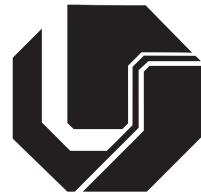


DAVI JUDÁ DE SOUZA FRAGA

**ANÁLISE DE INTEGRIDADE DE DUTOS RÍGIDOS
SUJEITOS À CORROSÃO GENERALIZADA
EMPREGANDO INTELIGÊNCIA ARTIFICIAL**



UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA MECÂNICA

2025

DAVI JUDÁ DE SOUZA FRAGA

**ANÁLISE DE INTEGRIDADE DE DUTOS RÍGIDOS SUJEITOS À
CORROSÃO GENERALIZADA EMPREGANDO INTELIGÊNCIA
ARTIFICIAL**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Mecânica da Universidade Federal de Uberlândia, como parte dos requisitos para a obtenção do título de **MESTRE EM ENGENHARIA MECÂNICA**.

Área de Concentração: Mecânica dos Sólidos e Vibrações.

Linha de Pesquisa: Confiabilidade Estrutural.

Orientador: Prof. Dr. Antônio Marcos Gonçalves de Lima

Uberlândia – MG
2025

Ficha Catalográfica Online do Sistema de Bibliotecas da UFU
com dados informados pelo(a) próprio(a) autor(a).

F811 Fraga, Davi Judá De Souza, 1999-
2025 ANÁLISE DE INTEGRIDADE DE DUTOS RÍGIDOS SUJEITOS À
CORROSÃO GENERALIZADA EMPREGANDO INTELIGÊNCIA
ARTIFICIAL [recurso eletrônico] / Davi Judá De Souza Fraga. - 2025.

Orientador: Antonio Marcos Gonçalves de Lima.
Dissertação (Mestrado) - Universidade Federal de Uberlândia,
Pós-graduação em Engenharia Mecânica.
Modo de acesso: Internet.
Disponível em: <http://doi.org/10.14393/ufu.di.2025.323>
Inclui bibliografia.

1. Engenharia mecânica. I. Lima, Antonio Marcos Gonçalves de,
1975-, (Orient.). II. Universidade Federal de Uberlândia. Pós-
graduação em Engenharia Mecânica. III. Título.

CDU: 621

Bibliotecários responsáveis pela estrutura de acordo com o AACR2:
Gizele Cristine Nunes do Couto - CRB6/2091
Nelson Marcos Ferreira - CRB6/3074



ATA DE DEFESA - PÓS-GRADUAÇÃO

Programa de Pós-Graduação em:	Engenharia Mecânica				
Defesa de:	Dissertação de Mestrado Acadêmico, nº 660, PPGEM				
Data:	27/06/2025	Hora de início:	09:00	Hora de encerramento:	10h30
Matrícula do Discente:	12322EMC002				
Nome do Discente:	Davi Judá de Souza Fraga				
Título do Trabalho:	Análise de integridade de dutos rígidos sujeitos à corrosão generalizada empregando inteligência artificial				
Área de concentração:	Mecânica dos Sólidos e Vibrações				
Linha de pesquisa:	Dinâmica de Sistemas Mecânicos				
Projeto de Pesquisa de vinculação:	Metodologia para Análise de Integridade de Dutos rígidos baseada em Estatística Avançada e Ferramentas de Inteligência Artificial				

Reuniu-se por videoconferência a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em Engenharia Mecânica, assim composta: Prof. Dr. Edson Hideki Koroishi - UTFPR; Prof. Dr. Marcus Antonio Viana Duarte - UFU e Prof. Dr. Antônio Marcos G. de Lima - UFU; orientador do candidato.

Iniciando os trabalhos, o presidente da mesa, Dr. Antônio Marcos G. de Lima, apresentou a Comissão Examinadora e o candidato, agradeceu a presença do público, e concedeu ao Discente a palavra para a exposição do seu trabalho. A duração da apresentação do Discente e o tempo de arguição e resposta foram conforme as normas do Programa.

A seguir, o senhor presidente concedeu a palavra, pela ordem sucessivamente, aos examinadores, que passaram a arguir o candidato. Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando o candidato:

Aprovado.

Esta defesa faz parte dos requisitos necessários à obtenção do título de Mestre.

O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do Programa, a legislação pertinente e a regulamentação interna

da UFU.

Nada mais havendo a tratar, foram encerrados os trabalhos. Foi lavrada a presente ata que após lida e achada conforme foi assinada pela Banca Examinadora.



Documento assinado eletronicamente por **Antonio Marcos Gonçalves de Lima, Professor(a) do Magistério Superior**, em 27/06/2025, às 10:38, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Edson Hideki Koroishi, Usuário Externo**, em 27/06/2025, às 10:39, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Marcus Antonio Viana Duarte, Professor(a) do Magistério Superior**, em 27/06/2025, às 10:42, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site
https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **6411272** e o código CRC **C1EA37E3**.

Referência: Processo nº 23117.039423/2025-74

SEI nº 6411272

AGRADECIMENTOS

Agradeço primeiramente a Deus por nunca me desamparar e me guardar em todo o tempo.

À minha família, em especial meus pais, Paulo Cezar e Marlineide Pereira , que sempre estiveram ao meu lado motivando para vencer todos os obstáculos, minha irmã, Sarah, pelo apoio em toda a minha jornada, a minha amiga, Márcia Cristina, por todo o apoio e paciência que teve comigo.

Ao Prof. Dr. Antônio Marcos pela orientação e por ter feito isso da melhor forma possível. Agradeço imensamente por sua paciência e compreensão durante a construção deste trabalho.

Ao Prof. Dr. Marcelo deixo meus sinceros agradecimentos por todo o auxílio, paciência e disponibilidade que tornaram possível a realização deste trabalho.

Aos membros da banca examinadora, prof. Dr. Edson Hideki Koroishi e prof. Dr. Marcus Antonio Viana Duarte pelo aceite e disponibilidade em contribuir com o meu trabalho.

Aos meus amigos e colegas do Laboratório de Mecânica de Estruturas (LMEst), em especial à Leonardo Cabral, Ely Queiroz, Fernanda Beatriz, Fernanda Rossi, Leonardo Sicchieri, Raimundo Neto, Stanley Washington, Larissa, Kaique e Fabrício pelo auxílio e acolhimento, que tornou essa jornada mais leve.

Aos meus amigos pessoais, em especial André Felipe, Arthur Ganam, Flávio Evangelista, Bruno Bonifácio, Aline Costa, Tiago Guimarães, Habnner, André Lemos e Larissa Lemos por todo o apoio ao longo desse trabalho e pelas risadas que tornaram os dias mais leves.

Ao Programa de Pós-Graduação em Engenharia Mecânica da Universidade Federal de Uberlândia (UFU) pela oportunidade de realizar o Curso de Mestrado Acadêmico em Engenharia Mecânica.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e a Petrobras pelo apoio financeiro fornecido para a realização deste trabalho.

E por fim, a todos que de alguma forma, contribuíram para a minha formação acadêmica, meu sincero obrigado.

FRAGA, D. J. S., **Análise de integridade de dutos rígidos sujeitos à corrosão generalizada empregando inteligência artificial.** 2025. 79 f. Dissertação de Mestrado, Universidade Federal de Uberlândia, Uberlândia.

RESUMO

Grande parte dos hidrocarbonetos produzidos em ambiente *offshore* é transportado através de dutos rígidos submarinos. Entretanto, tais sistemas estão frequentemente sujeitos à corrosão, podendo levar a acidentes graves e/ou catástrofes. Neste sentido, muitos esforços têm sido feitos pelas indústrias do petróleo e gás afim de evitar tais incidentes, além da redução significativa dos custos com inspeções. Tendo em vista esse objetivo técnicas de inspeção e ferramentas estatísticas para avaliar a integridade física dos dutos são amplamente utilizadas na indústria. Atualmente, a principal forma de monitorar a corrosão é através de inspeções regulares realizadas nas linhas de dutos rígidos. Nos chamados dutos pigáveis, essas inspeções são realizadas com o uso de um equipamento de ensaio não destrutivo conhecido como PIG (*Pipeline Inspection Gauge*). Esse equipamento é capaz de realizar a limpeza interna do duto e coletar informações da perda de espessura desse tipo de ativo. Contudo, devido ao alto custo, tais inspeções são realizadas seguindo um cronograma estabelecido pelos engenheiros de manutenção. Eles definem as datas de inspeção a partir dos dados obtidos pelo PIG, e através de métodos estatísticos de previsão de vida remanescente (RUL- *Remaining Useful Life*) eles fazem previsões sobre o tempo útil de tais sistemas com um dado nível de confiança. No entanto, tais métodos tendem a ser extremamente conservadores, o que ocasiona em um maior número de inspeções nos dutos, elevando os gastos da produção. Tendo em vista esse cenário, o presente trabalho sugere a utilização de uma metodologia híbrida, que combina a geração de dados sintéticos usando estatística com ferramentas de inteligência artificial (IA) para estimar a vida remanescente de dutos rígidos pigáveis. Os dados de inspeção obtidos nos ensaios serão utilizados para a determinação da vida remanescente e para a validação da metodologia. Os resultados obtidos mostram que, tal metodologia consegue seguir a tendência de crescimento da profundidade de corrosão na parede do oleoduto, sendo bastante promissora para a sua extensão para o caso de dutos não pigáveis.

Palavras-chave: Vida Remanescente. Ensaios não destrutivos. Dados sintéticos. Inteligência Artificial.

FRAGA, D. J. S., **Integrity analysis of rigid pipelines subjected to generalized corrosion using artificial intelligence.** 2025. 79 p. Dissertation, Federal University of Uberlândia, Uberlândia.

