



Aplicação de Inteligência Artificial na Classificação de Imagens Médicas

Palavras-Chave: Inteligência Artificial, Radiologia, *Machine Learning*

Autores/as:

Yves Kamal dos Santos Soares – UNICAMP

Prof.^a Dr.^a Nelson Afonso Lutaif - UNICAMP

Financiamento: PIBIC/CNPq

INTRODUÇÃO:

Os conhecimentos científico e tecnológico estão em constante evolução. Esse processo de desenvolvimento trouxe uma tecnologia eficaz e inovadora: a inteligência artificial (IA) que é caracterizada por um conjunto de operações e habilidades desempenhadas por máquinas que mimetizam o raciocínio humano, capaz de analisar dados de forma não linear, gerar aplicações a partir de modelos prévios e aprendizado construído através de exemplos^{1,2}.

Dentre as diversas áreas médicas, a radiologia é potencialmente uma das primeiras a ser influenciada pela IA, pois é um campo que lida com trabalhos processuais de reconhecimento de padrões de imagens a fim de auxiliar em intervenções e diagnósticos.

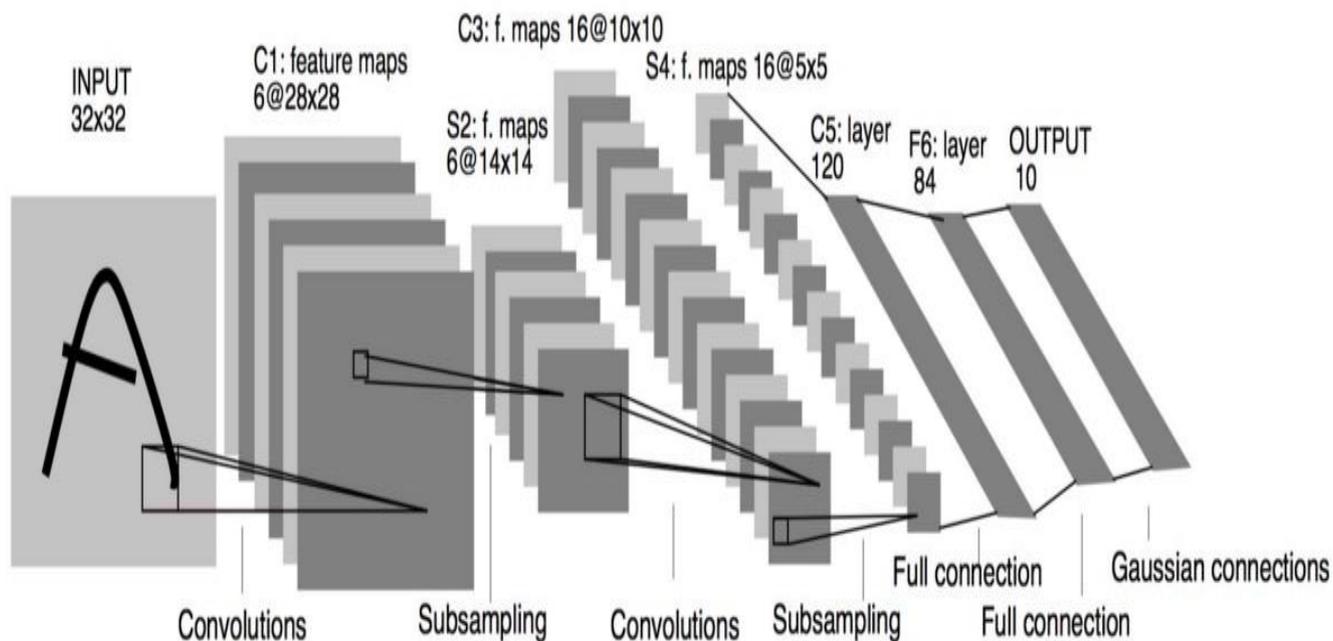
O presente trabalho, continuação do mesmo projeto em ano prévio, objetiva não só desenvolver um software de Machine Learning em Tensor Flow treinado com uma biblioteca de imagens de tomografia computadorizada do HC da Unicamp e do dataset imagens COVID (criado pela sociedade norte americana de radiologia), de modo a fornecer uma ferramenta para os sistemas de saúde, otimizando a eficácia diagnóstica dos mesmos e servindo como auxílio ao médico generalista, mas também melhorar a acurácia obtida em relação ao anterior.

