Gestão:

Reunião de Acompanhamento
e Avaliação - RAA 2026

ANÁLISE NÃO-INTRUSIVA DE ESCOAMENTOS MULTIFÁSICOS ATRAVÉS DE MODELOS DE APRENDIZADO DE MÁQUINA BASEADOS EM VISUALIZAÇÃO

Seghetto, Leonardo[1]; Silva, Alexandre Kupka da[2]
[1]Bolsista do PRH 45/UFSC, discente do curso de Eng. Mecânica, EMC - UFSC, Florianópolis – SC.
E-mail: leonardo.seghetto@lepten.ufsc.br
[2]Docente do departamento de Eng. Mecânica, EMC - UFSC, Florianópolis – SC.

RESUMO

Comparou-se diferentes abordagens de pré-processamento e ao desenvolvimento de redes neurais convolucionais (CNNs) para compreender a influência destas no funcionamento (e confiabilidade) dos modelos. As 4 abordagens comparadas são: **(i) Heurística**, procedimento definido por [1], no qual se define uma arquitetura de referência e se realiza sucessivas variações na mesma, comparando a performance dessas em relação à anterior. **(ii) NAS** (*neural architecture search*), algoritmos de busca de arquiteturas de redes neurais. Neste trabalho o *framework* híbrido Optuna [2] foi empregado. **(iii) RIB** (*randomly initialized backbone*) compreende treinar uma arquitetura de modelos como ResNet50 [3], EfficientNetB0 [4] ou MobileNetV3 [5] do zero e, finalmente, **(iv) FT** (*fine-tuning*) compreendendo a importação de modelos pré-treinados do repositório de código aberto da *Huggin Face* timm [6], podendo ou não haver ajuste fino do classificador a ser definido pelo Optuna.

OBJETIVOS

Objetiva-se através deste desenvolver redes neurais convolucionais (CNNs) para monitoramento não-intrusivo de escoamentos multifásicos baseados em visualização (neste caso, *jet & spray cooling*), atentando-se às implicações das escolhas de pré-processamento e de design dos modelos em sua confiança (i.e., como tais escolhas impactam no funcionamento do modelo) e rendimento (e.g., custo computacional por inferência). Além disso, objetiva-se comparar, além das métricas de performance do modelos (e.g., RMSE), o custo computacional (e.g., FLOPs, latência e energia) associado a inferência de cada um. Aplica-se GradCAM++ [7] (uma técnica de XAI, Inteligência Artificial Explicável) na tentativa de compreender quais regiões do escoamento o modelo está considerando como mais relevantes à sua inferência.

APLICAÇÃO NO SETOR DE PETRÓLEO E ENERGIAS

Qualquer aplicação que possa ser mensurada através de visualização acaba por conseguinte se beneficiando deste estudo, uma vez que algumas recomendações gerais visando confiabilidade nestes casos são obtidas. Exemplos práticos são a identificação e quantificação das fases presente em mistura heterogênea, a redução de gastos energéticos em sistemas de refrigeração (como *jet impingement*) considerando um sistema de monitoramento mais eficaz (i.e., aumento da eficiência global do sistema), o monitoramento de reatores nucleares (detecção de regimes de ebulição no sistema de resfriamento, indicando estágios iniciais de instabilidades potencialmente catastróficas), entre outras. Em suma, o presente trabalho pode influenciar positivamente qualquer setor que busca desenvolver sistemas de monitoramento baseados em inteligência artificial aplicada à visão computacional.

AGRADECIMENTOS

Apoio financeiro do Programa de Formação de Recursos Humanos da Agência Nacional do Petróleo, Gás Natural e Biocombustíveis – PRH-ANP, gerido pela Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), Brasil. Processo nº 2025/02544-5.
Os autores agradecem ao LEPTEN, EMC, CTC e UFSC pela disponibilização de infraestrutura adequada ao desenvolvimento do estudo.

ANÁLISES & RESULTADOS

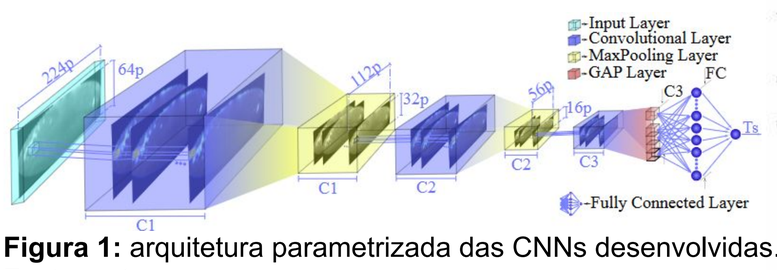


Figura 1: arquitetura parametrizada das CNNs desenvolvidas. Fonte: autores.

