

Inteligência Artificial Aplicada a Detecção de Vazamentos em Dutos e Canos

Lucas Silva, Rael Oliveira, Anderson Calderini, Jose Rodrigues e João Dias

Resumo— Vazamentos em dutos e canos podem gerar prejuízos significativos devido à perda do fluido, assim como, contaminação de solos e rios, dependendo do fluido vazado. Este trabalho, desenvolvido como projeto de iniciação científica, tem como objetivo criar uma ferramenta que permita aumentar a eficiência da inspeção aérea de dutos e canos utilizando técnicas de aprendizado de máquina para a detecção de vazamentos. Para isso, foram treinados e testados três modelos de redes neurais com pré-processamento de imagens para detecção de vazamentos utilizando um banco de imagens próprio. A rede teve desempenho satisfatório para a aplicação proposta com 87% de acurácia.

Palavras-Chave— Aprendizado de máquina, visão computacional, detecção de vazamento.

Abstract— Leaks in ducts and pipes can generate significant losses due to fluid loss, as well as contamination of soils and rivers, depending on the leaked fluid. This work, developed as a scientific initiation project, aims to create a tool to increase the efficiency of aerial inspection of pipelines and pipes using machine learning techniques for leak detection. For this, three models of neural networks with pre-processing of images for leak detection were trained and tested using a proprietary image bank. The network performed satisfactorily for the proposed application with 87% accuracy.

Keywords— Machine learning, computer vision, leak detection.

I. INTRODUÇÃO

É de extrema importância para as empresas de água, petróleo e gás detectar vazamentos de fluidos em suas tubulações. Pois esses vazamentos podem causar sérios danos ambientais e econômicos [1]. No entanto, a detecção de vazamentos de fluidos é uma tarefa difícil, pois esse tipo de vazamento pode ser muito pequeno e pode ocorrer em qualquer lugar da tubulação. Além disso, os dutos podem estar localizados em ambientes de difícil acesso, o que torna a detecção de vazamentos de fluidos ainda mais difícil.

Uma das maneiras de detectar vazamentos de fluidos é inspecionar as tubulações com câmeras sem detecção automática. No entanto, isso é um processo caro e demorado [2], pois é necessário um operador para monitorar as imagens das câmeras e identificar os vazamentos. Outra maneira de detectar vazamentos de fluidos é usar sensores para detectar a perda de

pressão ou aumento da temperatura. No entanto, esses sensores são caros e podem ser afetados por outros fatores, como a temperatura do ar [2].

Uma maneira inovadora de abordar o problema da detecção de vazamentos de fluidos é usar técnicas de aprendizado de máquina para processar imagens das tubulações e dos dutos e detectar vazamentos de fluidos. Essa abordagem tem várias vantagens. Primeiro, as imagens das tubulações e dos dutos podem ser obtidas facilmente usando câmeras de baixo custo. Além disso, as técnicas de aprendizado de máquina podem analisar as imagens rapidamente e permitem adaptação fácil a diferentes tipos de vazamentos de fluidos, de tubulações e de dutos ao aplicarmos modificações ao conjunto de dados.

Apesar destas vantagens, fica evidente que esta técnica funcionará apenas para canos e dutos expostos e em ambientes abertos, com espaço suficiente para uma inspeção aérea utilizando drones.

O objetivo deste artigo é explorar os resultados obtidos no projeto para utilização de técnicas de aprendizado de máquina para a detecção de vazamentos de fluidos em dutos e canos. Utilizamos 3 redes neurais para comparar os desempenhos, a DenseNet121, Xception e ResNet50.

Este trabalho está organizado da seguinte maneira: o desenvolvimento da base de dados, das funções de pré-processamento, das arquiteturas e do treinamento é apresentado Seção 2; os resultados dos treinamentos são mostrados na Seção 3; e as conclusões são feitas na Seção 4.

II. INTELIGÊNCIA ARTIFICIAL

Nessa seção descreveremos os métodos utilizados para a criação da base de dados, construção das redes neurais e os testes de desempenho.

A. Base de Dados

Os dados foram criados pelos autores do estudo usando fotos de canos os quais foram furados propositalmente para simular um vazamento. A base de dados foi aumentada utilizando técnicas comuns [3], como a rotação e a translação, e também foram utilizados efeitos de cor para variar as cores dos canos.

No total, antes da *augmentação*, haviam 1334 imagens, após os procedimentos de *augmentação* ficamos com 5733 imagens. A divisão do banco de dados foi de 2601 imagens classificadas como normais e 3132 imagens classificadas como com vazamento. Para a validação, utilizamos a técnica *Leaving-out*, com 5% das imagens utilizadas no treinamento.