ABSTRACT

The phenomenon of corrosion is a recurrent problem in the oil and gas industries, where unexpected failures can cause damage and failures of the components, affecting the safety and lives of users. In this case, by considering that, the degradation processes in such industries occur by physico-chemical phenomena capable of completely degrading the walls of pipes and ducts, these industries have been spent significant amounts of money in inspections and equipments of it with the aim of monitoring their assets suffering from corrosion. Thus, this work aims to use artificial intelligence (AI) approaches combined with statistics to estimate remaining useful life (RUL) of subsea pipelines subjected to general corrosion processes. The proposed methodology incorporates extreme value methods to generate synthetic data by using bootstrap methods to enrich the initial data for training and test the neural networks. This strategy proposed in this study has demonstrated efficiently due to the poor historical initial data available by performing non destructive testing (NDT) inspection data by the industries. In the quest for the neural network approach, it has been used the so-called Multilayer Perceptron (MLP) taking into account the wall thickness measurements over the equipment's operational period as parameter for a time series analysis. The proposed methodology showed results with a mean absolute error of around 23,75% when compared with the 2024 inspection. Finally, the RUL estimated by the proposed method has compared with the classical t-student method and semi-probabilistic approach, showing the remaining life prediction in each methodology.

LISTA DE FIGURAS

Figura 2.1 – Representação das partes de um duto rígido submarino. Adaptado de: https://www.repositorio.mar.mil.br/handle/ripcmb/845365	7
Figura 2.2 – Representação da reação de corrosão(SILVA et al., 2015)	8
Figura 2.3 – Representação dos tipos de corrosão. a) Corrosão uniforme, b) Corrosão por pite, c) Cavitação e corrosão por erosão, d) Corrosão por corrente parásitária, e) Corrosão influenciada por microrganismos. Fonte:(VANAEI; ESLAMI; EGBEWANDE, 2017)	10
Figura 2.4 – Representação de um PIG instrumentado (MAZZINI, 2009)	13
Figura 2.5 – Representação do teste de corrente de Foucault. Fonte (COSTA JÚNIOR, 2021).	14
Figura 2.6 – PIG MFL. Fonte (COSTA JÚNIOR, 2021)	15
Figura 2.7 – Dados de cupom de corrosão (Cortesia da Petrobras).	16
Figura 3.1 – Variação da distribuição T-student conforme o aumento do grau de liberdade.	19
Figura 3.2 – Geometria de falha. Fonte: (PEREIRA JUNIOR, 2021)	21
Figura 3.3 – Esquema de previsão de vida via método semi-estocástico	25
Figura 4.1 – Relação entre ML, DL e Inteligência Artificial, adaptado de Rezende et al. (2021)	28
Figura 4.2 – Representação simples de um neurônio, adaptado de Rezende et al. (2021)	30
Figura 4.3 – Representação de um perceptron, adaptado de Rezende et al. (2021)	31
Figura 4.4 – Representação esquemática de um modelo MLP	31
Figura 5.1 – Representação das etapas da metodologia híbrida	35
Figura 5.2 – Inspeção 2013	36
Figura 5.3 – Inspeção 2016	36
Figura 5.4 – Inspeção 2021	37
Figura 5.5 – Inspeção 2024	37
Figura 5.6 – Diagrama de blocos dos pontos de corrosão	38
Figura 5.7 – Diagrama de divisão das secções dos intervalos do duto	40
Figura 5.8 – Perda de parede média em cada intervalo de 250 metros	40

Figura 5.9 – Perda média de parede nos primeiros 250 metros.	41
Figura 5.10 – Distribuição de Weibull variando parâmetro de escala.	42
Figura 5.11 – Distribuição de Weibull variando parâmetro de forma.	43
Figura 5.12 – Comparação curva ajustada aos dados.	44
Figura 5.13 – Comparação dados sintéticos e curva ajustada aos dados.	45
Figura 5.14 – Histórico processual erro médio absoluto para treinamento da rede aos dados do intervalo 1.	48
Figura 5.15 – Histórico processual erro médio quadrático para treinamento da rede aos dados do intervalo 1.	49
Figura 5.16 – Comparativo treino, teste e dados sintéticos do intervalo 1.	50
Figura 5.17 – Representação de determinação da vida remanescente usando IA.	51
Figura 5.18 – Previsão de vida remanescente intervalo 1.	51
Figura 5.19 – Erro absoluto (Inspeção 2024 - IA 2024).	52
Figura 5.20 – Previsão usando análise Semi-estocástica.	54
Figura 5.21 – Método Kriging.	56
Figura 5.22 – Erro absoluto.	56

LISTA DE TABELAS

Tabela 2.1 –	Distribuição das causas dos acidentes com dutos (1980-2006) adaptada de (GEREMIA, 2012)	11
Tabela 2.2 –	Fonte (NACE, 2005)	17
Tabela 3.1 –	Fator de segurança parcial γ_m . Adaptado (NOOR et al., 2009).....	22
Tabela 3.2 –	Fator de segurança parcial, γ_d e o fator, ε_d . Adaptado (NOOR et al., 2009)	22
Tabela 3.3 –	Desvio padrão, StD[d/t], para ferramenta de inspeção MFL. Adaptado (NOOR et al., 2009)	22
Tabela 3.4 –	Variação Temporal. (NOOR et al., 2009)	24
Tabela 4.1 –	Principais funções de ativação utilizadas em redes neurais artificiais. Adaptado Rezende et al. (2021)	33
Tabela 4.2 –	Principais funções de perda utilizadas no treinamento de redes neurais artificiais.	33
Tabela 5.1 –	Tabela com a perda de parede média em milímetros dos intervalos 1 ao 15.	41
Tabela 5.2 –	Determinação da unidade de tempo.	44
Tabela 5.3 –	Previsão de vida dos primeiros 9 intervalos de 250 metros do duto.	52

LISTA DE SÍMBOLOS E ABREVIATURAS

Símbolos latinos:

$f(x)$	Função polinomial
\mathbf{G}	Matriz polinomial
\mathbf{H}	Campo magnético
R^2	Coeficiente de determinação
\bar{x}	Média

Símbolos gregos:

β	Parâmetro de forma distribuição Weibull
θ	Parâmetros de correlação
λ	Parâmetro de escala distribuição Weibull
μ	Média
σ	Desvio Padrão
σ^2	Variância

Abreviaturas:

CNN	<i>Convolutional Neural Network</i>
MLP	<i>Multilayer Perceptron</i>
ReLU	<i>Rectified Linear Unit</i>
ELU	<i>Exponential Linear Unit</i>
RUL	<i>Remaining Useful Life</i>
IA	Inteligência Artificial

IDE	<i>Integrated Development Environment/ Ambiente de Desenvolvimento Integrado</i>
DL	<i>Deep Learning</i>
LMEst	Laboratório de Mecânica de Estruturas
TanH	Função Tangente Hiperbólica
END	Ensaio não Destruutivo
PIG	<i>Pipeline Inspection Gauge</i>
MCI	Monitoramento da Corrosão Interna
RMSE	<i>Root Mean Square Error</i>
RMAE	<i>Relative Mean Absolute Error</i>
MSE	<i>Mean Square Error</i>
MAE	<i>Mean Absolute Error</i>

SUMÁRIO

CAPÍTULO I: INTRODUÇÃO	1
1.1 Objetivos	2
1.1.1 Objetivos específicos	3
1.2 Justificativa	3
1.3 Estrutura da Dissertação	4
CAPÍTULO II: CORROSÃO E INSPEÇÃO EM DUTOS RÍGIDOS	6
2.1 Dutos Rígidos.....	6
2.2 Corrosão	8
2.2.1 Corrosão em dutos rígidos.....	9
2.2.2 Acidentes com dutos	10
2.3 Controle da corrosão interna em dutos <i>Offshore</i>	11
2.3.1 Obtenção de dados a partir de inspeções	12
2.4 PIG	12
2.4.1 PIG MFL.....	13
2.5 Monitoramento da corrosão	15
2.5.1 Cupons de corrosão	15
2.5.2 Preparação, instalação, análise e interpretação dos cupons de corrosão ...	16
CAPÍTULO III: MÉTODOS ESTATÍSTICOS PARA PREVISÃO DE VIDA DE SISTEMAS QUE SOFREM COM CORROSÃO.....	18
3.1 Distribuição T-student e a previsão de vida remanescente	18
3.2 Teoria de valores extremos e método POT	20
3.3 Método semi-estocástico para previsão de vida	20
CAPÍTULO IV: CONCEITOS BÁSICOS SOBRE REDES NEURAIS ARTIFICIAIS	26
4.1 Conceito de <i>Machine Learning</i> e <i>Deep Learning</i>	26
4.1.1 Algumas Aplicações	28
4.2 Redes Neurais Artificiais	29

4.2.1	<i>Funções de ativação</i>	32
4.2.2	<i>Formas de Aprendizagem</i>	32
CAPÍTULO V: METODOLOGIA HÍBRIDA PARA PREVISÃO DE VIDA DE SISTEMAS QUE SOFREM COM CORROSÃO.....		35
5.1	Exibição dos dados de inspeção	35
5.2	Geração dos dados sintéticos	38
5.2.1	<i>Modelo exponencial ajustado</i>	39
5.2.2	<i>Ajuste da distribuição Weibull</i>	41
5.3	Treinamento da rede MLP	45
5.3.1	<i>Normalização dos dados</i>	46
5.4	Construção e treinamento da rede MLP	46
5.5	Previsão de vida remanescente (RUL)	50
5.6	Resultados	52
5.7	Trabalhos futuros e aplicação em dutos não Pigaveis	54
CAPÍTULO VI: CONSIDERAÇÕES FINAIS		57
6.1	Trabalhos futuros	58
REFERÊNCIAS BIBLIOGRÁFICAS		59
APÊNDICE A: CÓDIGOS CONSTRUÇÃO DE REDE NEURAL ARTIFICIAL		63

CAPÍTULO I

INTRODUÇÃO

Apesar dos esforços na busca de formas de energia renováveis, como a eólica e a solar, a energia proveniente dos derivados de petróleo ainda ocupa lugar central na matriz energética mundial. Os hidrocarbonetos estão presentes na indústria aeronáutica, automobilística e naval de forma direta, além de estarem presentes nas cadeias produtivas dos mais variados tipos de produtos.

