

# GERADOR DE DADOS ULTRASSÔNICOS SINTÉTICOS DE TESTES NÃO DESTRUTIVOS UTILIZANDO REDES ADVERSÁRIAS GENERATIVAS E AUMENTO ADAPTATIVO DE DADOS.

Misael Pedro Conceição Alves<sup>1</sup>; Carlos Alberto Campos da Purificação<sup>2</sup>; Taniel Silva Franklin<sup>3</sup>  
1 Bolsista; Projeto Soft Robots Pesquisa, Desenvolvimento e Inovação (PD&I); misael.alves@fbter.org.br  
2 Centro Universitário SENAI CIMATEC; Salvador-BA; carlos.purificacao@fieb.org.br  
3 Centro Universitário SENAI CIMATEC; Salvador-BA; taniel.franklin@fieb.org.br

## RESUMO

Testes não destrutivos são amplamente utilizados na indústria com o objetivo de detectar falhas e verificar propriedades de produtos. Sua principal vantagem é a não alteração das propriedades mecânicas, químicas ou físicas do material testado. Atualmente esse processo de teste e avaliação é feito de maneira manual, necessitando pelo menos de um operador para realizar ambas as tarefas. Uma das opções para tornar a etapa de avaliação mais rápida e eficiente é o uso de algoritmos de classificação e detecção de características para automatizar a análise de imagens obtidas através do emprego de sensores. Porém, uma das barreiras para empregar tais métodos é a falta de volume de dados suficiente para treinar e avaliar com segurança modelos direcionados a essa tarefa. Portanto, o presente trabalho propõe o uso de redes neurais adversárias generativas para geração de imagens sintéticas de testes não destrutivos obtidos por meio de sensores ultrassônicos.

**PALAVRAS-CHAVE:** Redes Adversárias Generativas, NDT, sensores ultrassônicos.

## 1. INTRODUÇÃO

Os ensaios com sondas de teste ultrassônico são de grande valor. Proporcionam a inspeção de peças metálicas sem causar danos ao objeto de estudo, viabilizando a sua reutilização caso falhas não sejam encontradas durante a inspeção. Porém como destacado por VIRKKUNEN et al., 2019, O empecilho para treinamento de modelos para reconhecimento de imagens de testes ultrassônicos se deve a escassez de dados representativos e ao alto custo de produção de ensaios. Objetivando superar essas limitações o presente estudo aplica redes adversárias generativas juntamente a técnica de aumento adaptativo do discriminador com o intuito de gerar imagens sintéticas de inspeções com sondas ultrassônicas do tipo *phased array ultrasonic testing* (PAUT) para viabilizar treinamento de modelos de aprendizado de máquina para automatizar o processo de avaliação dos dados obtidos.

A principal característica de redes adversárias generativas é a presença de duas arquiteturas distintas, uma especializada em aprender sobre a distribuição de dados reais e gerar dados sintéticos nomeada gerador e outra responsável por avaliar as imagens e estimar a probabilidade destas serem reais ou falsas (sintéticas) denominada discriminador. Esses dois modelos são treinados simultaneamente, de modo que o gerador tenta fraudar o discriminador a cada rodada de treinamento, gerando imagens com distribuições cada vez mais próximas das imagens reais.

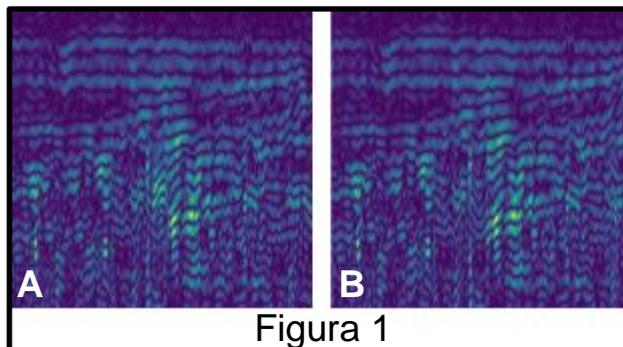
Diversas questões podem ser enfrentadas ao treinar uma rede adversária generativa, uma delas é o sobre ajuste do discriminador às amostras de treino devido a pequenos conjuntos de dados.<sup>2</sup> Uma das técnicas que podem ser utilizadas para treinamentos dessas arquiteturas de redes neurais é o aumento adaptativo do discriminador (ADA). Como descrito por KARRAS, T. et al., 2020, essa técnica utiliza o aumento de dados para prevenir o ajuste excessivo do discriminador aos dados de treinamento, associado com um método de controle que garante que as modificações aplicadas não sejam aprendidas pelo gerador.