METODOLOGIA:

Sucintamente, uma rede neural convolucional funciona captando imagens de entrada, atribuindo diferenças e importâncias com posterior discriminação das imagens, após ser corretamente treinada. As operações das redes neurais mais básicas, e que também são implementadas no treinamento da rede deste trabalho, são: (1) as camadas de convolução, (2) *pooling* e (3) camada totalmente conectada².

Respectivamente, cada setor é responsável por: transformar conteúdo da imagem em dados; simplificação da informação em único valor e transformar o dado informativo da camada anterior em uma única linha que contém as informações extraídas. Após o correto treinamento da rede, o programa é capaz de executar a identificação de imagens através dos padrões prévios.

Foram coletadas através do programa Ària, 171 radiografias durante o ano de 2020. Todos exames pertenciam a pacientes com exame de PCR + para COVID. Foram separadas manualmente, após escrutínio diagnóstico, três grupos de imagens: Derrames pleurais (n=57), Consolidações (n=57) e Normais (n= 57) das imagens. Foram utilizadas 20% das imagens para treinamento, 10% para validação e 70% para o teste da rede.



Legenda: Esquema de funcionamento de uma rede neural convolucional. Retirado de: Y. Lecun, L. Bottou, Y. Bengio and P. Haffner, "Gradient-based learning applied to document recognition," in *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278-2324, Nov. 1998, doi: 10.1109/5.726791.

RESULTADOS E DISCUSSÃO:

A função de ativação de uma rede neural artificial é extremamente importante, uma vez que é responsável pelo aprendizado da rede. Essa função decide quais neurônios devem ser ativados, através da análise de informações que são julgadas importantes. Programamos a evolução do aprendizado da rede neural em diferenciar radiografias normais e radiografias com alterações compatíveis com lesões provocadas pelo SARS-COVID 19, optando-se por achados de pneumonias com aspecto de consolidação e derrames pleurais, diferentemente do trabalho do ano passado, onde o programa deveria diferenciar imagens normais de infectadas. Através de sucessivas iterações (30) com as imagens randomizadas de todos os 3 grupos, é possível observar uma taxa de acurácia ao final do processo (Taxa de Acurácia Final (33,33%).

CONCLUSÕES:

Como podemos observar, nossa taxa de acurácia foi bastante limitada, mesmo com incremento do número de imagens (95 para 171) e otimização da rede. Modelos de diagnóstico por imagem baseados em computadores dependem e muito do método de classificação ao qual foram submetidos. No nosso caso, por exemplo, redes neurais artificiais, modelo de inteligência artificial usado pelo *software*, tem a vantagem de aprenderem relação de input e output complexas e tem pouca dependência do conhecimento prévio, entretanto necessita de vários parâmetros para ajustar os classificadores, a complexidade computacional é alta e o *overtraining* geralmente é inevitável para sucesso final³.

No nosso caso, a modificação da rede para dados categóricos prejudica o valor preditivo final, sendo que esta alteração só se justifica possível mediante a uma quantidade muito grande de dados, preservando um grau de acurácia final aceitável. Em relação ao ano passado, onde a taxa de acurácia final foi de 89,9%, o programa fora treinado apenas para detecção entre imagens normais e com lesões pulmonares, o que facilitava a decisão da máquina, uma vez que trabalhava com certezas. Agora com

a delimitação de categorias e aumento do número de classes, a rede neural passou a operar com possibilidades mudando significativamente a decisão final tomada expressa por essa queda de acurácia.

BIBLIOGRAFIA

1. Gore JC. Artificial intelligence in medical imaging. *Magn Reson Imaging*. 2020;68:A1-A4. doi:10.1016/j.mri.2019.12.006
2. Geoff Currie, K. Elizabeth Hawk, Eric Rohren, Alanna Vial, Ran Klein. Machine Learning and Deep Learning in Medical Imaging: Intelligent Imaging. *Journal of Medical Imaging and Radiation Sciences*. 2019; vol. 50, Issue 4, Pages 477-487, ISSN 1939-8654. Disponível em:<https://doi.org/10.1016/j.jmir.2019.09.005>.
3. Bağcı U, Bray M, Caban J, Yao J, Mollura DJ. Computer-assisted detection of infectious lung diseases: a review. *Comput Med Imaging Graph*. 2012 Jan;36(1):72-84. doi: 10.1016/j.compmedimag.2011.06.002. Epub 2011 Jul 1. PMID: 21723090; PMCID: PMC3207027.