

Detecção de Pneumonia Causada por COVID-19 Utilizando Few-Shot Learning

**Pedro Paulo de Souza Leão, Eulanda Miranda dos Santos,
Rafael Albuquerque Pinto, Lucas Gabriel Coimbra Evangelista**

¹ Instituto de Computação – Universidade Federal do Amazonas (UFAM)
Caixa Postal – 69080-900 – Manaus – AM – Brazil

{ppsl, emsantos}@icompu.ufam.edu.br

{rafael.albuquerque, lucas.evangelista}@icompu.ufam.edu.br

Abstract. *Radiological data are important for the diagnostic and treatment of COVID-19 and other lower respiratory tract infections, such as pneumonia. In this context, we propose in this paper a method that employs a Siamese Network designed to perform Few-Shot Learning to detect pneumonia related to COVID-19 in X-ray images. The generalizability of this model is evaluated using two datasets from different sources, allowing internal and external evaluation. The data partitioning is based on patient identifiers. The model was able to achieve over 96% accuracy, precision, and sensitivity in the internal evaluation. However, in the external evaluation the result was unexpected. On the other hand, it was observed that the Siamese Network model with Few-Shot Learning outperforms a traditional CNN.*

Resumo. *Dados radiológicos são importantes no diagnóstico e tratamento da COVID-19 e de doenças relacionadas ao trato respiratório inferior, tais como a pneumonia. Considerando esse contexto, nós apresentamos neste artigo um método que utiliza uma Rede Siamesa que, por meio de uma estratégia de Few-Shot Learning, busca detectar pneumonia relacionada com COVID-19 em imagens de raio-x. A capacidade de generalização desse modelo é avaliada utilizando dois conjuntos de dados de fontes diferentes, na forma de avaliação interna e externa. A partição dos dados é feita a partir de identificadores dos doentes. O modelo foi capaz de alcançar mais de 96% de acurácia, precisão, e sensibilidade na avaliação interna. Porém, na avaliação externa o resultado foi abaixo do esperado. Por outro lado, observou-se que o modelo de Rede Siamesa com Few-Shot Learning supera uma CNN tradicional.*

1. Introdução

Em dezembro de 2019 foram registrados os primeiros casos da doença do novo coronavírus, a COVID-19, em Wuhan, China. No dia 11 de março de 2020 a pandemia de COVID-19 foi declarada pela Organização Mundial de Saúde (OMS) devido à rápida disseminação e mortalidade, com cerca de 118.000 casos em 114 países e 4.291 óbitos¹.

¹Who director-general's opening remarks at the media briefing on COVID-19 - 11 march 2020. <https://www.who.int/director-general/speeches/detail/who-director-general-s-opening-remarks-at-the-media-briefing-on-covid-19—11-march-2020>

Quase dois anos depois, foram mais 281 milhões de casos registrados em 223 países e mais de 5,4 milhões de mortes [Casella et al. 2022].

A COVID-19 é uma doença vascular e respiratória que ataca os pulmões e outros tecidos pelo corpo. Conforme evidenciado por [Casella et al. 2022], casos moderados da doença incluem sintomas clínicos e radiológicos, indicando doenças para trato respiratório inferior, como a pneumonia, e a saturação de oxigênio maior ou igual a 94% em ar ambiente. Quanto mais graves os casos, mais evidentes se tornam os sintomas.

A radiologia desempenha um papel importante no tratamento e no diagnóstico de doenças relacionadas à COVID-19, como no caso da identificação e tratamento de doenças de trato respiratório inferior decorrentes da infecção de tecidos pulmonares, *e.g.*, Pneumonia. Dada a maior disponibilidade de equipamentos para extração de radiografia em comparação com outras opções, como a tomografia computadorizada (CT - do inglês *Computed Tomograph*) que é bem menos acessível, métodos que permitem o auxílio para um diagnóstico e tratamento da COVID-19 por meio de radiografias são muito úteis. Nesse contexto, o uso de algoritmos de Aprendizagem de Máquina (AM) tem sido investigado na literatura.