## 2. METODOLOGIA

O conjunto de dados utilizado para validar a técnica de geração de dados sintéticos contém amostras obtidas através de um ensaio experimental. Essas amostras foram disponibilizadas pelos elaboradores do ensaio por meio da plataforma de hospedagem de código fonte, GitHub. O corpo de prova inspecionado para aquisição de dados foi uma solda de topo em um tubo de aço inoxidável austenítico 316L. Três falhas por fadiga térmica com profundidades de 1,6, 4,0 e 8,6 mm foram implementadas no diâmetro interno do tubo próximo à raiz da solda e escaneados com equipamento ultrassônico.<sup>1</sup> A coleta de dados do teste não destrutivo foi feita utilizando sondas Imasonic 1.5 MHz 1.5M5x3E17.5-9, ligadas a um detector de falhas Zetec Dynaray 64/64PR-Lite, este conectado a um computador, como descrito por VIRKKUNEN et al., 2019. Os dados gerados contêm 454 A-scan, cada um deles contendo 5058 amostras com 16 bits de profundidade. O conjunto de dados passou por um corte, onde somente a área de interesse foi mantida, resultando em

imagens de dimensões 454 x 454 pixels que posteriormente foram convertidas para 256 x 256 pixels por propósitos de aprendizado de máquina. Ao total foram geradas 20000 amostras para serem utilizadas como dados de treino e teste.<sup>1</sup>

Figura 1: A) amostra com falha. B) amostra sem falha.



O conjunto de imagens adquiridas utilizando as técnicas e materiais citados acima foram disponibilizados nos formatos de arquivo *.bin* e *.label*. Desses arquivos, foram extraídas as imagens e rótulos indicando a presença ou inexistência de falha, a figura 1 apresenta exemplos dessas imagens. Esses rótulos foram usados posteriormente para separar as imagens em 2 pastas. Separadamente os dois conjuntos de imagem foram utilizados para criar conjuntos de treino e validação. Primeiro as imagens foram embaralhadas em ordem aleatória e separadas em 20% para validação e 80% para treinamento. Em seguida as imagens são convertidas para o formato tensor e suas dimensões escaladas quando necessário.

A arquitetura das redes adversárias generativas desenvolvidas para gerar as imagens sintéticas foi implementada utilizando a biblioteca *Tensorflow*. Entre as camadas implementadas, três se destacam. A camada de convolução 2D responsável por reduzir a dimensionalidade e extrair características que serão importantes para avaliar as imagens reais e geradas. Por sua vez, as camadas de convolução transposta promovem o aumento da escala dos dados por meio da imputação de dados através de *kernels*. Já a camada Densa tem utilidade tanto na classificação das características extraídas das imagens quanto na expansão do vetor de entrada aleatório do gerador.

Como citado anteriormente, o estudo utilizou a técnica de aumento adaptativo do discriminador para viabilizar o treinamento da GAN por conta do baixo volume de dados. O aumentador pode modificar as imagens por meio de quatro operações. Translação, rotação, ampliação e espelhamento. Estas operações ocorrem de maneira aleatória e seus limites são definidos por coeficientes individuais de cada uma das operações.