Devido sua importância, as empresas produtoras de petróleo investem boa parte de seus recursos a fim de manter uma produção eficiente e capaz de atender o competitivo mercado mundial. Contudo, a exploração e refino do petróleo é uma tarefa desafiadora e exige a utilização de diversas máquinas e equipamentos que precisam operar continuamente todos os dias. Com isso, o desgaste desses equipamentos é inevitável.

Um dos equipamentos centrais no transporte de petróleo e gás natural é o duto rígido. Devido à alta complexidade e o difícil acesso, a inspeção de dutos submarinos é uma atividade altamente complexa e de elevado custo. Vale ressaltar também que os dutos rígidos são o meio de transporte de hidrocarbonetos mais utilizado na atualidade (ADDOR, 2009), logo, existe o perigo de vazamentos e contaminação do meio ambiente com petróleo bruto.

Os principais tipos de falhas que causam desgaste em dutos submarinos são: problemas na fabricação e na montagem do duto, desgaste devido a corrosão, que pode ser interna e/ou externa, e correntes marítimas (HO et al., 2020)

Por essa razão, as empresas gastam boa parte de seus recursos devido a danos ou prevenindo a corrosão nos equipamentos. Foi calculado em 2001 que o custo direto de todos os tipos de corrosão nos Estados Unidos chega anualmente a US\$ 276 bilhões ou 3,1% do produto interno bruto do país (KOCH et al., 2002).

Tendo em vista esse cenário, inspeções regulares em dutos são de fundamental importância. Um bom plano de manutenção possibilita uma produção organizada e contínua, com menos imprevistos além de evitar acidentes e desastres ambientais devido o vazamento de petróleo ou gás natural.

As inspeções realizadas em dutos são através de ensaios não destrutivos. Nos dutos rígidos, para aferição do desgaste da parede dos dutos, utiliza-se o PIG (*Pipeline Inspection Gauge*), sendo utilizados na área de inspeção da integridade da parede dos dutos. Sua maior vantagem, está no fato de proporcionar uma análise dos dutos sem que haja a necessidade de desmontar parte do mesmo para análise, reduzindo os custos da manutenção(BACELAR; SOUZA; DEMETINO, 2019). O PIG utiliza a variação do fluxo do campo magnético para determinar a espessura atual da parede do duto de petróleo, proporcionando assim um melhor acompanhamento da degradação do duto com o passar do tempo. Existem outros tipos de PIG, contudo, o mais utilizado é o de variação do campo eletromagnético.

Além dos dutos que comportam a passagem de um instrumento de medição como o PIG, existem aqueles onde a passagem desse equipamento não é possível. Nesse caso são os dutos tidos como não pigáveis. Nestes casos, os equipamentos para a inspeção são utilizados apenas em pontos críticos da tubulação(ALVES; LOPES, 2005).

Com os dados obtidos pelo PIG, é possível fazer uso de técnicas estocásticas para determinação da vida remanescente da tubulação, ou técnicas semi-empíricas como a sugerida pela norma RP-F101(NOOR et al., 2009). Além disso, outras técnicas estocásticas como o método FORM (*First Order Reliability Method*), também podem ser utilizados para estimar a vida remanescente dos equipamentos submetidos a corrosão (LEMOS et al., 2021). Portanto, através desses métodos, os planos de manutenção são determinados pela equipe de engenheiros de inspeção.

Entretanto, muitas destas metodologias tendem a ser extremamente conservativas, o que gera um maior aumento no número de inspeções nos dutos, acarretando em mais gastos.

Diante disso, com o objetivo de aumentar a confiabilidade operacional e redução de custos de manutenção e paradas programadas de dutos submarinos para transporte de gás natural e hidrocarbonetos, este trabalho visa realizar pesquisas envolvendo aprendizagem de máquina e redes neurais para análise de dados de inspeção via PIG com o foco na estimativa da vida residual de tais sistemas.

1.1 Objetivos

O objetivo dessa Dissertação é propor uma ferramenta avançada utilizando técnicas de aprendizado profundo (*Deep Learning*) capaz de prever a taxa de corrosão dos tubos ao longo do tempo e determinar a vida remanescente dos dutos submarinos.

Neste sentido, espera-se poder contribuir com o processo de inferência atualmente realizado pela indústria do petróleo, uma vez que os métodos clássicos de previsão de vida são extremamente conservadores, o que acarreta uma maior quantidade de inspeções internas que registram uma espessura de parede ainda muito superior a medida de parada.

Em suma, a metodologia proposta visa auxiliar as equipes de manutenção a determinar prazos maiores entre as paradas programadas, mantendo a confiabilidade e os padrões de segurança estabelecidos pelas normas técnicas de segurança.

1.1.1 Objetivos específicos

- Desenvolver uma ferramenta avançada que utiliza redes neurais e procedimentos estatísticos para aumentar a precisão na estimativa do aumento da perda de parede de dutos rígidos;
- Desenvolver e implementar em linguagem *Python* modelos de previsão do tipo MLP para aplicar em séries temporais, afim de prever a vida útil;
- Utilizar os dados de inspeção para validar as previsões feitas por IA;
- Gerar dados sintéticos por meio do histórico de inspeção afim de criar um vasto banco de dados para treinamento da rede;

1.2 Justificativa

A inspeção de dutos submarinos é uma etapa crucial durante uma parada operacional para manutenção, pois os resultados desse exame são fundamentais para definir a vida remanescente da linha, bem como para determinar a necessidade de reparos afim de evitar vazamentos de agentes contaminantes no meio ambiente.

Contudo, ao estimar a vida remanescente dos dutos, as empresas utilizam métodos que atribuem uma taxa de corrosão linear ou elevados fatores de confiabilidade. Sabendo que a corrosão é um fenômeno estocástico, e que fatores ambientais podem acelerar ou desacelerar o processo corrosivo, as taxas de corrosão utilizadas nessas estimativas são muito elevadas, a fim de manter um alto padrão de confiabilidade.

Com isso, os métodos de previsão de vida costumam determinar vidas remanescentes curtas, o que geram paradas programadas para inspeção com mais frequência e, consequentemente, um maior gasto em inspeções internas nos dutos submarinos. Entretanto, ao se avaliar a integridade do duto, percebe-se que o mesmo não teve uma mudança significativa na perda de parede, e que tal intervenção poderia ser adiada sem nenhum prejuízo ambiental.

Tendo em mente esse problema e o avanço da tecnologia, foi então que a utilização de técnicas de *machine learning* se mostraram muito eficientes para determinar o crescimento da corrosão com o passar do tempo. Esses algoritmos são capazes de estimar uma correlação entre

dados quando uma relação matemática não é facilmente observada. Além disso, sua capacidade adaptativa a novos dados proporciona a inteligência artificial uma vantagem operacional, uma vez que basta retreinar o modelo com novos dados para que ele atualize a previsão da vida remanescente a cada nova inspeção.

Porém, devido à baixa quantidade de histórico na manutenção dos equipamentos, propõe-se a geração de dados sintéticos, cuja finalidade é suprir a escassez de informações reais para a etapa de aprendizagem das redes neurais artificiais. Uma vez treinadas e testadas, os modelos da rede serão empregados para determinar a vida útil dos dutos rígidos.

Portanto, a partir dos parâmetros obtidos de uma amostra (inspeção via PIG do duto), ferramentas estatísticas e de *machine learning* serão empregadas para estimar o crescimento da profundidade de corrosão média na parede do duto. E com o aumento do histórico de inspeções, a utilização de dados sintéticos também será reduzida, sendo substituído por dados reais de inspeção.

1.3 Estrutura da Dissertação

Esta dissertação está dividida em 7 capítulos:

O Capítulo 1 discute brevemente o fenômeno de corrosão, aponta os principais métodos e ferramentas que serão utilizados no desenvolvimento deste trabalho. Neste capítulo, também são abordados os principais objetivos e contribuições desta pesquisa, finalizando com a descrição da estrutura utilizada na dissertação.

O Capítulo 2 discute detalhadamente o fenômeno de corrosão e descreve os métodos de controle de corrosão usados na indústria atual. Também aborda o funcionamento das inspeções em dutos rígidos submarinos, os tipos de PIG, como são usados os cupons de corrosão e algumas normas para determinar a pressão máxima resistida pelo duto.

O Capítulo 3 apresenta os métodos estatísticos para previsão de vida remanescente, dentre eles a previsão de vida usando a distribuição T-student e o método semi-estocástico. Além disso esse capítulo visa mostrar o método de valores extremos e como o mesmo é utilizado para determinar pontos de risco ao oleoduto.

O Capítulo 4 apresenta uma fundamentação teórica sobre redes neurais artificiais, aprendizagem de máquinas, a arquitetura da rede utilizada, linguagem de programação utilizada e métodos de previsão usando séries temporais.

O Capítulo 5 mostra a aplicação da metodologia proposta neste trabalho, que utiliza dados sintéticos gerados para realizar o treino da rede neural artificial. Além disso, mostra a aplicação deste método em um equipamento real, determinando a vida remanescente do mesmo e usando uma de suas inspeções para a validação do método.

