

**Autores:** Anderson Calderini<sup>1</sup>, Rael Oliveira<sup>2</sup>, Leonardo Borret<sup>3</sup>, João Dias, José Rodrigues  
Centro Federal de Educação Tecnológica – CEFET/RJ  
Rio de Janeiro, RJ, Brasil

{anderson.calderini, rael.oliveira, leonardo.borret}@aluno.cefet-rj.br, e {joao.dias, jose.rodrigues}@cefet-rj.br

## INTRODUÇÃO

É extremamente importante que companhias de água, petróleo ou gás possam detectar vazamentos de fluidos em suas tubulações, para que os danos econômicos [1] e ambientais, comumente causado por estes vazamentos, possam ser mitigados rapidamente, assim prevenindo um agravamento na situação.

Atualmente, a detecção de vazamentos de fluidos é um processo custoso e demorado, levando em conta fatores como o tamanho das tubulações ou ambiente de difícil acesso onde se encontram.

As principais técnicas utilizadas na identificação de vazamentos em tubulações são o uso de câmeras de detecção não-automática, método custoso e demorado que depende de um operador, e a instalação de sensores de pressão dentro dos canos, método caro e que apresenta muita imprecisão por conta de fatores externos, tais como a temperatura [2] e pressão do ar. Neste trabalho, desenvolvido como um projeto de iniciação científica, utilizamos técnicas de Machine Learning e visão computacional para inspeção aérea de tubulações, utilizando um drone autônomo.

## BANCO DE DADOS

Para treinamento de inteligência artificial, foi utilizada uma base de dados produzida inteiramente pelos autores do trabalho, contendo imagens de canos propositalmente furados causando vazamento, além de fotos dos canos em pleno funcionamento.

Foram obtidas, inicialmente, 1334 imagens, que foram *augmentadas* por processos comuns [3], totalizando 5733 imagens, das quais 2601 continham canos em perfeito funcionamento, e 3132 continham canos propositalmente furados.

