



**REENCONTROS  
NOVOS ESPAÇOS  
OPORTUNIDADES**

**XXXIV SIC** Salão Iniciação Científica

**26 - 30  
SETEMBRO  
CAMPUS CENTRO**

<b>Evento</b>	Salão UFRGS 2022: SIC - XXXIV SALÃO DE INICIAÇÃO CIENTÍFICA DA UFRGS
<b>Ano</b>	2022
<b>Local</b>	Campus Centro - UFRGS
<b>Título</b>	Omnidirectional 2.5D representation for COVID-19 diagnosis using chest CTs
<b>Autor</b>	THIAGO SOTORIVA LERMEN
<b>Orientador</b>	CLAUDIO ROSITO JUNG

## RELATÓRIO DE ATIVIDADES


Bolsista: Thiago Sotoriva Lermen

Orientador: Cláudio Rosito Jung

O objetivo principal do projeto de pesquisa é a extração de informação 3D a partir de imagens esféricas, que fornecem um campo de visão de 360 graus da cena capturada. A partir de uma imagem equirretangular gerada através de um volume 3D processado como uma imagem esférica, classifica-se imagens métricas volumétricas. Em particular foram utilizados dados de Tomografia Computadorizada (TC) de pulmões visando a identificações de doenças, dentre as quais pode-se destacar a COVID-19.

Inserindo uma câmera esférica no interior de um volume de TC pulmonar, foram amostrados dados ao longo de cada raio, visando extrair informações referentes ao exame. Para COVID-19, as lesões em vidro fosco são indicadores da doença. Dessa forma, é possível representar em uma imagem equirretangular que representa as intensidades das lesões associadas ao vidro-fosco.

Para cada volume, portanto, foi gerado uma imagem equirretangular com dois canais representando as intensidades de vidro-fosco e a profundidade. Essa técnica pode ser aplicada para diversas abordagens que envolvam dados volumétricos que possam ser representados em um domínio planar retangular. A Figura 1 abaixo representa a linha de trabalho para gerar as imagens retangulares a partir de um volume de TC pulmonar.



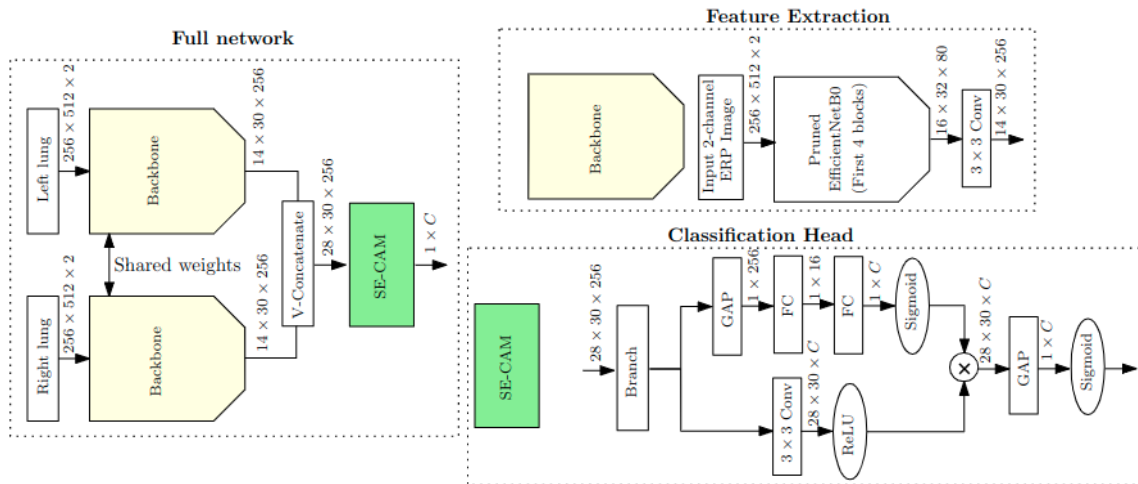
**Figura 1:** Processo de geração de imagem equirretangular a partir de um volume de TC pulmonar.