Em [Roberts et al. 2021], os autores indicam que um dos principais problemas em trabalhos existentes que tentam propor métodos de AM para identificação de casos de COVID-19 utilizando imagens de raios-x do tórax (CXR do inglês *Chest X-ray*) e CT é o seguinte: a falta de avaliação adequada. Comumente, esses trabalhos utilizam um conjunto de dados proveniente de uma única fonte de informação - por exemplo, dados coletados por um mesmo equipamento de um mesmo hospital. Nesse caso, o modelo de AM é treinado com uma partição do conjunto de dados e testado com outra partição do mesmo conjunto, configurando uma avaliação interna com relação às fontes e pacientes que são usados para ajustar e validar o modelo. Por outro lado, o processo ideal seria tratar o problema via avaliação externa, ou seja, o modelo deve ser treinado com dados de uma e/ou várias fontes de informação e testado em dados de outras fontes de informação. Esse tipo de procedimento é conhecido como avaliação externa.

Uma dos principais desafios relatados por [Roberts et al. 2021] na execução de avaliação externa é a escassez de dados, principalmente se considerarmos os exemplos para pacientes com COVID-19, diagnosticados ou não com pneumonia. Por exemplo, ao gerar um conjunto de dados composto por exemplos de imagens radiográficas, o ideal seria considerar uma vasta opção de equipamentos e visões e configurações para a doença, pois esses fatores podem inserir muitos vieses de coleta e aquisição dos dados, fato que dificulta a capacidade de generalização de métodos de AM.

Outro desafio também relatado por [Roberts et al. 2021] é o processo de amostragem em repositórios públicos para criação dos conjuntos de dados de trabalhos relacionados. Esse processo pode levar ao uso de instâncias de mesma origem, caso os repositórios possuam interseção devido às suas dependências de outros repositórios ou conjuntos de dados.

Uma das estratégias utilizadas na literatura para tratar escassez dos dados é baseada no uso técnicas de aumento de dados. Isso é feito por meio de transformações aleatórias sobre as imagens em tempo de execução. As transformações aleatórias ocorrem devido à necessidade de aumentar a representatividade dos dados e reduzir o viés

decorrente de alguns padrões da coleta das imagens ou estado fisiológico de pacientes para o problema.

Outra abordagem bastante utilizada é o *Few-Shot Learning* (FSL), que, como evidenciado em [Wang and Yao 2019], utiliza poucos exemplos para tratar tarefas com dados escassos, *e.g.* a detecção de uma nova doença tendo poucos exemplos disponíveis para treinar. FSL representa um tipo de problema em AM em que há apenas um número limitado de exemplos com informação supervisionada para o alvo, com o auxílio de algum conhecimento prévio. Por exemplo, o modelo pode possuir o conhecimento prévio relacionado à identificação de similaridade para pares de imagens CXR.

Há na literatura alguns trabalhos que empregam FSL no problema de detecção de pneumonia causada por COVID-19 em imagens de CXR. Em [Aradhya et al. 2021], é utilizada uma abordagem não supervisionada de agrupamento para gerar grupos de exemplos de mesma classe. Nesse trabalho, *One-Shot Learning* é empregado para gerar os grupos de dados. A tarefa do modelo era classificar exemplos como pertencentes à uma das seguintes classes: normal, pneumonia viral, pneumonia Bacterial e COVID-19. Os autores também investigam o cenário com duas classes: normal x COVID-19.

Já em [Jadon 2021], uma Rede Siamesa é aplicada utilizando a abordagem FSL focada na identificação de similaridade entre pares de imagens CXR para detecção de COVID-19. Os autores obtiveram excelentes resultados, alcançando mais de 96% de acurácia. Além disso, o método FSL foi comparado a outros métodos baseados em abordagens de aprendizado não supervisionado, transferência de aprendizado, aprendizado semi-supervisionado, e aprendizado supervisionado, sendo que o método de FSL apresentou os melhores resultados. Os autores trabalharam com 3 classes: normal, pneumonia e COVID-19.

Por fim, em [Shorfuzzaman and Hossain 2021], uma abordagem FSL via Rede Siamesa também é proposta. Esse modelo é aplicado no diagnóstico de COVID-19 baseado em meta aprendizado. A Rede Siamesa é composta por uma Rede Neural Convolutiva (CNN), mais precisamente a MobileNet [Howard et al. 2017], a qual é modificada e ajustada para gerar representações em uma Rede Siamesa. Para isso, são elaborados dois conjuntos: 1) conjunto de pesquisa - formado por instâncias que serão classificadas; 2) conjunto de suporte - composto por instâncias provenientes da partição de treinamento. Os dois conjuntos são utilizados para ajustar a Rede Siamesa a aprender a identificar a semelhança entre pares de imagens de mesma classe. O método obteve elevadas taxas de desempenho, alcançando sensibilidade 96,0% e especificidade 98,0%. Apenas 3 classes são consideradas: normal, pneumonia não causada por COVID-19 e COVID-19.

