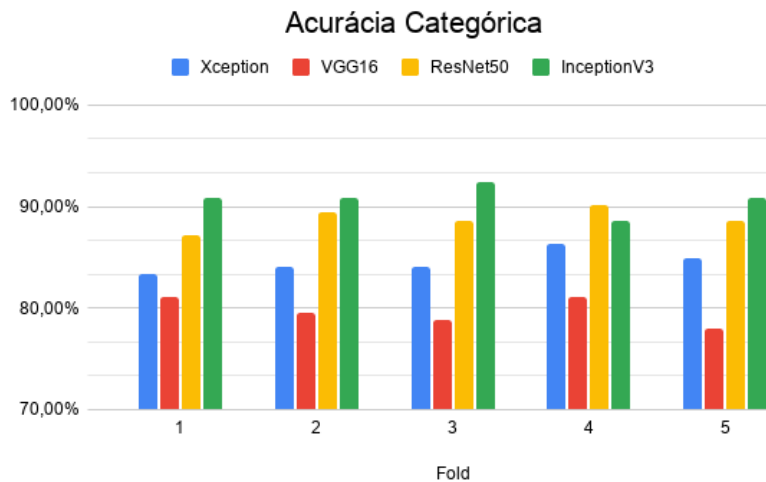


Figura 2: resultado para os testes em acurácia categórica das redes confeccionadas com o conjunto de teste

O resultado de cada um dos classificadores confeccionados pode ser observado na Figura 2. A acurácia geral diminui consideravelmente, com o mínimo descendo de 83% para 79%. O melhor classificador foi o da InceptionV3, que atingiu a melhor acurácia em quatro dos cinco k-folds (acima de 90%). As diferenças no desempenho do período de validação para o teste demonstram que foi válida a aplicação de uma verificação num conjunto jamais visto pela rede.

CONSIDERAÇÕES FINAIS

Neste trabalho foi construído classificador de lesão glomerular por amiloidose. Para tal, foram utilizadas diversas técnicas sugeridas por especialistas nos últimos anos, como *auto machine learning*, *transfer learning*, validação cruzada, partição em *folds*. O *auto*

machine learning foi testado e obteve resultados similares às técnicas já conhecidas e comprovadas por especialistas. Ao total, foram treinados 35 classificadores para chegar a um resultado de 92,42% de acurácia.

REFERÊNCIAS

- VIRCHOW, R. As Based upon Physiological and Pathological Histology: CELLULAR PATHOLOGY. *Nutrition Reviews*, v. 47, n. 1, p. 23–25, 27 abr. 2009.
- A WORKING GROUP OF THE INTERNATIONAL IGA NEPHROPATHY NETWORK AND THE RENAL PATHOLOGY SOCIETY et al. The Oxford classification of IgA nephropathy: pathology definitions, correlations, and reproducibility. *Kidney International*, v. 76, n. 5, p. 546–556, set. 2009.
- WEENING, J. J. et al. The Classification of Glomerulonephritis in Systemic Lupus Erythematosus Revisited. *Journal of the American Society of Nephrology*, v. 15, n. 2, p. 241–250, 1 fev. 2004.
- HAWKINS, P. N. Diagnosis and monitoring of amyloidosis. *Baillière's clinical rheumatology*, v. 8, n. 3, p. 635-659, 1994.
5. MONTEIRO, Natalia Fernandes; DIZ, Mary Carla Estevez. Dificuldades no diagnóstico da amiloidose primária: Relato de caso. *Revista Médica de Minas Gerais*, v. 25, n. 2, p. 280-286, 2015.
- FEURER, Matthias et al. Auto-sklearn: efficient and robust automated machine learning. In: *Automated Machine Learning*. Springer, Cham, 2019. p. 113-134.
- HUTTER, Frank; KOTTHOFF, Lars; VANSCHOREN, Joaquin. *Automated machine learning: methods, systems, challenges*. Springer Nature, 2019.
- TORREY, Lisa; SHAVLIK, Jude. Transfer learning. In: *Handbook of research on machine learning applications and trends: algorithms, methods, and techniques*. IGI global, 2010. p. 242-264.
- SZEGEDY, Christian et al. Rethinking the inception architecture for computer vision. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016. p. 2818-2826.
- HE, Kaiming et al. Deep residual learning for image recognition. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016. p. 770-778.
- SIMONYAN, Karen; ZISSERMAN, Andrew. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*, 2014.
- CHOLLET, François. Xception: Deep learning with depthwise separable convolutions. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2017. p. 1251-1258.
- SHORTEN, Connor; KHOSHGOFTAAR, Taghi M. A survey on image data augmentation for deep learning. *Journal of Big Data*, v. 6, n. 1, p. 1-48, 2019.
- BERRAR, Daniel. Cross-validation. *Encyclopedia of bioinformatics and computational biology*, v. 1, p. 542-545, 2019.
- BURDEN, Frank R.; BRERETON, Richard G.; WALSH, Peter T. Cross-validated selection of test and validation sets in multivariate calibration and neural networks as applied to spectroscopy. *Analyst*, v. 122, n. 10, p. 1015-1022, 1997.
- TAN, Mingxing; LE, Quoc. Efficientnet: Rethinking model scaling for convolutional neural networks. In: *International Conference on Machine Learning*. PMLR, 2019. p. 6105-6114.
- JIN, Haifeng; SONG, Qingquan; HU, Xia. Auto-keras: An efficient neural architecture search system. In: *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. 2019. p. 1946-1956.