Lucas T. da Silva, curso técnico de Informática, Cefet/RJ, Rio de Janeiro, e-mail: lucasbabur@gmail.com; Rael da S. Oliveira, curso técnico de Telecomunicações, Cefet/RJ, Rio de Janeiro, e-mail: rael.oliveira@aluno.cefet-rj.br; Anderson C. Calderini, curso técnico de Eletrônica, Cefet/RJ, Rio de Janeiro, e-mail: ansocortez@gmail.com; Jose A. F. de C. R. Rodrigues, Coordenadoria de Eletrônica, CEFET/RJ, Rio de Janeiro-RJ, e-mail: jose-antoniofontes@gmail.com; João T. Dias, Programa de Pós-Graduação em Engenharia Elétrica, CEFET/RJ, Rio de Janeiro-RJ, e-mail: joao.dias@cefet-rj.br;

B. Pré-processamento

No pré-processamento dos dados, utilizamos 2 técnicas principais, a detecção de bordas utilizando um filtro de detecção de bordas, e o filtro de reflexão, que detecta pixels acima de um determinado limite de cor branca [2]. Estas imagens são salvas em conjunto, resultando em uma resolução de (100x300), conforme pode ser visto na Fig. 1.




Fig. 1. Exemplo de uma imagem com o resultado dos filtros de pré-processamento

C. Arquitetura

Para fins de testes, comparamos 3 arquiteturas, a Xception [4], a DenseNet121 [5] e a ResNet50 [6], todas recebendo os mesmos dados, com seus pesos congelados e sem mudanças na configuração, exceto por 2 camadas decisórias finais, uma densa com 64 neurônios e o neurônio final (*output*).

D. Treinamento

O treinamento foi configurado para ser feito em 30 épocas, porém é interrompido caso se alcance um platô nos resultados. Além disso, a taxa de aprendizado (*learning rate*) é reduzida em um fator de 0.1 antes do interrompimento do treinamento, para verificar se não há mais ganhos possíveis com a redução do fator de aprendizado [7], [8]. A função de ativação usada foi a ReLu para treino, e um neurônio final utilizando a função sigmoide.

III. RESULTADOS

Os gráficos das Figuras 2, 3 e 4 mostram o progresso do treino das três redes implementadas. A época com os melhores resultados no banco de dados de validação foi a que teve os pesos salvos, assim, é possível observar uma comparação de todas as épocas e isolar o erro.




Fig. 2. Desempenho da ResNet50

Estes resultados indicam que é possível utilizar redes neurais para classificação de vazamentos em canos, e que, possivelmente, os resultados encontrados foram devido às camadas




Fig. 3. Desempenho da Xception




Fig. 4. Desempenho da DenseNet121

densas, dado o desempenho da DenseNet121. Isto sugere que, utilizando por base camadas densas, outras técnicas de reconhecimento de imagens podem ser aplicadas para tentar aumentar ainda mais a acurácia.

IV. CONCLUSÃO

Os testes apresentaram um desempenho próximo de 100% durante o treinamento, e uma acurácia de 87% no banco de dados de validação, demonstrando que o aprendizado foi generalizado para imagens fora do banco de dados.

Apesar dos resultados positivos, alguns pontos passíveis de melhoria são a adição, como um fator decisório da inteligência artificial, do uso de câmeras térmicas infravermelhas e o balanço do banco de dados. No entanto, os resultados já obtidos nos testes se mostraram extremamente promissores.

AGRADECIMENTOS

Agradecemos ao Cefet/RJ, a Faperj e ao CNPq pelo financiamento parcial do projeto que deu origem a esse trabalho.

REFERÊNCIAS

- [1] M. A. Cohen, A Taxonomy of Oil Spill Costs *Resources for the future*. 2010.
- [2] M. A. Kilinski, "Overview of Available Leak Detection Technologies" *Pacific Northwest*, Julho 2019.
- [3] A. Buslaev, V. I. Iglovikov, E. Khvedchenya, A. Parinov, M. Druzhinin, A. A. Kalinin, "Albumentations: Fast and Flexible Image Augmentations", Fevereiro 2020.
- [4] F. Chollet, Xception: Deep Learning with Depthwise Separable Convolutions. 2017.
- [5] G. Huang, Z. Liu, L. Maaten, K. Q. Weinberger, Densely Connected Convolutional Networks, Janeiro 2018.
- [6] H. Kaiming, Z. Xiangyu, R. Shaoqing, S. Jian, Deep Residual Learning for Image Recognition, Dezembro 2015.
- [7] L. Liyuan, H. Pengcheng, C. Weizhu, L. Xiaodong, G. Jianfeng, H. Jiawei, On the Variance of the Adaptive Learning Rate and Beyond, Outubro 2021.
- [8] K. You, M. Long, J. Wang, M. I. Jordan, "How Does Learning Rate Decay Help Modern Neural Networks?", Setembro 2019.