Além de terem utilizado FSL, esses três trabalhos têm outra característica em comum: eles não apresentam avaliação externa considerando uma fonte de dados externa ao conjunto usado para o ajuste e avaliação inicial dos modelos. Diferentemente dos trabalhos citados acima, neste trabalho nós empregamos FSL com Rede Siamesa em uma avaliação externa, cujos resultados são comparados aos resultados obtidos via avaliação interna. Além disso, duas abordagens de geração do conjunto de suporte são investigadas. A primeira seleciona um número n de imagens aleatórias para cada uma das 3 classes para compor um conjunto de suporte. Uma estratégia de vizinho mais próximo é utilizada para definir a classe das imagens CXR. Essa abordagem é similar à empregada

em [Shorfuzzaman and Hossain 2021]. Adicionalmente, a segunda abordagem testada neste trabalho é baseada no cálculo de uma representação média para as n imagens de uma mesma classe da nossa tarefa. Essa segunda abordagem é similar à utilizada por [Chen et al. 2020] na literatura de FSL.

É importante destacar que há trabalhos que utilizam FSL e avaliação externa no contexto de análise de COVID-19 a partir de imagens de CXR. Porém, como em [Li et al. 2020], esses trabalhos buscam prever a severidade de casos de COVID-19 com base em pontuações anotadas por radiologistas. Portanto, não são trabalhos com foco em classificação das imagens. Em [Li et al. 2020], por exemplo, bons resultados foram obtidos por um método baseado em FSL para *Spearman rank correlation* tanto nas avaliações internas quanto nas externas. Os autores consideraram casos de 3 conjuntos de dados: um externo aos pacientes em São Paulo - Brasil; e outros dois internos, nos Estados Unidos. O modelo também empregava uma Rede Neural Siamesa.

2. Método

Considerando que neste artigo nós empregamos uma Rede Siamesa na execução de um processo de FSL com avaliação externa, dois aspectos são fundamentais para a execução do trabalho. O primeiro está relacionado com a rede, pois é necessário o emprego de um modelo de CNN na composição da Rede Siamesa investigada, a qual é responsável por extrair as características das imagens e gerar os *embeddings*. O segundo aspecto é a base de dados. Para a elaboração do protocolo de avaliação externa executado neste trabalho, foi necessário organizar dois conjuntos de dados, um para a avaliação externa e outro para a avaliação interna dos modelos.

2.1. Modelo

Rede Neural Siamesa é um modelo de arquitetura que contém pelo menos duas CNNs paralelas e idênticas, ou seja, os membros da Siamesa devem compartilhar a mesma arquitetura, os mesmos pesos iniciais e atualizados, e ter os mesmos hiperparâmetros. Cada CNN membro é projetada para produzir um *embedding*, isto é, uma representação da entrada de dimensão reduzida. Essa arquitetura permite que a rede compare as entradas que recebe, geralmente uma por CNN membro, a fim de aprender similaridade entre os dados de entrada. Portanto, os *embeddings* são utilizados para otimizar uma função de perda de ranqueamento baseado em similaridade durante o treinamento. Na fase de teste, a rede gera uma pontuação de similaridade entre os dados de entrada. Por exemplo, se a Rede Siamesa é composta por duas CNNs, a entrada é composta por um par de imagens.

O modelo de CNN utilizado neste trabalho é baseado na MobileNet [Howard et al. 2017]. A **Figura 1** resume o modelo. Nós substituímos o topo da MobileNet por uma camada *Global Average Pooling 2D*, uma camada Densa com 1.024 neurônios com função de ativação ReLU, e uma camada densa com 3 neurônios cuja função de ativação é *Softmax*. Já a perda é calculada utilizando a Entropia Cruzada Categórica. Durante o treinamento é feito um ajuste fino dos pesos da MobileNet em todas as camadas, originalmente pré-treinados no conjunto de dados ImageNet, ou seja, os pesos são descongelados. Em seguida a esse pré-ajuste, o modelo passa a ser usado para a extração dos *embeddings* de cada imagem são submetida à Rede Siamesa.

