

## FERRAMENTA DIGITAL USANDO APRENDIZADO DE MÁQUINA PARA DIAGNÓSTICO DE DOENÇAS PULMONARES EM IMAGENS DE RAIOS-X

Rogério C. O. Júnior (EG)<sup>1,2</sup>, Alan B. Pavan (PQ)<sup>1,2</sup>

<sup>1</sup>Universidade Federal de Itajubá - UFQ

<sup>2</sup>Grupo de Estudos e Pesquisa em Machine Learning - GREMLING

**Palavras-chave:** Aplicativo para Smartphone (Android). Deep Learning. Deep Learning with PyTorch for Medical Image Analysis. Diagnóstico de Raios-X. Inteligência Artificial.

### Introdução

Esse projeto de iniciação científica teve como objetivo a criação de um aplicativo de celular que usa de Machine Learning para diagnóstico de doenças pulmonares e a criação de um novo banco com os dados de usuários. A intenção principal deste aplicativo é que ele funcione como uma ferramenta auxiliar/complementar aos médicos, que algumas vezes tem dificuldade em diferenciar tipos de doenças pulmonares apenas com o raio-X. Por exemplo, a realização de diagnóstico diferencial entre uma pneumonia bacteriana ou pneumonia viral. Essa ferramenta pode ser bastante útil em pequenas cidades pois fornece diagnóstico rápido e barato devido ao tipo de dado utilizado: raio-X.

### Metodologia

O processo de desenvolvimento do projeto é apresentado no fluxograma abaixo.

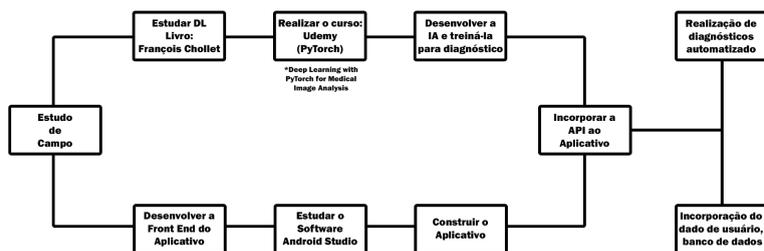


Figura 1: Fluxograma de Metodologia.

O projeto foi dividido em três partes: Primeira, estudar machine learning e criar a IA. Segunda, estudar a plataforma do Android Studio e criar o App. E finalmente conectá-las na nuvem usando o Firebase. E então deu-se início ao estudo de machine learning pelo livro de CHOLLET, e foi complementado com o

curso “Deep Learning with PyTorch for Medical Image Analysis” realizado pela plataforma online da Udemy. Com o conhecimento obtido foi construída a IA/API responsável por diagnosticar as imagens de raio-X.

Então, iniciou-se o estudo e desenvolvimento do aplicativo para smartphones (Android) que é apresentado na Figura[2]. O botão Iniciar é o atalho para o uso do app, de modo a escanear e subir a imagem a ser diagnosticada. O botão Tutorial, explica passo a passo como o app deve ser usado. O botão Informações, fornece informações técnicas tais como especificações do app, criador, uso de dados entre outros. O botão Sair encerra o aplicativo.

Finalmente realizou-se o procedimento de integração da IA na plataforma do Firebase, que será responsável em retornar o laudo para o usuário.



Figura 2: Imagem da tela inicial do aplicativo.

### Resultados e discussão

Foram geradas diversas IA's das quais duas foram selecionadas. A IA<sub>1</sub> com um pouco mais de treino em

relação a  $IA_2$ , visivelmente observado pelas diferenças entre valores de acurácia e precisão de ambas. Porém, ao treinar a  $IA_2$  com um tempo levemente menor que a  $IA_1$  nos gerou uma maior capacidade de generalização, assim resultou um maior valor de recorrência.

Esse valor de recorrência é derivado da matriz confusão, isto é, o que é relevante para esse valor são os números de falsos positivos e falsos negativos que a IA me retorna.

A  $IA_1$  tem uma taxa de 52,6% de falso negativo, enquanto a taxa na  $IA_2$  é de apenas 14,6%. Isso vem a um custo de falsos positivos,  $IA_1$  com 5% e a  $IA_2$  com 26,1%, ou seja, a  $IA_2$  tem um acréscimo de 21,1% em falsos positivos em troca de uma redução de 38,0% em falsos negativos em relação a  $IA_1$ .

	$IA_1$	$IA_2$
<b>Acurácia</b>	<b>83,4%</b>	<b>76,5%</b>
<b>Precisão</b>	<b>74,0%</b>	<b>48,8</b>
<b>Recorrência</b>	<b>47,4%</b>	<b>85,5%</b>

**Tabela 1:** Eficiência das IA's.

É importante ressaltar que existe uma discrepância de número de casos saudáveis e doentes nos dados. Foram usados 3,4 vezes mais dados de pulmões saudáveis do que doentes.

Daí fica a decidir o que é melhor, se em geral um maior número de acertos independente dos falsos positivos e falsos negativos, ou minimizar ao máximo o número de falsos negativos.