## TREINAMENTO

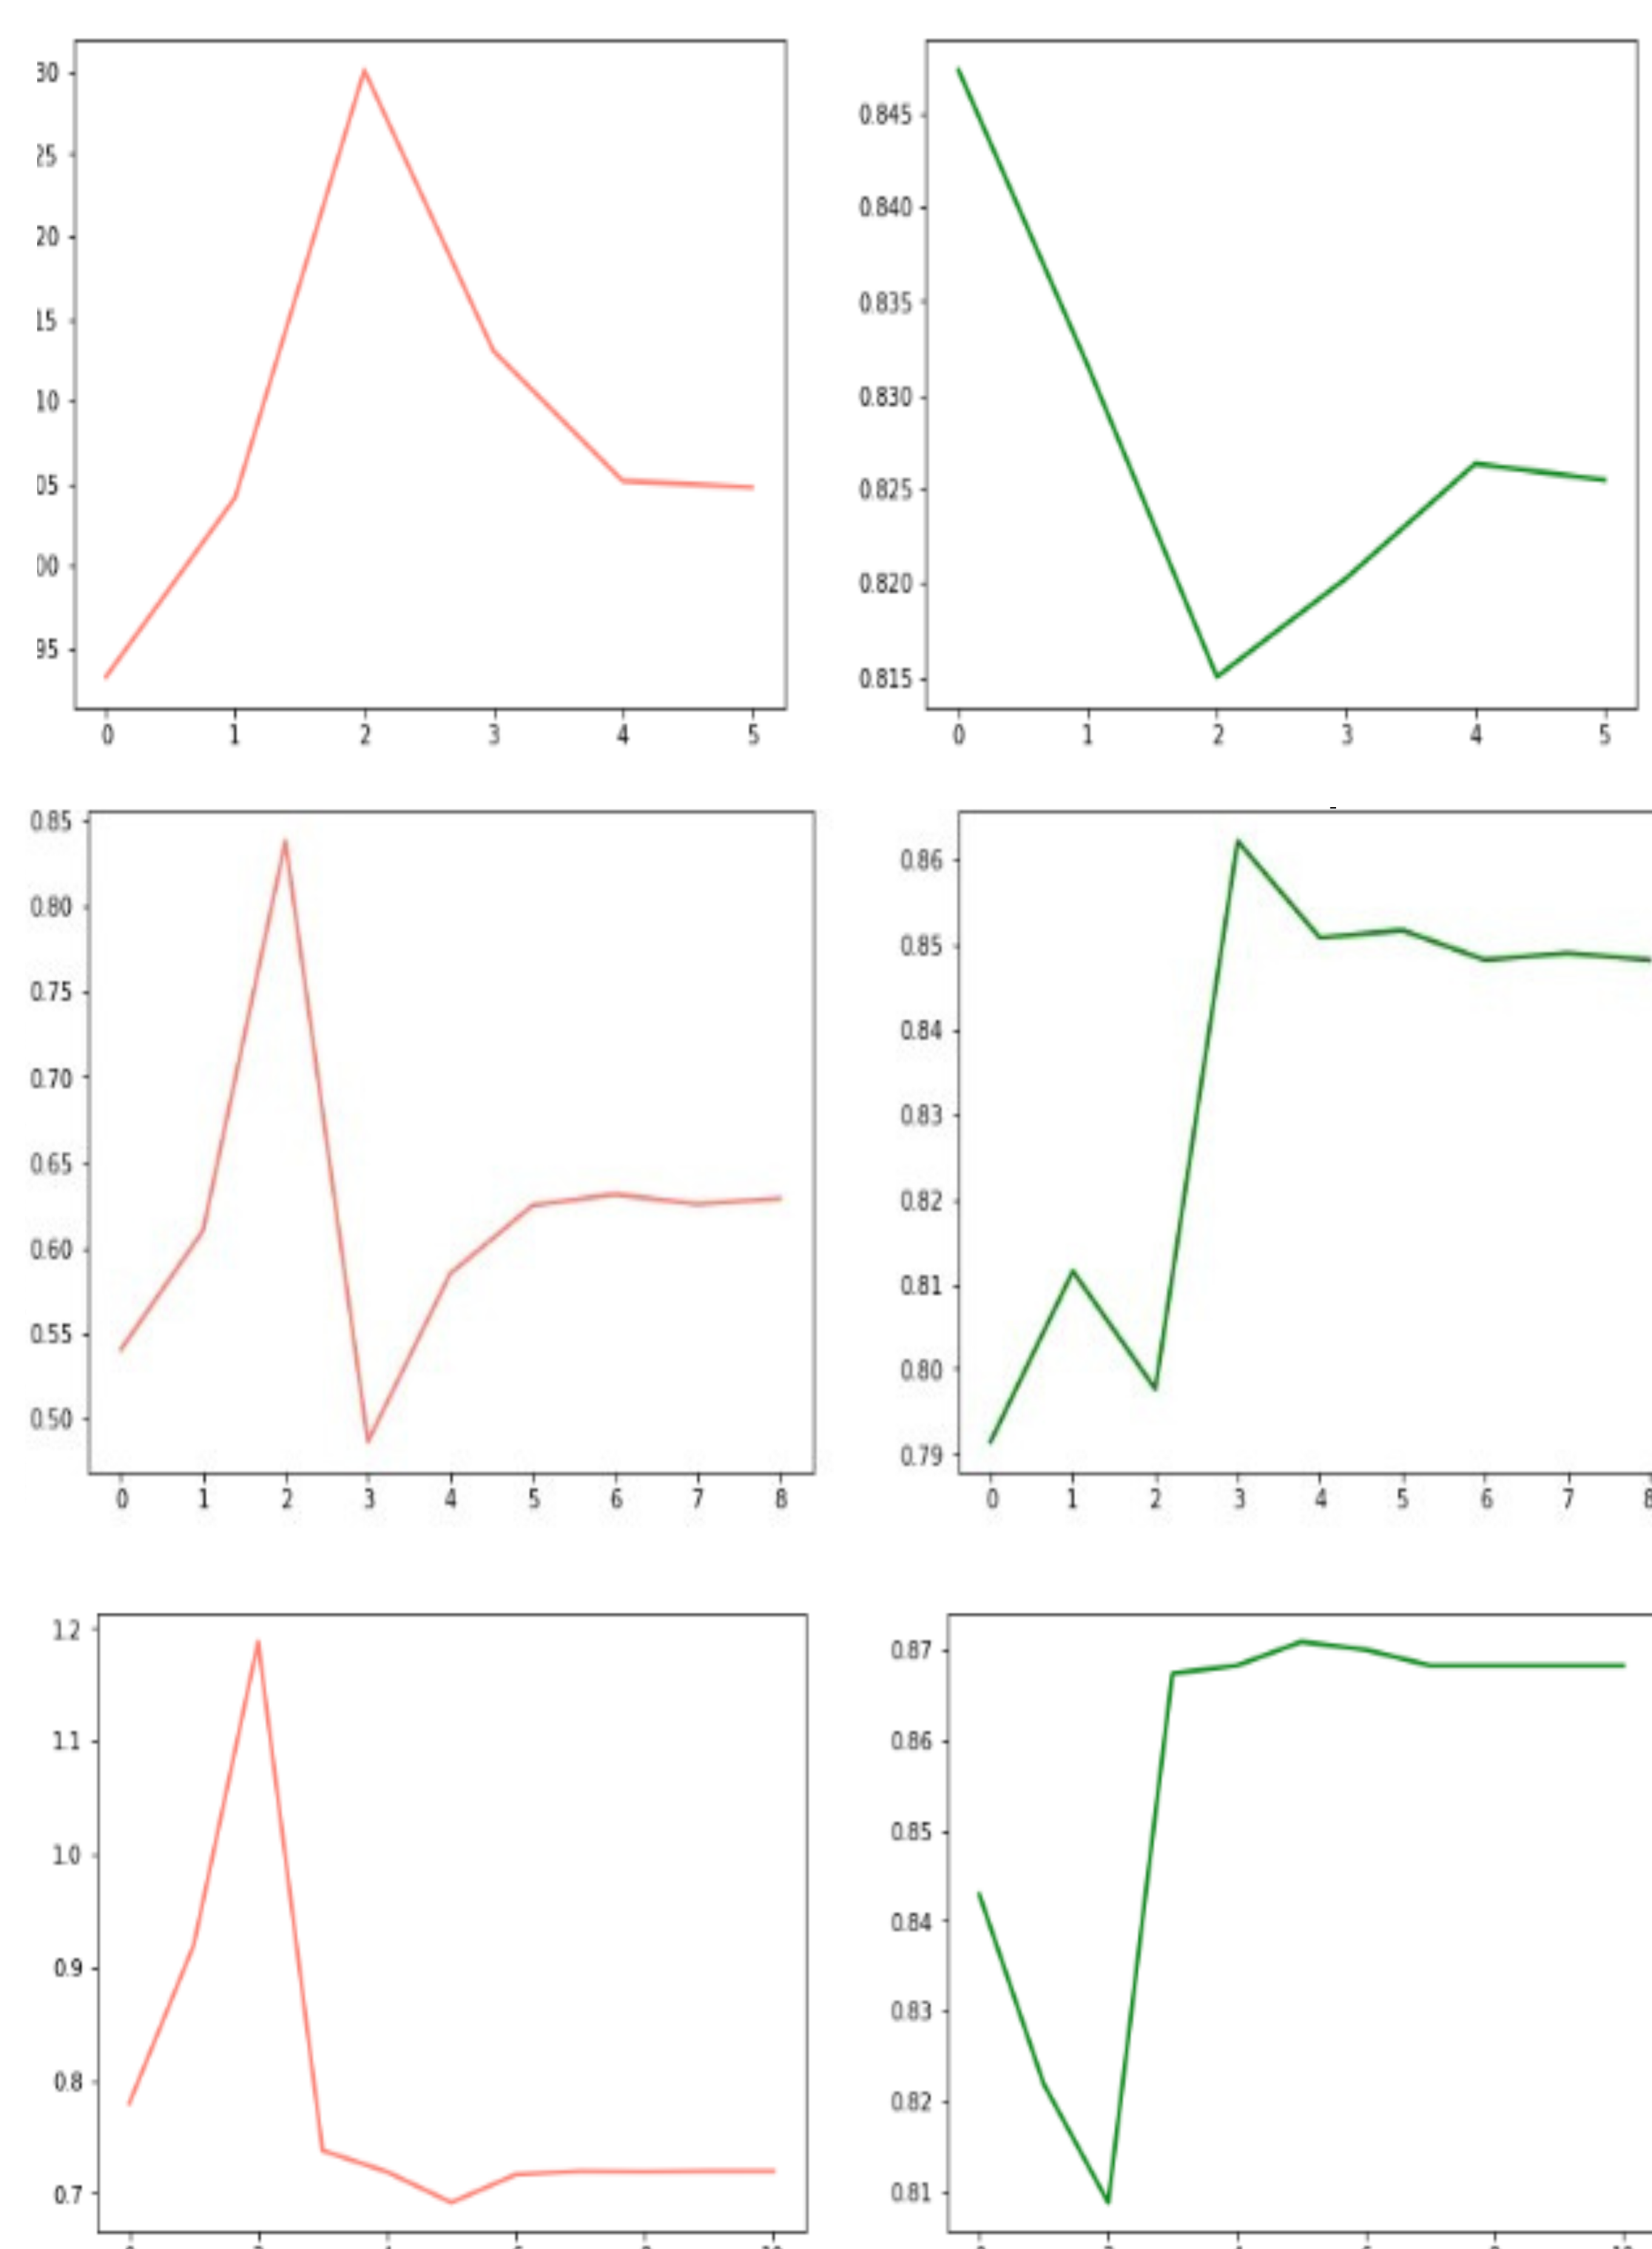
Para fins de teste, foram testadas simultaneamente 3 arquiteturas diferentes, Xception, DenseNet121 e ResNet50, todas recebendo os mesmos dados.