A partir da fundamentação teórica, foi possível trabalhar com redes de classificação de COVID-19 utilizando conjuntos de dados disponibilizados, tanto de forma interna quanto públicos. Para o caso de dados disponibilizados de forma interna, foram utilizados os conjuntos de dados gerados pelo Hospital Moinhos de Vento (HMV) e pelo Hospital de Clínicas de Porto Alegre (HCPA). Para o caso de dados públicos, foi utilizado o conjunto de dados *Signal Processing Grand Challenge* (SPGC), o qual tem sido frequentemente usado em pesquisas relacionadas à COVID-19 e visão computacional.

Foi possível elaborar uma arquitetura de rede neural utilizando *kernels* de convolução para extrair informações relevantes das imagens. Além disso, a arquitetura elaborada teve como especialidade trabalhar com imagens equirretangulares, com foco em classificação de COVID-19. O problema de classificação de COVID-19 foi dividido em dois subproblemas definidos a partir do conjunto de dados que foi usado para validação da abordagem:

1. COVID-19 vs. Normal
2. COVID-19 vs. Não-COVID (Incluindo *Community-acquired pneumonia* (CAP))

A arquitetura mencionada trabalha com técnicas avançadas de *deep learning*, como por exemplo a utilização de redes siamesas que compartilham os mesmos pesos ao longo do aprendizado, utilização de uma saída que usa redução de dimensionalidade através do módulo SE-CAM. A Figura 2 abaixo representa a arquitetura de rede desenvolvida para as tarefas de classificação 1 e 2, mencionadas acima.



**Figura 2:** Arquitetura de rede desenvolvida para classificação de COVID-19 a partir de imagens equirretangulares

Além disso, foram testados diversos *backbones* (redes pré-treinadas) com o objetivo de extrair recursos importantes para detecção de padrões nas imagens de entrada da rede. Com o objetivo de realizar um treino mais adequado, também foram desenvolvidas técnicas de aumento de dados, como por exemplo rotações no eador.

A arquitetura desenvolvida se mostrou muito competitiva com os resultados gerados pelo estado-da-arte, podendo, portanto realizar comparações e estudo de arquiteturas desenvolvidas por outros pesquisadores. A Tabela 1 abaixo mostra os resultados da técnica utilizada em comparação com outras abordagens para o conjunto de dados do SPGC. Percebe-se que a nossa técnica atingiu resultados muito similares a outras técnicas utilizando os volumes de TC, todavia, o diferencial a nossa técnica é exatamente o fato de ser extremamente mais eficiente treinar dados menos complexos, como imagens 2D equirretangulados, em comparação à dados mais complexos volumétricos. Para a realização dos experimentos foi necessário ler os artigos científicos publicados referentes a cada um dos autores.

Method	Sensitivity (%)			Accuracy (%)
	COVID-19	CAP	Normal	
Chaudhary et al. (2021)	85.71	<b>90.00</b>	94.29	<b>90.00</b>
Garg et al. (2021)	88.57	<b>90.00</b>	88.57	88.89
<i>Our technique</i>	<b>94.29</b>	70.00	91.43	87.78
Yang et al. (2021b)	80.00	<b>90.00</b>	<b>100.00</b>	87.78
Xue and Abhayaratne (2021)	82.86	80.00	91.43	85.56
Bougourzi et al. (2021b,a)	91.43	45.00	91.43	81.11
Ewen and Khan (2021)	88.57	35.00	97.14	80.00
Li et al. (2021)	88.87	35.00	97.14	80.00

**Tabela 1:** Resultados comparativos nos conjuntos de dados COVID-CT-MD/SPGC-COVID

Além disso, foi possível realizar a comparação de outras redes que fazem parte do estado-da-arte utilizando o conjunto de dados disponíveis internamente. A Tabela 2 abaixo mostra o resultados da nossa abordagem quando comparada com redes volumétricas, chamadas de CovNet e DeCoVNet.