O Capítulo 6 apresenta as conclusões desta dissertação, destacando sua eficácia, aplica-

bilidade e principais características. Além disso, é realizada uma síntese das contribuições mais relevantes, identificando aspectos que ainda podem ser explorados em pesquisas futuras.

E por fim, as referências utilizadas nesse trabalho se encontram no Capítulo 7.

Os códigos referentes ao modelo de rede neural estão no apêndice A.

CAPÍTULO II

CORROSÃO E INSPEÇÃO EM DUTOS RÍGIDOS

Neste capítulo serão abordados, ainda que de forma sucinta, os principais tipos de corrosão que ocorrem em dutos de petróleo e alguns conceitos sobre dutos submarinos, com o intuito de entender sobre as inúmeras variáveis que influem no processo de operação de dutos submarinos que sofrem com corrosão.

Ademais, será feita uma análise do fenômeno de corrosão interna em dutos, mostrando os principais tipos, sua classificação e como as indústrias fazem o monitoramento desse tipo de problema nos dutos.

2.1 Dutos Rígidos

Os dutos rígidos submarinos são estruturas responsáveis pelo escoamento de matéria prima entre o poço e o continente, além de interligar diferentes plataformas produtoras (MASSA, 2003).

As linhas de dutos rígidos são constituídas de tubos de aço carbono e, dependendo do fluido transportado, podem ser feitos de ligas especiais, que inibem a corrosão, abrasão e erosão. Também podem ser revestidas externamente com a finalidade de conservar a temperatura do fluido transportado, evitando a temperatura de formação de hidratos ou depósitos orgânicos (parafina). A figura 2.1 mostra como se divide as camadas de um duto rígido.

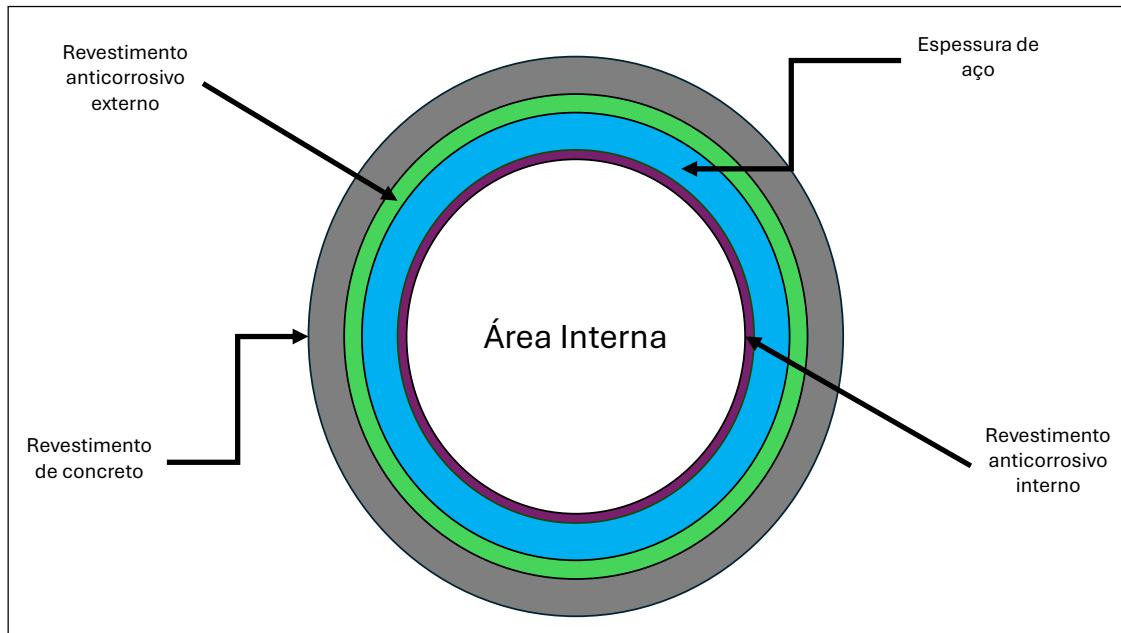


Figura 2.1 – Representação das partes de um duto rígido submarino. Adaptado de:
<https://www.repositorio.mar.mil.br/handle/ripcmb/845365> .

Os dutos podem ser classificados em três tipos, a saber: os subterrâneos, os aparentes e os submarinos. Os dutos submarinos são classificados assim porque a maior parte de sua extensão está submersa no fundo do mar (GEREMIA, 2012). Além da classificação quanto a posição, os dutos também podem ser classificados quanto ao produto que transportam, sendo eles: coleta, transporte ou distribuição (GEREMIA, 2012).

Tubos de coleta são pequenos gasodutos interligados formando redes com a finalidade de trazer o petróleo bruto ou gás natural a partir de vários poços nas proximidades (GEREMIA, 2012). São geralmente pequenos com pequeno diâmetro. Tubulações de transporte são longas, com grandes diâmetros, que transportam o produto por longas distâncias. Essas linhas incluem diversas estações de compressão, no caso de gasodutos, ou estações de bombeamento de líquido, para oleodutos (GEREMIA, 2012).

Tubulações de distribuição são compostas de diversos dutos com um pequeno diâmetro. Eles são utilizados para transportar o fluido a seu consumidor final (GEREMIA, 2012).

2.2 Corrosão

A corrosão é a deterioração de um metal, ou liga metálica, a partir de sua superfície, pelo meio no qual está inserido (SILVA et al., 2015). Por se tratar de um fenômeno físico-químico, o desgaste do material ocorre devido a reações de oxidação e redução que convertem o metal, ou liga metálica, em óxido, hidróxido ou sal.

A oxidação do ferro (Fe) ocorre porque ele é um elemento termodinamicamente instável na presença do oxigênio ($O_2(g)$). Além disso, devido a utilização de vapor de água para o aquecimento do óleo nas refinarias, os efeitos da corrosão são ainda mais severos, pois a presença de oxigênio ($O_2(g)$) e água ($H_2O(g)$) formam um meio mais reativo para aços(SILVA et al., 2015).

Atualmente, os aços-carbono comuns possuem mais de 97% de Fe, sendo esse um elemento químico que se torna termodinamicamente instável na presença de O_2 . Segundo Silva et al. (2015) quando exposto na presença de O_2 e H_2O o processo de corrosão se torna mais agressivo. Esta reação química forma uma camada porosa de produtos de corrosão conhecida como ferrugem.

No caso de um ambiente de alta umidade relativa, a condensação do vapor da água forma uma lâmina de água que cobre totalmente ou parcialmente a superfície metálica gerando assim uma pilha de corrosão(SILVA et al., 2015). Em suma, a formação da ferrugem pode ser representada pela figura 2.2.

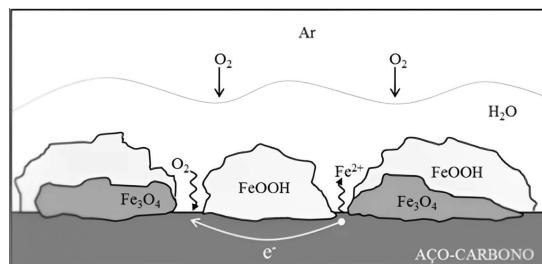


Figura 2.2 – Representação da reação de corrosão(SILVA et al., 2015) .

Embora a concentração de O_2 no ar seja constante, a sua solubilidade em água é muito baixa, sendo esse consumido rapidamente sobre a superfície do aço. O oxigênio será reposto naturalmente, porém deverá ultrapassar uma camada de ferrugem cada vez mais espessa para atingir uma área exposta cada vez menor, e assim sucessivamente. Por esta razão, a velocidade de corrosão diminui com o tempo(SILVA et al., 2015).

2.2.1 Corrosão em dutos rígidos

A corrosão em dutos na indústria petroquímica é de alta periculosidade, pois o vazamento de dutos rígidos acarreta na deposição de produtos inflamáveis e tóxicos no meio ambiente. O caso mais complexo é a contaminação da água do mar, onde a limpeza do óleo na água é de alta complexidade.

A corrosão interna em dutos rígidos submarinos pode ser classificada segundo os seguintes parâmetros estabelecidos pela literatura(ADDOR, 2009):

- Morfologia;
- As causas ou mecanismos;
- Os fatores Mecânicos;
- O meio corrosivo;
- Localização do ataque.

Tendo em vista essas características, Vanaei, Eslami e Egbewande (2017) classificam os principais tipos de corrosão interna em dutos submarinos da seguinte forma:

- **Corrosão uniforme:** O processo corrosivo é responsável por uma perda metálica em toda a superfície do material;
- **Corrosão localizada (puntiforme ou por pite):** Este processo se caracteriza pela perda localizada de material. Segundo Vanaei, Eslami e Egbewande (2017) a corrosão por pite é a principal causa de furos nos dutos rígidos ;
- **Corrosão induzida por microrganismos (microbiológica):** É o tipo de corrosão que ocorre devido a presença de bactérias que liberam substâncias corrosivas durante a sua respiração celular ;
- **Corrosão por cavitação:** É a degradação da parede do duto devido ao estouro de bolhas de ar no interior do duto. As bolhas de ar são geradas a partir do escoamento interno do fluido;
- **Corrosão por erosão:** É a degradação da parede do duto devido a erosão causada por sedimentos presentes no fluído.

A figura 2.3 ilustra como cada tipo de corrosão afeta as paredes de um duto rígido.