A **Figura 2** mostra uma visão geral do funcionamento da Rede Siamesa criada em nosso trabalho, a qual é composta por duas CNNs idênticas, similares à mostrada no

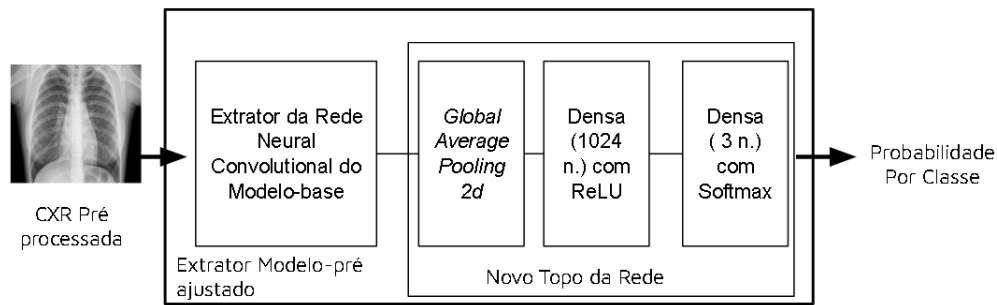


Figura 1. Esquema do funcionamento da CNN pré-treinada utilizada para compor a Rede Siamesa.

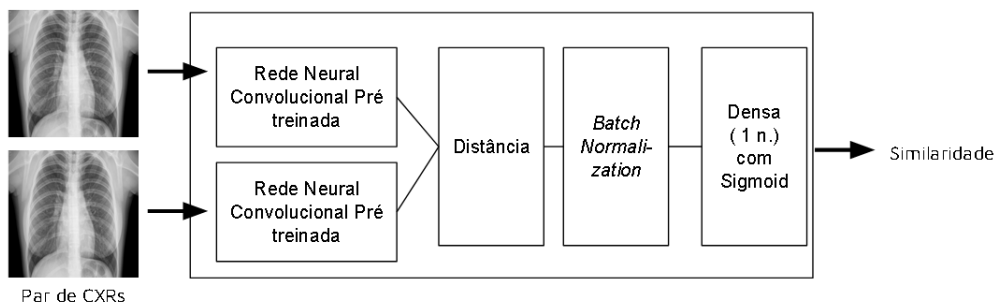


Figura 2. Esquema do funcionamento da Rede Siamesa.

esquema anterior, **Figura 1**. Primeiramente, o par de imagens de entrada passa pelas CNNs (uma imagem para cada CNN), que extraem as características das imagens. Na sequência, a distância euclidiana é calculada com normalização feita via média e variância móveis. Essa etapa é responsável por gerar um valor de similaridade dentro do intervalo $[0, 1]$ utilizando função de ativação *Sigmoid* em uma camada Densa com 1 neurônio e a função de perda *Contrastive Loss*, considerando margem igual a 1.

Para o ajuste do modelo de Rede Siamesa, são consideradas as taxas de aprendizado de $1e-5$ para treinamento da CNN e de $1e-4$ para treinamento da Rede Siamesa com otimizador Nadam. Outros parâmetros são os seguintes: 100 épocas, *batch size* de 32 para treino e validação e *Early Stopping* para monitorar a melhora na avaliação para a perda em validação, com paciência em até 10 épocas para se constatar melhora.

Além disso, a nossa Rede Siamesa é treinada com base na estratégia de FSL. Essa estratégia foca em aprender a fazer previsões com base em um número limitado de instâncias, principal característica das bases de CXR existentes publicamente para detecção de COVID-19, pois são normalmente bases pequenas. O objetivo do FSL é aprender as similaridades e as diferenças entre as imagens. Um elemento fundamental do FSL é o conjunto de suporte: pequeno conjunto de imagens rotuladas utilizado no momento do teste. Ao utilizar o conjunto suporte, é feita uma comparação entre a imagem de teste e as instâncias do conjunto de suporte.

Neste trabalho, nós selecionamos de forma aleatória um número n de exemplos para cada uma das k classes do problema para compor o conjunto suporte. Nós investigamos duas estratégias para a definição da classe das instâncias de teste:

- **Vizinho mais próximo:** A classe escolhida para ser atribuída à instância z de entrada é a classe do exemplo mais semelhante a z dentre os $n * k$ exemplos do conjunto suporte.
- **Média dos *embeddings*:** a operação de média é utilizada para obter um *embedding* médio das n imagens de cada classe. Nesse caso, o conjunto de suporte passa a ser formado por k *embeddings* médios, e a classe de z será a classe do elemento mais similar a z dentre os membros do conjunto de suporte.

