

Estudo de redes Dense para Detecção de Pneumonia em Radiografias de Tórax Pediátricas

Antônio M. Pinto¹, Geraldo Braz Júnior¹

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

{antoniomp, geraldo}@nca.ufma.br

Resumo. Este artigo propõem modelos computacionais para detectar pneumonia em radiografias de tórax pediátricas. Os métodos propostos conseguiram detectar 98.97% dos casos em que a doença estava presente, prever o diagnóstico correto de 79.0% das infecções virais e 97.9% das infecções bacterianas.

1. Introdução

De acordo com a Organização Mundial da Saúde (OMS), a pneumonia é responsável por 19% das mortes de crianças menores de 5 anos. Esta doença é, consistentemente, a maior causa de mortalidade infantil no mundo, especialmente em países em desenvolvimento [Rudan et al. 2008].

O objetivo deste trabalho consiste em avaliar o desempenho das redes *dense* [Iandola et al. 2014] no contexto de detecção e diagnóstico de pneumonia em radiografias de tórax. São realizados dois experimentos com a rede: aprendizado do zero e fine tuning.

2. Metodologia

As imagens utilizadas para treinar os modelos de rede neural são radiografias de tórax de crianças diagnosticadas com pneumonia, viral ou bacteriana. As amostras foram coletadas a partir de crianças com 1 à 5 anos de idade do hospital Guangzhou Women and Children's Medical Center, Guangzhou, durante a rotina de acompanhamento dos pacientes [Kermany et al. 2018]. A rede neural foi treinada utilizando a mesma distribuição da publicação original. Antes do treino, a base foi ampliada com técnicas de processamento de imagem, com a finalidade de aprimorar os resultados finais e equilibrar a base.

Foram utilizadas duas abordagens de treino diferentes. Entre elas, *fine tuning* e aprendizado do zero. O processo também é descrito na Fig. 1, onde se pode visualizar os procedimentos.




Figura 1. Diagrama da execução dos experimentos.

As redes propostas seguiram a arquitetura Dense 121 [Iandola et al. 2014]. Todos os experimentos utilizaram o otimizador gradiente descendente estocástico, com uma taxa de aprendizado igual a $1e-2$, momento Nesterov e decaimento. O treino do zero durou 60 épocas. O processo com *fine tuning* durou, na etapa de sintonização durou 10 épocas, seguidas de 45 de treino completo. A rede foi inicializada com os pesos treinados pelo desafio *imagenet*, disponíveis na plataforma Keras [Chollet et al. 2015]

3. Resultados preliminares

Para realizar a detecção da pneumonia, utilizar o aprendizado do zero obteve o melhor resultado, detectando 99.0% casos de pneumonia e 81.1% das radiografias saudáveis, como pode ser visto na Tabela 1. Entretanto, considerando a métrica de acurácia como parâmetro, o melhor resultado foi obtido pela abordagem de treino com *fine tuning*, com uma sensibilidade marginalmente menor. Para a tarefa de diagnóstico, o melhor resultado foi obtido com treino do zero, acertando 79.0% dos casos virais e 97.9% dos casos com infecções bacterianas.

	Acurácia	Especificidade	Sensibilidade
Do zero	92.3%	81.1%	99.0%
Fine tuning	93.2%	84.1%	98.7%

Tabela 1. Resultados obtidos na tarefa de detecção.

4. Conclusão

Neste trabalho foram desenvolvidas e testadas aplicações para redes *dense*, utilizando diferentes técnicas de aprendizado profundo. Então foi testado que a rede neural profunda Dense 121 consegue apresentar um desempenho adequado na tarefa de classificação. Ainda assim, não supera o estado da arte [Rajaraman et al. 2018], apesar de atualmente superar os outros métodos publicados.

Referências

- Chollet, F. et al. (2015). Keras. <https://keras.io>.
- Iandola, F., Moskewicz, M., Karayev, S., Girshick, R., Darrell, T., and Keutzer, K. (2014). Densenet: Implementing efficient convnet descriptor pyramids. *arXiv preprint arXiv:1404.1869*.
- Kermany, D. S., Goldbaum, M., Cai, W., Valentim, C. C., Liang, H., Baxter, S. L., McKeown, A., Yang, G., Wu, X., Yan, F., et al. (2018). Identifying medical diagnoses and treatable diseases by image-based deep learning. *Cell*, 172(5):1122–1131.
- Rajaraman, S., Candemir, S., Kim, I., Thoma, G., and Antani, S. (2018). Visualization and interpretation of convolutional neural network predictions in detecting pneumonia in pediatric chest radiographs. *Applied Sciences*, 8(10):1715.
- Rudan, I., Boschi-Pinto, C., Biloglav, Z., Mulholland, K., and Campbell, H. (2008). Epidemiology and etiology of childhood pneumonia. *Bulletin of the world health organization*, 86:408–416B.