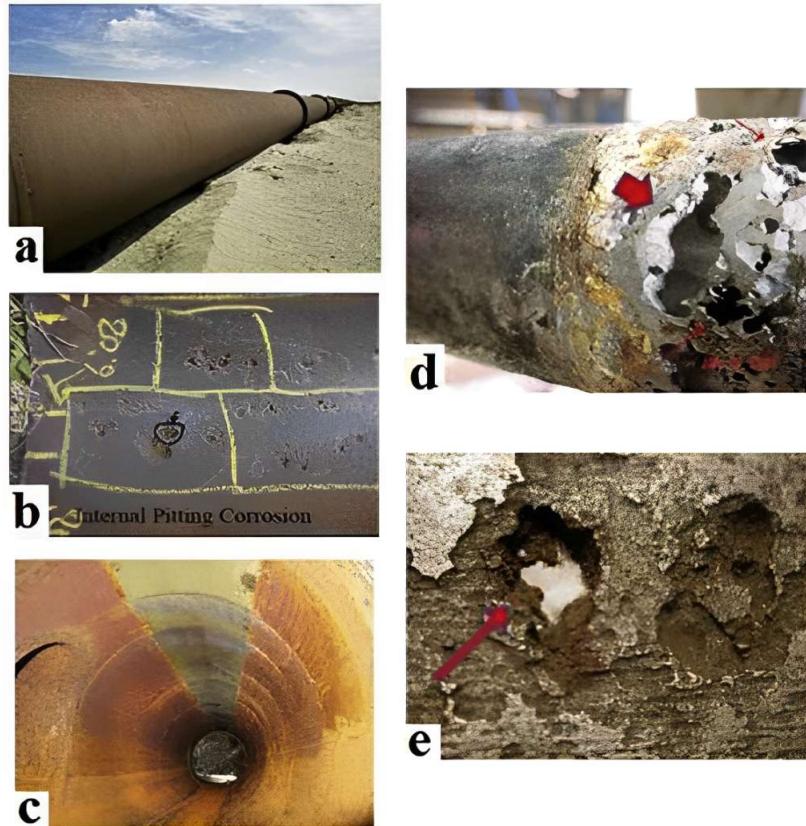


Figura 2.3 – Representação dos tipos de corrosão. a) Corrosão uniforme, b) Corrosão por pite, c) Cavitação e corrosão por erosão, d) Corrosão por corrente parasitária, e) Corrosão influenciada por microrganismos. Fonte:(VANAEI; ESLAMI; EGBEWANDE, 2017) .

Somado aos tipos de corrosão, também vale ressaltar que a temperatura acelera o processo de corrosão. Uma vez que componentes metálicos são naturalmente suscetíveis à corrosão quando expostos a agentes oxidantes, as reações dos metais com esses agentes são exotérmicas e, portanto, são termodinamicamente viáveis em altas temperaturas, uma vez que a diminuição da energia livre é menor, a reação é cineticamente favorecida e a velocidade de reação é relativamente maior (ZIBETTI, 2023).

2.2.2 Acidentes com dutos

Segundo Geremia (2012) uma das maiores causas de vazamentos de dutos é justamente o fenômeno da corrosão. A tabela 2.1 mostra as causas de falha em dutos rígidos.

Ainda analisando a tabela 2.1 podemos observar que:

Modo de Falha	1980-1989	1990-1999	2000-2006	Total
Terceiros	5	9	12	26
Natural	4	0	0	4
Operacional/manutenção	3	5	4	12
Operacional/outras	5	4	2	11
Mecânico/Corrosão	13	10	4	27
Mecânica/outras	3	6	4	13
Não apurada	2	56	21	79
TOTAL	35	90	47	172

Tabela 2.1 – Distribuição das causas dos acidentes com dutos (1980-2006) adaptada de (GEREMIA, 2012)

- Muitos dos registros por ação de terceiros entre 1980 e 2006 são atribuídas a acidentes em obras de infraestrutura, como perfuração feitas por empresas de telefonia, água e esgoto ;
- As causas naturais não tem sido registradas desde 1989;
- As causas não apuradas referem-se a casos relacionados a rompimentos de dutos que transportam gás natural, com vazamentos muito pequenos, sobre os quais não havia maior disponibilidade de informações a respeito dessas ocorrências nos registros da CADEQ CETESB.

2.3 Controle da corrosão interna em dutos *Offshore*

Segundo Addor et al. (2010), a metodologia mais recente para se obter o controle da corrosão interna em dutos rígidos *offshore* utiliza como princípio um programa de inspeção com PIGs inteligentes, sendo complementado pelo Monitoramento da Corrosão Interna (MCI). O MCI é o monitoramento e avaliação dos resultados das taxas de corrosão estimados por "cupons" de perda de massa, por sondas de corrosão instaladas em pontos específicos do duto, análises laboratoriais de amostras de fluidos e resíduos coletados durante a operação e pelo monitoramento de parâmetros de operação (pressão, temperatura e fluxo volumétrico, principalmente). As taxas de corrosão obtidas pelo MCI de um oleoduto em operação são usados para auxiliar a análise de integridade estrutural do duto.

Além disso, a inspeção em dutos tem a finalidade de avaliar danos mecânicos na tubulação, o estado do revestimento do sistema de proteção catódica, sistema de proteção operacional e acessórios do duto(MAZZINI, 2009).

2.3.1 *Obtenção de dados a partir de inspeções*

A fim de avaliar as condições dos dutos submarinos, informações como espessuras de parede interna e externa corroídas, parâmetros de operação como temperatura e pressão são necessárias. Para determinar essas informações, os operadores responsáveis devem realizar inspeções internas e externas nos dutos de maneira regular.

Contudo, segundo (CAMARGOS; OLIVEIRA, 2018) existe uma certa dificuldade de avaliar a integridade dos dutos mais antigos pois não havia a preocupação da realização de inspeções, de forma a não serem projetados adequadamente para a realização periódica de tais atividades. Por esta razão, em alguns casos, os equipamentos possuem um histórico limitado de dados e informações.

Existem inúmeras técnicas de inspeção em dutos, mas a escolha do método a ser empregado depende fortemente das condições ambientais as quais o equipamento está submetido.

Segundo CAMARGOS e OLIVEIRA (2018) as rotinas normais de inspeção em dutos rígidos submarinos são divididos em dois locais, interno, tipicamente realizada por PIGs, e externo, no qual se usam veículos operados remotamente. Neste trabalho, o estudo dedicou-se às inspeções internas realizadas por PIGs.

2.4 PIG

Os PIGs instrumentados são capazes de informar as condições das linhas. Eles podem informar sobre a localização de imperfeições nos dutos, detecção de vazamentos e pontos onde há redução da parede (MAZZINI, 2009). E, apesar da existência de dutos não pigáveis, os PIGs são bastante utilizados. Sua principal vantagem está no fato de poder determinar as condições internas de toda a extensão do duto em análise. A estrutura do PIG pode ser vista na figura 2.4.

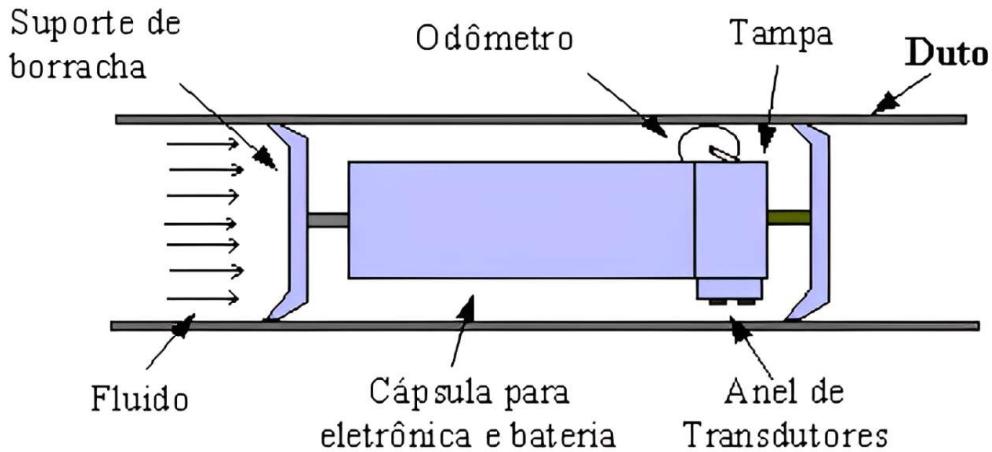


Figura 2.4 – Representação de um PIG instrumentado (MAZZINI, 2009)

O PIG é introduzido dentro do duto e viaja por toda a sua extensão, impulsionados pela própria vazão do fluido. Ele também pode realizar funções de limpeza, separação de produtos, dentre outros, sendo utilizado para a aquisição de dados sobre a integridade do duto.

O grande avanço no uso dessas ferramentas deve-se ao fato do aumento do número de dutos chegando ao final de sua vida útil de projeto, e desta forma, devem ser rigorosamente inspecionados a fim de verificar possíveis falhas e permitir uma decisão segura quanto a sua continuidade operacional.

Nas tecnologias modernas, a aquisição de dados ocorre a cada 2 ou 3 mm de deslocamento da ferramenta, coletando informações em vários pontos ao longo da circunferência do tubo a cada medição (COSTA JÚNIOR, 2021). Dentre os métodos utilizando PIG para detecção de corrosão, os mais utilizados são os PIGs de ultrassom e os PIGs baseados na técnica de Magnetização por Fuga de Fluxo (MFL) (COSTA JÚNIOR, 2021).

2.4.1 PIG MFL

Apesar de existirem vários tipos de PIG de inspeção, a mais utilizada é a inspeção por PIG MFL (COSTA JÚNIOR, 2021). Afim de entender como o MFL funciona, é preciso entender o teste de corrente de Foucault. Esse teste é a base para o fenômeno de fuga de campo magnético que ocorre na inspeção PIG MFL.