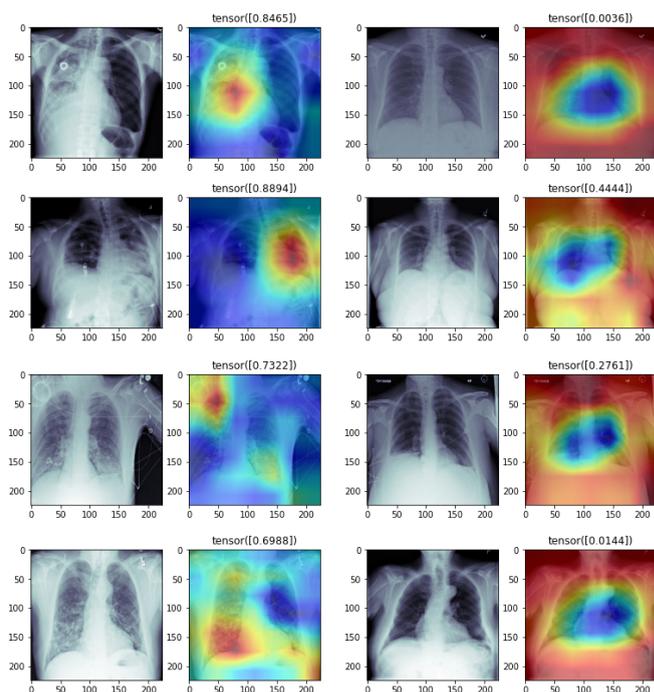
## Conclusões

O uso de Machine Learning para o desenvolvimento de uma IA capaz de diagnosticar doenças pulmonares se mostrou promissor. A qualidade de imagem em relação a resolução da mesma mostrou ter pouca interferência no diagnóstico. Possivelmente há um erro "comum" de misturar tipos de raio-X de contrastes diferentes (baixo e alto contraste, focados na observação respectivamente de tecido mole e duro). A falta de enquadramento pode interferir no diagnóstico, ou neste caso a imagem pode ter passado do limite mínimo de resolução, ou ainda pode ser uma caso de erro de contraste do raio-X.

Exemplo na figura [3]:



**Figura 3:** Nesta imagem podemos observar que um dos problemas citados acima podem ter interferido no diagnóstico da IA levando a um resultado de falso positivo. Predição 1 (doente); Laudo 0 (saudável).



**Figura 4:** A seguinte imagem consiste do Activation Map de algumas predições. Importante ressaltar que o valor do tensor impresso é a probabilidade do pulmão conter pneumonia.

O Activation Map (função que destaca pixels de interesse da IA) apresentado na Figura[4] se mostrou muito eficiente ao mostrar que em relação aos diagnósticos de pulmões doentes a IA está focada nas manchas causadas pela pneumonia. Porém ao diagnosticar pulmões saudáveis a IA aparenta estar mais

interessada com o "resto" da imagem, e não nos pulmões. Uma possível interpretação é que, ao falhar em encontrar os padrões da doença nos pulmões (centro da imagem), a IA começa a generalizar para o resto da imagem. Isso se traduz em: É mais fácil achar padrões onde existem informações/manchas (no resto da imagem) do que onde tem falta delas (nos pulmões), e como as manchas fora dos pulmões não compatíveis a de manchas de pneumonia a IA o julga como um pulmão saudável.

Possíveis atualizações e a evolução da IA para uma Multi Class Classification com as diversas doenças pulmonares é possível e está em discussão.

## Agradecimento

Agradeço ao IFQ/UNIFEI (Instituto de Física e Química - Universidade Federal de Itajubá) pelo financiamento da bolsa de iniciação em desenvolvimento tecnológico.

## Referências

CHOLLET, François. Deep Learning with Python, Manning Publications, 2017.

PANSE, Rohit. Using Machine Learning to Diagnose Pneumonia from Chest X Rays. 2019. Disponível em: <https://community.wolfram.com/groups/-/m/t/1383429>. Acesso em: 14 setembro 2021.

WONG, Ho Yuen Frank et al. Frequency and distribution of chest radiographic findings in COVID-19 positive patients. Radiology, p. 201160, 2020.

APOSTOLOPOULOS, Ioannis D.; MPESIANA, Tzani A. Covid-19: automatic detection from x-ray images utilizing transfer learning with convolutional neural networks. Physical and Engineering Sciences in Medicine, p. 1, 2020.

HEINSFELD, Anibal Sólón et al. Identification of autism spectrum disorder using deep learning and the ABIDE dataset. NeuroImage: Clinical, v. 17, p. 16-23, 2018.

AL-ANTARI, Mugahed A. et al. A fully integrated computer-aided diagnosis system for digital X-ray mammograms via deep learning detection, segmentation, and classification. International journal of medical informatics, v. 117, p. 44-54, 2018.

GANG, Peng et al. Dimensionality reduction in deep learning for chest x-ray analysis of lung cancer. In: 2018 tenth international conference on advanced computational intelligence (ICACI). IEEE, 2018. p. 878-883.

ASAOKA, Ryo et al. Using deep learning and transfer

learning to accurately diagnose early-onset glaucoma from macular optical coherence tomography images. American journal of ophthalmology, v. 198, p. 136-145, 2019.

LIU, Siqi et al. Early diagnosis of Alzheimer's disease with deep learning. In: 2014 IEEE 11th international symposium on biomedical imaging (ISBI). IEEE, 2014. p. 1015-1018.