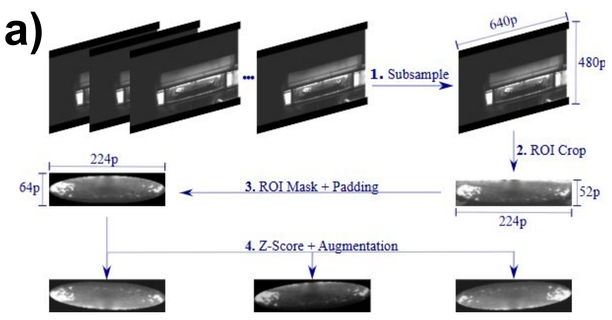


Figura 2: Em **a)** a *pipeline* de pré-processamento empregada. Em **b)** o decaimento do SSIM (*Structural Similarity Index Metric*) para diferentes passos de subamostragem (n), utilizado para verificar que a hipótese de i.i.d. (amostras independentes e igualmente distribuídas) seja válida. Em **c)** GradCAM++ das camadas convolucionais de um modelo provindo de NAS com erro de 0,55ºC. Nota-se que as duas primeiras camadas reconhecem bordas e texturas elementares, enquanto que a última reage às regiões com significância à tarefa (i.e., inferir T_S, a temperatura da superfície aquecida). Fonte: autores.