Segundo COSTA JÚNIOR (2021), o teste tem por finalidade identificar falhas em um material condutor. O teste consiste na indução de uma corrente em uma superfície por meio de uma bobina posicionada próxima ao material a ser examinado. Essa bobina conduz uma corrente alternada, gerando, por sua vez, um campo magnético que induz a formação da corrente de Foucault no material. Além disso, uma segunda bobina é responsável por monitorar as variações

nos parâmetros elétricos e magnéticos tanto da corrente de Foucault quanto da corrente gerada pela bobina principal. Na presença de um defeito ocorre uma variação no campo magnético, que é detectado pela bobina de busca, registrando assim a perda de parede e o comprimento da descontinuidade.

A figura 2.5 representa esse fenômeno.

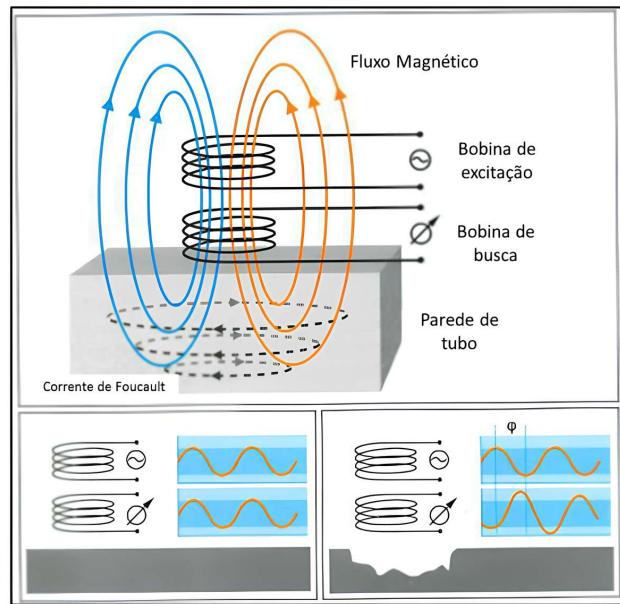


Figura 2.5 – Representação do teste de corrente de Foucault. Fonte (COSTA JÚNIOR, 2021)

Este método é muito eficaz na detecção de perdas de metal por corrosão, pois qualquer variação na espessura da parede impacta diretamente a distribuição das linhas de campo magnético geradas pelos ímãs do PIG (COSTA JÚNIOR, 2021). A figura 2.6 mostra um PIG MFL e alguns de seus componentes.

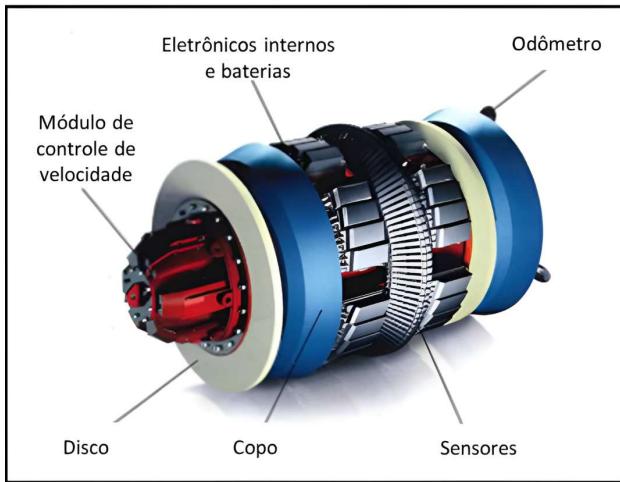


Figura 2.6 – PIG MFL. Fonte (COSTA JÚNIOR, 2021)

2.5 Monitoramento da corrosão

O monitoramento da corrosão permite auxiliar a equipe de operação a determinar os planos de manutenção dos dutos em operação. Os tópicos a seguir descrevem a utilização dos cupons de corrosão, e das normas utilizadas para determinar a integridade do duto em análise.

2.5.1 Cupons de corrosão

Cupons de corrosão são pequenas amostras de metal confeccionadas com materiais diversos em forma de haste retangular ou em forma de disco. Esses cupons são depositados em locais de interesse, durante um período de tempo para determinar a reação de deterioração do metal em um meio corrosivo (SILVA, 2014).

Os cupons de corrosão fornecem dois tipos de informação: a corrosividade do meio e o dano que a instalação sofre em decorrência do meio. Os cupons são periodicamente examinados para determinar a taxa de corrosão. A figura 2.7 mostra as taxas de corrosão obtidas a partir de cupons de corrosão instalados nos dutos.

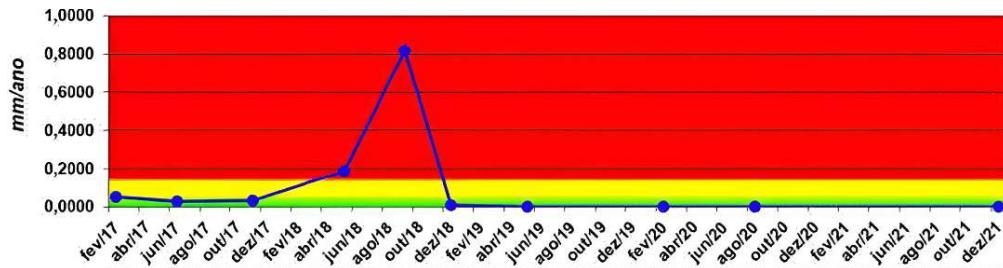


Figura 2.7 – Dados de cupom de corrosão (Cortesia da Petrobras).

Diversas metodologias são utilizadas para a caracterização da corrosão por *pites* em cupons. As normas NACE RP0775 (2005), ASTM G46 (2005) e NBR 9771 (1987) estabelecem os requisitos necessários para a identificação, análise e avaliação desse tipo de corrosão (SILVA, 2014).

2.5.2 Preparação, instalação, análise e interpretação dos cupons de corrosão

Segundo SILVA (2014), a norma NACE Standard RP0775-2005 determina a forma de utilização dos cupons de corrosão no campo petrolífero de perfuração, produção e operações de transporte. Ela determina também a preparação e técnicas de manuseio dos cupons de metal antes e depois da exposição ao ambiente corrosivo.

Além da perda de massa, existem outros pontos a serem avaliados nos cupons de corrosão, dentre eles a localização, o tempo em operação, a medida da profundidade do pite, entre outros (SILVA, 2014).

Ainda segundo SILVA (2014), a norma NACE Standard RP0775-2005 divide-se nas seguintes etapas: processamento de cupons de corrosão, instalação dos cupons de corrosão, gravação de dados em relatório e interpretação dos dados.

A taxa de corrosão é determinada usando a equação (2.1)

$$CR = \frac{(W \cdot 365 \cdot 1000)}{(A \cdot T \cdot D)} \quad (2.1)$$

Onde CR é a taxa média de corrosão uniforme, W é a perda de massa, A é a área inicial exposta, T é o tempo de exposição, D é a densidade do metal.

Para determinar a taxa máxima por pite (PR), usa-se a equação (2.2),

$$PR = \frac{\text{profundidade do pite} \cdot 365}{\text{Tempo}} \quad (2.2)$$

Por fim, a perda de massa pode ser convertida em perda de espessura total, ou taxa de corrosão generalizada. O processo corrosivo pode ser classificado como baixo, moderado ou alto. A tabela abaixo representa a classificação NACE (2005).

	Taxa Corrosão uniforme mm/ano	Taxa máxima pites mm/ano
Baixo	<0,025	<0,13
Moderado	0,025 - 0,12	0,13 - 0,20
Alto	0,13 - 0,25	0,21 - 0,38
Severo	>0,25	>0,38

Tabela 2.2 – Fonte (NACE, 2005)

CAPÍTULO III

MÉTODOS ESTATÍSTICOS PARA PREVISÃO DE VIDA DE SISTEMAS QUE SOFREM COM CORROSÃO

Este capítulo tem por finalidade apresentar alguns métodos de análise dos dados de inspeção e metodologias estatísticas para previsão de vida remanescente de dutos rígidos. Será abordado a previsão de vida usando a distribuição T-student e o método semi-estocástico que provém da norma DNV-RP-F101. Também será discutido a análise de dados usando a teoria de valores extremos e o método POT (*Peak-Over-Threshold*).

3.1 Distribuição T-student e a previsão de vida remanescente

Nas últimas décadas, tem-se observado o uso crescente da distribuição T-student (CINTRA, 2004) para a análise de dados de inspeção de inúmeros ativos industriais, principalmente na indústria do petróleo e gás. Ainda segundo Cintra (2004) este interesse é devido ao fato de que a distribuição T-student têm caudas mais pesadas que a distribuição normal. Além disso, a distribuição T-student se aproxima da distribuição normal quando seu grau de liberdade é muito grande.