**Table 1. Per-fold and average results for the in-house dataset**

Method	Sensitivity (%)		Accuracy (%)	
	Typical	Negative		
<i>Our technique</i>	Fold 1	91.67	<b>100.00</b>	<b>95.35</b>
	Fold 2	<b>96.00</b>	<b>95.65</b>	<b>95.83</b>
	Fold 3	<b>100.00</b>	<b>100.00</b>	<b>100.00</b>
	Fold 4	<b>100.00</b>	<b>100.00</b>	<b>100.00</b>
	Fold 5	<b>92.00</b>	91.30	<b>91.67</b>
	Mean	95.93	<b>97.39</b>	<b>96.57</b>
	Std.	<b>3.65</b>	3.48	3.15
Wang et al. (2020)	Fold 1	<b>96.00</b>	90.00	93.47
	Fold 2	96.00	95.00	95.65
	Fold 3	100.00	82.00	91.30
	Fold 4	100.00	81.00	91.11
	Fold 5	88.00	90.00	88.88
	Mean	<b>96.00</b>	87.60	92.08
	Std.	4.38	5.31	<b>2.30</b>
Li et al. (2020)	Fold 1	88.00	95.00	90.70
	Fold 2	75.00	91.00	81.98
	Fold 3	79.00	89.00	83.72
	Fold 4	88.00	91.00	89.13
	Fold 5	75.00	<b>96.00</b>	85.11
	Mean	81.00	92.40	86.12
	Std.	5.89	<b>2.65</b>	3.28

**Tabela 2:** Resultados comparativos nos conjuntos de dados HMV-HCPA em comparação com redes volumétricas

Os resultados, a implementação e os experimentos com as redes foram importantes para a minha contribuição no artigo do Prof. Dr. Thiago L. T. da Silveira. Além disso, os conhecimentos adquiridos possibilitaram a contribuição em problemas similares que envolvam a utilização de técnicas de *deep learning* voltadas para detecção e classificação de lesões de pele.

## REFERENCIAS

- [1] Chaudhary, Shubham, et al. "Detecting covid-19 and community acquired pneumonia using chest ct scan images with deep learning." *ICASSP 2021-2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. IEEE, 2021.
- [2] P. Garg, R. Ranjan, K. Upadhyay, M. Agrawal and D. Deepak, "Multi-Scale Residual Network for Covid-19 Diagnosis Using Ct-Scans," *ICASSP 2021 - 2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2021, pp. 8558-8562, doi: 10.1109/ICASSP39728.2021.9414426.
- [3] Z. Yang, Y. Hou, Z. Chen, L. Zhang and J. Chen, "A Multi-Stage Progressive Learning Strategy for Covid-19 Diagnosis Using Chest Computed Tomography with Imbalanced Data," *ICASSP 2021 - 2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2021, pp. 8578-8582, doi: 10.1109/ICASSP39728.2021.9414745.
- [4] S. Xue and C. Abhayaratne, "Covid-19 Diagnostic Using 3d Deep Transfer Learning for Classification of Volumetric Computerised Tomography Chest Scans," *ICASSP 2021 - 2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2021, pp. 8573-8577, doi: 10.1109/ICASSP39728.2021.9414947.

- [5] Bougourzi F, Contino R, Distanto C, Taleb-Ahmed A. Recognition of COVID-19 from CT Scans Using Two-Stage Deep-Learning-Based Approach: CNR-IEMN. *Sensors (Basel)*. 2021 Aug 31;21(17):5878. doi: 10.3390/s21175878. PMID: 34502769; PMCID: PMC8434147.
- [6] N. Ewen and N. Khan, "Online Unsupervised Learning For Domain Shift In Covid-19 CT Scan Datasets," 2021 IEEE International Conference on Autonomous Systems (ICAS), 2021, pp. 1-5, doi: 10.1109/ICAS49788.2021.9551146.
- [7] B. Li, Q. Zhang, Y. Song, Z. Zhao, Z. Meng and F. Su, "Diagnosing Covid-19 from CT Images Based on an Ensemble Learning Framework," ICASSP 2021 - 2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 2021, pp. 8563-8567, doi: 10.1109/ICASSP39728.2021.9413707.
- [8] Li L, Qin L, Xu Z, Yin Y, Wang X, Kong B, Bai J, Lu Y, Fang Z, Song Q, Cao K, Liu D, Wang G, Xu Q, Fang X, Zhang S, Xia J, Xia J. Using Artificial Intelligence to Detect COVID-19 and Community-acquired Pneumonia Based on Pulmonary CT: Evaluation of the Diagnostic Accuracy. *Radiology*. 2020 Aug;296(2):E65-E71. doi: 10.1148/radiol.2020200905. Epub 2020 Mar 19. PMID: 32191588; PMCID: PMC7233473.