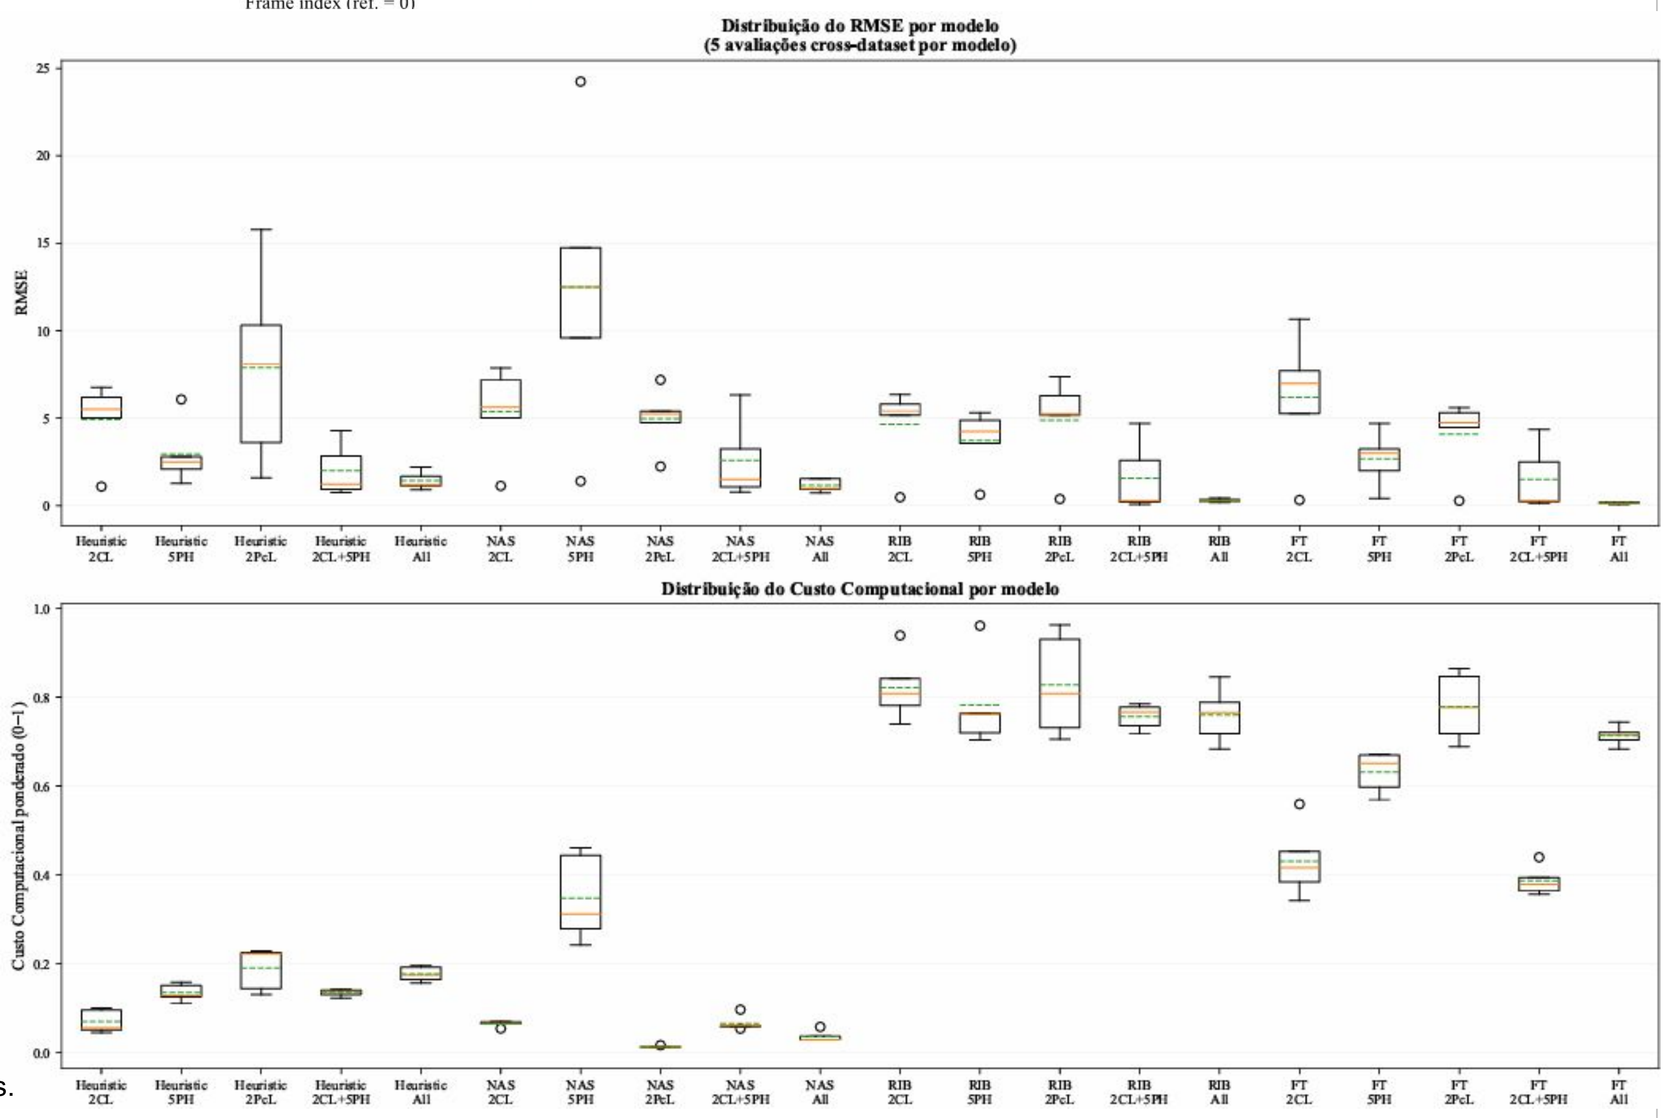


Figura 3: Diagrama de caixas dos 10 modelos em termos de RMSE (superior) e custo computacional (inferior). Fonte: autores.

REFERÊNCIAS

[1] Goodfellow, Y. Bengio, A. Courville, Deep Learning, MIT Press, 2016. URL http://www.deeplearningbook.org
[2] Akiba, S. Sano, T. Yanase, T. Ohta, M. Koyama, Optuna: A next-generation hyperparameter optimization framework, CoRR abs/1907.10902 (2019). arXiv:1907.10902. URL http://arxiv.org/abs/1907.10902
[3] . He, X. Zhang, S. Ren, J. Sun, Deep residual learning for image recognition, in: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016.
[4] M. Tan, Q. Le, EfficientNet: Rethinking model scaling for convolutional neural networks, in: K. Chaudhuri, R. Salakhutdinov (Eds.), Proceedings of the 36th International Conference on Machine Learning, Vol. 97 of Proceedings of Machine Learning Research, PMLR, 2019, pp. 6105–6114. URL https://proceedings.mlr.press/v97/tan19a.html
[5] A. Howard, M. Sandler, G. Chu, L.-C. Chen, B. Chen, M. Tan, W. Wang, Y. Zhu, R. Pang, V. Vasudevan, Q. V. Le, H. Adam, Searching for mobilenetv3, in: Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV), 2019.
[6] R. Winghtam, Pytorch image models (2019). doi:10.5281/zenodo.4414861. URL https://github.com/huggingface/pytorch-image-models
[7] Chattopadhay, Aditya, et al. "Grad-cam++: Generalized gradient-based visual explanations for deep convolutional networks." 2018 IEEE winter conference on applications of computer vision (WACV). IEEE, 2018.