A função densidade de probabilidade da distribuição T-student é dado pela equação 3.1 e a figura 3.1 mostra como o aumento do grau de liberdade aproxima a distribuição T-student da distribuição normal.

$$f(x) = \frac{\Gamma\left(\frac{\nu+1}{2}\right)}{\sqrt{\nu\pi} \Gamma\left(\frac{\nu}{2}\right)} \left(1 + \frac{x^2}{\nu}\right)^{-\frac{\nu+1}{2}} \quad (3.1)$$

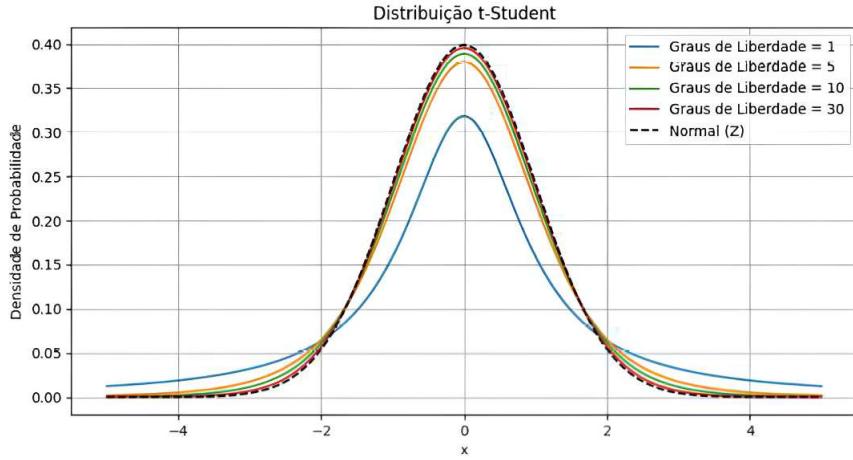


Figura 3.1 – Variação da distribuição T-student conforme o aumento do grau de liberdade.

Na equação 3.1, x é a variável aleatória, v é o número de graus de liberdade, Γ é a função gama.

Felizmente, na prática, essa função não precisa ser utilizada em todas as aplicações, uma vez que já existe a tabela de valores da distribuição T-student.

Além disso, a distribuição T-student já foi utilizada para previsão de vida em equipamentos sujeitos a corrosão (BELONSI et al., 2023), demonstrando assim sua robustez e aplicação na previsão de vida em componentes que sofrem com tal fenômeno de degradação.

Segundo Belonsi et al. (2023), a previsão de vida usando a distribuição T-student é dada por:

$$x_{\min} = \bar{x} - t_{\alpha;gl-1} \cdot \left(\frac{s}{\sqrt{n}} \right) \quad (3.2)$$

$$x(t) = x_{\text{nom}} - \left(\frac{x_{\min} - x_s}{t_{\text{oper}}} \right) \cdot t \quad (3.3)$$

Onde \bar{x} é a média amostral, s é o desvio padrão, n é o número de amostras e $t_{\alpha;gl-1}$ é obtido através da tabela da distribuição T-student, seu valor é de $t_{\alpha;gl-1} = 2,898$, para nível de significância α de 1%. A variável x_{nom} é a espessura nominal da parede do duto, em mm, x_s é a espessura mínima permitida, geralmente equivale a 20% do valor da espessura nominal da parede. Por fim, a vida remanescente, RUL, é calculada fazendo $RUL = t - t_{\text{oper}}$, onde t_{oper} é o tempo de operação do duto.

Sendo assim, para utilizar a distribuição T-student, basta ter, pelo menos, uma inspeção no duto e o conhecimento do ano de início de operação do mesmo. De posse desses valores, basta

seguir a equação 3.3 para estimar a vida remanescente.

3.2 Teoria de valores extremos e método POT

Análise de valores extremos (EVA - *Extreme Value Analysis*) geralmente é usada para prever o progresso da corrosão (YARVEISY; KHAN; ABBASSI, 2022). A teoria dos valores extremos é um ramo da estatística que lida com situações onde os dados são escassos, os chamados acontecimentos raros (ROSÁRIO, 2013). Também é possível usar a teoria de valores extremos na geração de dados sintéticos, no caso de existir a necessidade de mais dados para uma análise mais detalhada (LEMOS et al., 2020). Nessa linha, o método POT consiste em analisar os valores acima de um valor determinado, esse valor se chama limiar ótimo, sendo definido com base no interesse do usuário. Segundo Yarveisy, Khan e Abbassi (2022), o valor limite pode ser o valor que representa o percentil 95%. Uma vez definido o valor limite, os dados acima desse valor são ajustados a uma Distribuição Generalizada de Pareto (GPD) (YARVEISY; KHAN; ABBASSI, 2022). A função distribuição acumulada é dada pela equação 3.4 onde ξ é o parâmetro de forma e β é o parâmetro de escala, também temos o $y_{\text{excedente}}$ que é a diferença entre o cada valor acima do limiar e o valor definido para o limiar ótimo, daí se chamar excedente.

$$G_{\xi,\beta}(y) = 1 - \left(1 + \xi \frac{y_{\text{excedente}}}{\beta}\right)^{-\frac{1}{\xi}} \quad (3.4)$$

Uma vez determinado os valores e a distribuição que melhor se aderem aos excessos, é possível traçar um gráfico que compara o valor dos excessos de um limiar e a GPD. Caso seja necessário, é possível gerar dados sintéticos seguindo essa distribuição de dados.

3.3 Método semi-estocástico para previsão de vida

O método semi-estocástico foi definido por Noor et al. (2009), e estabelece uma relação temporal que leva em conta a incerteza associada a medição feita com o PIG. Associa-se essa incerteza com as fórmulas de previsão da integridade da estrutura presentes na norma DNV-RP-F101. Com isso, a previsão de vida é calculada.

A norma DNV-RP-F101 exibe instruções baseadas na experiência de 4 anos de uso, que foi uma parceria entre *British Gas Technology* e *Det Norske Veritras* (DNV), e também contou com o patrocínio de mais 11 empresas internacionais, incluindo a Petrobras. Essa norma é aplicada em dutos corroídos sujeitos a pressão interna e externa combinadas com tensões de compressão longitudinal (PEREIRA JUNIOR, 2021).

- Essa norma não pode ser aplicada para os seguintes casos:
 - Dutos que não sejam fabricados em aço carbono;
 - Aços com grau superior ao X80;
 - Defeitos não suaves, do tipo trinca;
 - Corrosão combinada com trinca;
 - Defeitos de perda de espessura provocados por danos mecânicos;
 - Defeitos de fabricação em soldas;
 - Defeitos com perda de espessura acima dos 85% da espessura nominal da parede;
 - Materiais em que a temperatura de transição seja acima da temperatura de operação;
 - Defeitos cujo a largura seja maior que o comprimento.

Antes de entrar na parte de formulação da norma, é preciso compreender como os defeitos são analisadas. A figura 3.2 mostra como as dimensões de cada falha são analisados. De maneira geral, independente da geometria, o comprimento da corrosão é o comprimento máximo da falha, e a profundidade é a profundidade máxima da falha detectada pelo PIG.

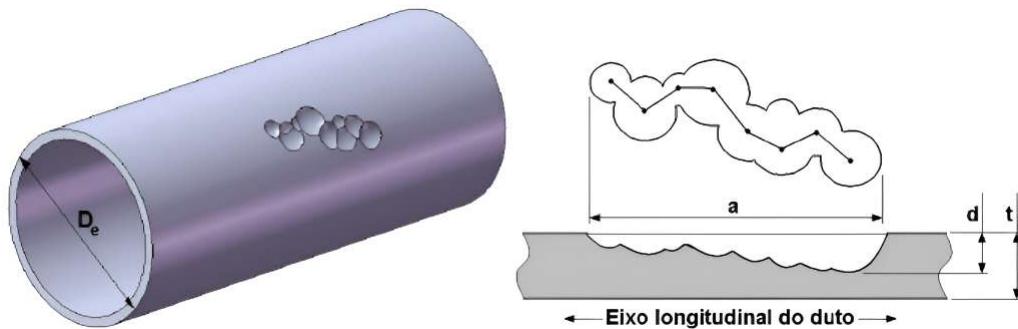


Figura 3.2 – Geometria de falha. Fonte: (PEREIRA JUNIOR, 2021)

Primeiramente, é preciso determinar a pressão máxima admissível para cada falha registrada no PIG. Antes de usar as equações relativas para a definição da pressão máxima tolerável em cada falha, é preciso estimar alguns parâmetros de segurança da norma. Esses parâmetros são escolhidos segundo o fator de segurança que o projeto exige e levando em conta a incerteza de medição presente no PIG. A tabela 3.1 é referente ao tipo de PIG utilizado, a tabela 3.3 define o desvio padrão associado a medida de acurácia do equipamento PIG utilizado e por fim a tabela 3.2 define os parâmetros γ_d e ϵ que serão utilizados na equação 3.7 para determinar o fator (d/t) que aparece na equação 3.5 para determinar a pressão máxima admissível em cada falha.

Tabela 3.1 – Fator de segurança parcial γ_m . Adaptado (NOOR et al., 2009)

	Baixa	Normal	Alta
Relativo (e.g., MFL)	$\gamma_m = 0.79$	$\gamma_m = 0.74$	$\gamma_m = 0.70$
Absoluto (e.g., UT)	$\gamma_m = 0.82$	$\gamma_m = 0.77$	$\gamma_m = 0.72$

Tabela 3.2 – Fator de segurança parcial, γ_d e o fator, ε_d . Adaptado (NOOR et al., 2009)

Fatores			Classes de segurança		
StD[d/t]	comprimento	ε_d	Baixa	Normal	Alta
(exato) 0.00	-	0.0	$\gamma_d = 1.00$	$\gamma_d = 1.00$	$\gamma_d = 1.00$
0.04	-	0.0	$\gamma_d = 1.16$	$\gamma_d = 1.16$	$\gamma_d = 1.16$
0.08	-	1.0	$\gamma_d = 1.20$	$\gamma_d = 1.28$	$\gamma_d = 1.32$
0.16	-	2.0	$\gamma_d = 1.20$	$\gamma_d = 1.38$	$\gamma_d = 1.58$

Tabela 3.3 – Desvio padrão, StD[d/t], para ferramenta de inspeção MFL. Adaptado (NOOR et al., 2009)

Acurácia PIG [mm]	Nível de Confiança 80%	Nível de Confiança 90%
Exato (± 0.0 de t)	$StD[d/t] = 0.00$	$StD[d/t] = 0.00$
± 0.05 de t	$StD[d/t] = 0.04$	$StD[d/t] = 0.03$
± 0.10 de t	$StD[d/t] = 0.08$	$StD[d/t] = 0.06$
± 0.20 de t	$StD[d/t] = 0.16$	$StD[d/t] = 0.12$

A tabela 3.3 depende da incerteza associada a medida do PIG. Essa medida está presente nos relatórios de inspeção. A primeira coluna mostra quantos milímetros de incerteza são referentes para cada tipo de desvio padrão a ser escolhido, t representa a espessura nominal da parede.