A avaliação das imagens sintéticas geradas se deu por meio da *Kernel Inception Distance (KID)*. Como descrito por *BETZALEL et al., 2022*, *KID* mede a discrepância média máxima quadrada entre as representações das amostras reais e geradas usando um kernel polinomial. Essa métrica assume valores positivos, com o menor valor possível sendo zero. Quanto maior o valor da *KID*, menor é a semelhança entre as imagens comparadas. Desta forma o objetivo aqui é minimizar essa métrica

### 3. RESULTADOS E DISCUSSÃO

Através de experimentos realizados utilizando as ferramentas e técnicas descritas no tópico anterior, foram treinados três conjuntos de rede adversárias generativas. Variando apenas o número de épocas de treinamento. Observando a métrica KID, é perceptível que os modelos não apresentam diferença significativa com relação a qualidade das imagens geradas. Resultados podem ser encontrados na tabela abaixo.

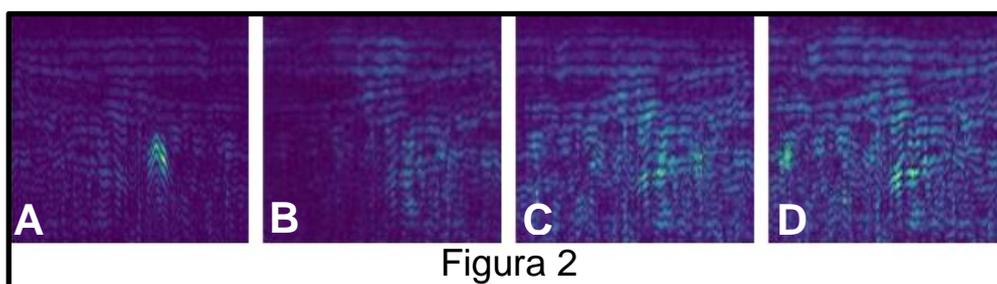
Tabela 1: Comparação entre KID e número de épocas de treino

KID ( <i>Kernel Inception distance</i> )	Épocas de treinamento
0,417	10
0,407	20
0,448	30

### 4. CONSIDERAÇÕES FINAIS

Os resultados encontrados demonstram que as redes adversárias generativas são capazes de mapear e reproduzir as estruturas de dados de imagens de testes ultrassônicos, isso pode ser atestado pelo valor da métrica KID alcançado. Além disso, os dados coletados indicam que a técnica de aumento adaptativo do discriminador viabiliza o treinamento de GANs com um volume reduzido de dados. Abaixo, na Figura 2, segue uma comparação entre as imagens geradas e reais.

Figura 2: Imagens de PAUT. A) original B) 10 épocas C) 20 épocas D) 30 épocas



### Agradecimentos

Esta pesquisa foi realizada em parceria entre o SENAI CIMATEC e a Shell Brasil. Os autores gostariam de agradecer à Shell Brasil Petróleo LTDA, à Empresa Brasileira de Pesquisa e Inovação Industrial (EMBRAPPI) e à Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP) pelo apoio e investimentos em PD&I.

### 5. REFERÊNCIAS

- <sup>1</sup>VIRKKUNEN, I. et al. **Augmented Ultrasonic Data for Machine Learning**. 2019. Disponível em: <<https://arxiv.org/abs/1903.11399>> Acesso em: 02 fev. 2024.
- <sup>2</sup>KARRAS, T. et al. **Training Generative Adversarial Networks with Limited Data**. 2020. Disponível em: <<https://arxiv.org/abs/2006.06676>> Acesso em: 11 mar. 2024.
- <sup>3</sup>BETZALEL, E. et al. **A Study on the Evaluation of Generative Models**. 2022. Disponível em: <<https://arxiv.org/abs/2206.10935>> Acesso em: 15 mar. 2024.
- <sup>4</sup>GOODFELLOW, I. J. et al. **Generative Adversarial Networks**. 2014. Disponível em: <<https://arxiv.org/abs/1406.2661>> Acesso em: 25 jan. 2024.