O treinamento foi configurado para ser realizado em 30 épocas, mas interrompido caso um platô nos resultados fosse atingido.

## RESULTADOS

Os gráficos nas figuras abaixo mostram o progresso no treinamento realizado nas três redes utilizadas.

Os gráficos à esquerda mostram a função de erro na validação, enquanto os gráficos à direita mostram a precisão. De cima para baixo, temos os resultados dos treinamentos de ResNet50, Xception e DenseNet121, respectivamente.



## CONCLUSÃO

Os testes realizados na DenseNet121 chegaram a um platô de 87% de acurácia, evidenciando a proficuidade do uso de inteligência artificial no combate a vazamentos.

## MELHORIAS

Atualmente, está sendo estudada a implementação de uma detecção via câmera infravermelha, já tendo um banco de dados sido desenvolvido para esta aplicação, contendo mais de dez mil fotos, que ainda não sofreram *augmentação*.

## AGRADECIMENTOS

Nós agradecemos ao Cefet/RJ, à Faperj e ao CNPq pelo fomento que deu viabilidade a este trabalho.

## REFERÊNCIAS

- [1] M.A. Cohen, A Taxonomy of Oil Spill Costs – What are the Likely Costs of the Deepwater Horizon Spill? Journal Resources for the future, Junho, 2010
- [2] M. A. Kilinski, Overview of Leak Detection Technologies – A Summary of Capabilities and Costs. Richland, WA: Pacific Northwest National Laboratory, Julho, 2019
- [3] A. Buslaev, V. I. Iglovikov, E; Khvedchenya, A. Parinov, M. Druzhinin, A. A. Kalinin, Albumentations: Fast and Flexible Image Augmentations. Journal Information, 2020.