Essas duas estratégias simulam uma situação de *Few-Shot Learning*, onde temos, no primeiro caso, um número n de protótipos e k classes conhecidas previamente pelo modelo. Já o segundo, considera apenas 1 protótipo baseado em n exemplos para cada uma das k classes.

2.2. Conjuntos de dados

Neste trabalho nós selecionamos 4 repositórios para extrair as amostras de radiografias a fim de elaborar os 2 conjuntos de dados necessários para os experimentos.

- **IDC - COVID-19: Image data Collection:** desenvolvido para detecção de achados radiográficos em imagens CXR. Trata-se de uma coleção de amostras de vários trabalhos, a qual permite a detecção de pneumonia para casos suspeitos ou testados positivo para COVID-19, amostras de casos positivos associados à outras doenças virais ou bacterianas, e também a classe nenhum achado.
- **CXI - Chest Xray Images (Pneumonia):** base composta por 5.863 CXRs advindos do Centro Médico de Mulheres e Crianças de Guangzhou, China. São radiografias de crianças entre 1 e 5 anos obtidas por meio de exames de rotina entre julho de 2013 e março de 2017.
- **RSNA - RSNA Pneumonia Detection Challenge:** repositório composto por 29.700 imagens de CXR divididas em 3 classes: sem opacidade pulmonar/não normal; com opacidade pulmonar; e normal. O RSNA é uma amostra de um repositório maior composto por mais de 100.000 imagens de pacientes anonimizados publicado pelo Centro Clínico do Instituto Nacional de Saúde, Estados Unidos.
- **COVIDx:** com mais de 10.000 imagens de CXR, essa base reúne imagens das três primeiras bases mencionadas, isto é IDC, RSNA, CXI, além de outros repositórios. Devido à essa intersecção com as bases de dados anteriores, nós filtramos essa base para evitar dados em comum com as outras bases.

O conjunto de dados utilizado na avaliação interna está resumido na **Tabela 1**. Esse conjunto é composto por amostras de imagens de CXR de casos suspeitos de COVID-19 da fonte IDC e balanceado com imagens das classes pneumonia e normal da fonte CXI, pois não havia imagens suficientes em IDC para essas classes. Já o conjunto empregado na etapa de validação interna (**Tabela 2**) contém amostras de imagens de casos suspeitos de COVID-19 da COVIDx, tomando-se o cuidado para não incluir instâncias que foram incluídas na primeira base de dados. Também foi feito o balanceamento da base. Nesse caso, com amostras da RSNA para as classes pneumonia e normal.

É importante destacar que o particionamento dos dois conjuntos de dados em treino, validação e teste foi feito primeiramente por meio de um agrupamento por identificador de pacientes. Em seguida, cada um dos pacientes que comporiam cada partição foi selecionado aleatoriamente, *i.e.*, não é possível que algum paciente representado na

partição de teste tenha algum exemplo em outra partição. A quantidade total de instâncias em cada partição é baseada na distribuição de 70% dos pacientes de cada classe para partição de treino, 15% para a de validação e 15% para a de teste. Considerando que diversos pacientes possuem mais de um exemplo, é esperado que o número de exemplos em cada partição para alguma das classes e alguma das partições não alcance 15%.

Dois pares de instâncias são gerados de forma aleatória a partir de cada instância das partições de treino ou de validação para o treinamento da Rede Siamesa: um par de instâncias similares e outro de instâncias dissimilares, dentre todas as outras instâncias da respectiva partição. Na fase de teste, é feita a separação de $k * n$ exemplos da partição de teste para compor o vetor suporte, onde k representa o número de classes do problema e n representa o número máximo de *shots* avaliados no cenário.

Tabela 1. Conjunto de dados Interno.

Partição	COVID-19	Normal	Pneumonia
treino	299	308	315
validação	77	77	77
teste	65	77	78
TOTAL	441	462	470

Tabela 2. Conjunto de dados Externo.

Partição	COVID-19	Normal	Pneumonia
teste	93	93	93

2.3. Preprocessamento e Aumento de Dados

Primeiramente, as imagens das duas bases de dados são redimensionadas para 512 x 512. Em seguida, as imagens são redimensionadas para 224 x 224 na fase de pré-processamento. Na sequência, os valores de intervalo [0, 255] são normalizados para [-1, 1] dividindo os valores por 127,5 e subtraindo 1 da intensidade de cada *pixel* em cada canal.

Além disso, uma etapa de aumento de dados é realizada por meio de transformações aleatórias para deslocamento vertical e horizontal em 10%, rotação em até 10°, *zoom in* e *out* em até 10%, e inversão horizontal para cada instância de treino. Também, é feito o preenchimento com o valor 0 para cada instância transformada.

3. Resultados

Os nossos experimentos foram realizados considerando dois cenários: 1) avaliação interna; e 2) avaliação externa. Além disso, duas abordagens de geração do conjunto de suporte são testadas. Por fim, nós testamos diferentes valores de n (quantidade de instâncias por classe incluídas no conjunto de suporte). Esse valor variou de 1, 3, 5 e 9. Considerando que as instâncias que compõem o conjunto de suporte são escolhidas de forma aleatória, cada configuração de experimento foi replicada 30 vezes, variando o conjunto de suporte. Portanto, os resultados resumidos nas próximas tabelas representam o desvio padrão e a média para as métricas de acurácia; precisão - ou a taxa de verdadeiros positivos entre os classificados como positivos; e sensibilidade - ou a taxa de verdadeiros

positivos classificados corretamente como positivos para a classe COVID-19 como classe positiva.

A **Tabela 3** mostra os resultados obtidos na avaliação interna. Como pode ser visto, tanto o primeiro método de seleção de múltiplos protótipos por classe (chamado aqui de *argmax*), quanto o método que utiliza um protótipo médio (chamado aqui de *argmax + min*), obtiveram elevadas taxas na validação interna, alcançando mais de 96% de acurácia, de precisão e de sensibilidade. Observa-se que os dois métodos de geração do conjunto de suporte não apresentam resultados muito diferentes entre si e a variação do valor de n parece não influenciar o resultado. Porém, ambos superam em mais de 15% as métricas obtidas pela CNN utilizando a abordagem clássica. É importante destacar que a base de teste da CNN é ligeiramente maior do que a base de teste da Rede Siamesa, pois as instâncias do conjunto de suporte são extraídas da base de teste.

Entretanto, considerando os resultados da avaliação externa vistos na **Tabela 4**, podemos notar que o modelo não conseguiu generalizar para a base externa. A melhor taxa de acurácia ficou abaixo de 50%, equivalente a apenas uma pequena melhora com relação a um classificador aleatório. Nesse cenário, ambas as abordagens para elaboração do conjunto de suporte apresentam resultados abaixo do ideal. Por outro lado, é importante notar que os resultados obtidos pelas abordagens de FSL superam os resultados da CNN padrão. O método *argmax* com $n = 9$ alcançou os melhores resultados. Diferentemente do que ocorreu na validação interna, neste cenário o resultado variou em função do valor de n . O desempenho do modelo melhora à medida que o valor de n aumenta.

Tabela 3. Resultados da Avaliação Interna.

Modelo	n	Acurácia	Precisão	Sensibilidade
argmax+mean	1	0.970 ± 0.003	0.999 ± 0.003	1.000 ± 0.000
	3	0.970 ± 0.004	1.000 ± 0.001	1.000 ± 0.000
	5	0.971 ± 0.004	1.000 ± 0.002	1.000 ± 0.000
	9	0.971 ± 0.004	1.000 ± 0.001	1.000 ± 0.000
argmax	1	0.970 ± 0.003	0.999 ± 0.003	1.000 ± 0.000
	3	0.969 ± 0.017	1.000 ± 0.000	1.000 ± 0.000
	5	0.971 ± 0.009	1.000 ± 0.000	1.000 ± 0.000
	9	0.965 ± 0.025	1.000 ± 0.000	1.000 ± 0.000
CNN	-	0.845	0.890	1.000

4. Conclusão

Neste trabalho nós empregamos uma Rede Siamesa utilizando a abordagem de FSL na classificação de imagens de raio-x. O modelo foi avaliado em dois cenários: avaliação interna e externa. O ótimo resultado no cenário de avaliação interna foi possível por empregarmos um modelo de CNN pré-treinado para compor a Rede Siamesa, a separação dos dados por pacientes, e a mistura de fontes de dados para avaliações.

No cenário de avaliação externa, entretanto, os resultados mostram que o modelo não consegue generalizar para fontes de dados diferentes. Nós acreditamos que com protótipos suficientemente representativos para o contexto em que se quer inserir o modelo para a classificação, poderíamos melhorar mais os resultados. Isso fica evidente ao

Tabela 4. Resultados da Avaliação Externa.

Modelo	n	Acurácia	Precisão	Sensibilidade
argmax+mean	1	0.363 ± 0.070	0.348 ± 0.125	0.464 ± 0.259
	3	0.385 ± 0.069	0.360 ± 0.118	0.517 ± 0.284
	5	0.393 ± 0.069	0.355 ± 0.116	0.549 ± 0.302
	9	0.404 ± 0.070	0.358 ± 0.111	0.588 ± 0.306
argmax	1	0.385 ± 0.069	0.396 ± 0.172	0.435 ± 0.260
	3	0.398 ± 0.067	0.398 ± 0.139	0.441 ± 0.222
	5	0.444 ± 0.054	0.422 ± 0.067	0.425 ± 0.116
	9	0.463 ± 0.029	0.435 ± 0.037	0.431 ± 0.0807
CNN	-	0.358	0.344	0.978

aumentarmos o número de instâncias que consideramos para a formação do conjunto de suporte. O desempenho abaixo do esperado também é determinado pelo fato dos dados utilizados para treinamento não serem suficientemente representativos para o domínio considerado. Esses pontos serão melhor trabalhados em etapas futuras.

5. Agradecimentos

Este artigo foi produzido no âmbito do Projeto Samsung-UFAM de Ensino e Pesquisa (SUPER), conforme previsto no Artigo 48 do Decreto nº 6.008 / 2006 (SUFRAMA), que foi financiada pela Samsung Eletrônica da Amazônia Ltda., nos termos da Lei Federal nº 8.387 / 1991, através do convênio 001/2020, firmado com a Universidade Federal do Amazonas e a FAEPI, Brasil.

Referências

- Aradhya, V. N. M., Mahmud, M., Guru, D. S., Agarwal, B., and Kaiser, M. S. (2021). One-shot cluster-based approach for the detection of COVID-19 from chest x-ray images. *Cognitive Computation*, 13(4):873–881.
- Cascella, M., Rajnik, M., Aleem, A., Dulebohn, S., and Di Napoli, R. (2022). Features, evaluation, and treatment of coronavirus (covid-19). *StatPearls*.
- Chen, Y., Wang, X., Liu, Z., Xu, H., and Darrell, T. (2020). A new meta-baseline for few-shot learning. *CoRR*, abs/2003.04390.
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., and Adam, H. (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. *CoRR*, abs/1704.04861.
- Jadon, S. (2021). COVID-19 detection from scarce chest x-ray image data using few-shot deep learning approach. In Park, B. J. and Deserno, T. M., editors, *Medical Imaging 2021: Imaging Informatics for Healthcare, Research, and Applications*. SPIE.
- Li, M. D., Arun, N. T., Aggarwal, M., Gupta, S., Singh, P., Little, B. P., Mendoza, D. P., Corradi, G. C., Takahashi, M. S., Ferracioli, S. F., Succi, M. D., Lang, M., Bizzo, B. C., Dayan, I., Kitamura, F. C., and Kalpathy-Cramer, J. (2020). Improvement and multi-population generalizability of a deep learning-based chest radiograph severity score for COVID-19.

- Roberts, M., , Driggs, D., Thorpe, M., Gilbey, J., Yeung, M., Ursprung, S., Aviles-Rivero, A. I., Etmann, C., McCague, C., Beer, L., Weir-McCall, J. R., Teng, Z., Gkrania-Klotsas, E., Rudd, J. H. F., Sala, E., and Schönlieb, C.-B. (2021). Common pitfalls and recommendations for using machine learning to detect and prognosticate for COVID-19 using chest radiographs and CT scans. *Nature Machine Intelligence*, 3(3):199–217.
- Shorfuzzaman, M. and Hossain, M. S. (2021). Metacovid: A siamese neural network framework with contrastive loss for n-shot diagnosis of covid-19 patients. *Pattern Recognition*, 113:107700.
- Wang, Y. and Yao, Q. (2019). Few-shot learning: A survey. *CoRR*, abs/1904.05046.