Uma vez definido os parâmetros iniciais da norma, basta usar a equação que determina a pressão máxima admissível, que é dada por:

$$P_{mao} = \frac{2 \cdot SMTS_t \cdot \gamma_m \cdot (1 - \gamma_d \cdot d/t^*)}{(D - t) \cdot (1 - \gamma_d) \cdot (d/t^*) \cdot Q^{-1}} \quad (3.5)$$

$$Q = \sqrt{1 + 0,31 \left(\frac{L}{\sqrt{Dt}} \right)^2} \quad (3.6)$$

$$d/t^* = (d/t)_{\text{percent}} + \varepsilon_d \cdot \text{StD}[d/t] \quad (3.7)$$

onde:

- P_{mao} = pressão máxima admissível
- d = profundidade do defeito de corrosão
- t = espessura nominal da parede do tubo
- D = diâmetro externo do tubo
- $SMTS$ = resistência à tração mínima especificada para o material
- γ_m = fator de segurança parcial para o modelo de previsão e classe de segurança
- γ_d = fator de segurança parcial para a profundidade da corrosão
- Q = fator de correção de comprimento
- d/t = Profundidade relativa de corrosão medida
- $(d/t)_{\text{percent}}$ = Razão entre a profundidade de falha e a espessura nominal

Uma vez definido a máxima pressão admissível em cada falha presente no duto, calcula-se o comprimento máximo aceitável, que é determinado pela equação 3.8.

$$L_{\max} = \sqrt{\frac{Q^2 - 1}{0,31}} \cdot \sqrt{Dt} \quad (3.8)$$

Com isso, é possível determinar a pressão máxima de operação e o comprimento máximo aceitável para cada falha, determinando assim se é seguro manter as operações no oleoduto. Porém, segundo Noor et al. (2009), é possível estimar a vida remanescente do duto, usando uma variação no desvio padrão $StD[d/t]$ que varia no tempo. Essa variação no tempo é usada para recalcular os parâmetros γ_d e ϵ . Esse processo temporal se inicia calculando a relação temporal de $StD[d/t]$ utilizando uma taxa de perda de parede linear, e um desvio padrão associado a taxa de perda de parede. Em seguida, através da equação 3.9, pode-se determinar uma variação temporal do desvio padrão $StD[d/t]$, que é comparado com a tabela 3.4 para estimar os novos parâmetros γ_d e ϵ e repetir todo o processo com as equações 3.7 e 3.8.

$$StD[d/t]_{\text{temporal}} = \sqrt{StD[d/t0]^2 + \frac{T^2}{t^2} \cdot StD[cr]^2} \quad (3.9)$$

onde:

- $StD[d/t_0]$ = Desvio Padrão da ferramenta de inspeção no ano inicial
- $StD[d/t]_{\text{temporal}}$ = Desvio padrão temporal, representa o desvio padrão da ferramenta de inspeção no futuro
- $StD[cr]$ = Desvio padrão da taxa de crescimento da corrosão
- T = Período de tempo
- t = Espessura nominal

Tabela 3.4 – Variação Temporal. (NOOR et al., 2009)

Fator de segurança	γ_d e ε_d	Range
Baixo	$\gamma_d = 1.0 + 4.0 StD[d/t]$	$StD[d/t] < 0.04$
	$\gamma_d = 1 + 5.5 StD[d/t] - 37.5 StD[d/t]^2$	$0.04 \leq StD[d/t] < 0.08$
	$\gamma_d = 1.2$	$0.08 \leq StD[d/t] \leq 0.16$
Normal	$\gamma_d = 1 + 4.6 StD[d/t] - 13.9 StD[d/t]^2$	$StD[d/t] \leq 0.16$
Alto	$\gamma_d = 1 + 4.3 StD[d/t] - 4.1 StD[d/t]^2$	$StD[d/t] \leq 0.16$
(Total)	$\varepsilon_d = 0$	$StD[d/t] \leq 0.04$
	$\varepsilon_d = -1.33 + 37.5 StD[d/t] - 104.2 StD[d/t]^2$	$0.04 \leq StD[d/t] \leq 0.16$

O limite de operação é definido quando, a partir dos dados obtidos na inspeção atual, comparados com os dados de comprimento máximo de corrosão e % de perda de parede no tempo futuro forem iguais. Ou seja, a partir da relação temporal, quando o comprimento máximo, obtido pela equação 3.8 for igual ao comprimento da falha atual. O ano em que esses valores forem iguais, então o duto estará operando em regime de falha.

Para facilitar o entendimento deste método, a figura 3.3 exemplifica o processo de previsão utilizando o método semi-estocástico. Essa metodologia utiliza a norma e ferramentas estatísticas para prever o crescimento da corrosão.

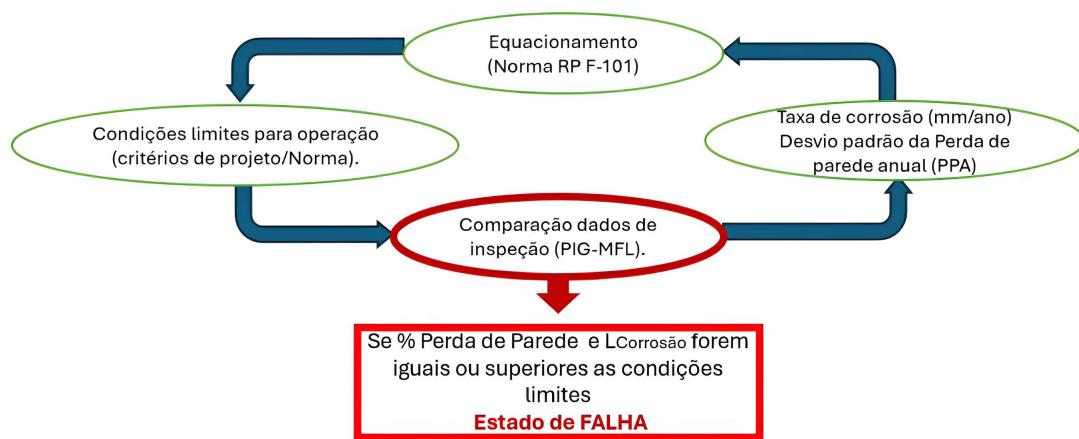


Figura 3.3 – Esquema de previsão de vida via método semi-estocástico

CAPÍTULO IV

CONCEITOS BÁSICOS SOBRE REDES NEURAIS ARTIFICIAIS

Este capítulo visa apresentar alguns conceitos fundamentais sobre redes neurais artificiais, aprendizado de máquina, aprendizado profundo e inteligência artificial. Além disso, os componentes básicos de uma rede neural, como funções de ativação, formas de aprendizado, validação de modelos neurais, séries temporais, também serão abordados neste capítulo.

4.1 Conceito de *Machine Learning* e *Deep Learning*

Segundo Bilal et al. (2016), o mundo está inundado de dados, e com o avanço rápido da tecnologia, essa quantidade de dados aumenta a cada instante. Estima-se que a empresa Google processe mais de 24 petabytes (10^{15} bites) de dados por dia.

Devido a essa grande quantidade de dados, a execução manual de tarefas de abstração tornou-se inviável. Porém, visando atender essa demanda, e aliado ao crescimento tecnológico, houve um incentivo à elaboração de ferramentas automatizadas de análise, conhecidas hoje como aprendizado de máquina (REZENDE et al., 2021).

Aprendizado de máquina (ML- *Machine Learning*) é uma subárea da Inteligência Artificial, voltada para o desenvolvimento de técnicas e algoritmos computacionais, capazes de extraírem características nos mais variados tipos de problemas da atualidade (KOHAVI, 1998).

A inteligência de máquina se tornou possível quando os cientistas deixaram de abordar as tarefas de inteligência de forma procedural e começaram a enfrentá-las empiricamente (MULLAINATHAN; SPIESS, 2017).

De modo geral, os algoritmos de *Machine Learning* são desenvolvidos com base na construção de um modelo de inferência programável, no qual uma previsão é gerada a partir da análise de dados amostrais (MULLAINATHAN; SPIESS, 2017). Por exemplo, os algoritmos de reconhecimento facial, não consistem em regras fixas para procurar determinadas combinações de pixels com base na compreensão humana do que constitui um rosto. Em vez disso, esses algoritmos usam

um grande conjunto de dados de fotos rotuladas como contendo ou não um rosto para estimar uma função $f(x)$ que prevê a presença y de um rosto a partir dos pixels x (MULLAINATHAN; SPIESS, 2017).

Assim, pode-se perceber que, o processo de aprendizado em ML é executado de forma indutiva, onde padrões de resposta são definidos automaticamente, por meio de experiências já observadas pelo modelo (KOHAVI, 1998). Logo, a principal aplicação para essas ferramentas é em problemas irregulares, nos quais uma relação matemática não é facilmente observada.

Nesse cenário, as redes neurais artificiais (RNAs) têm se destacado como uma das principais técnicas de *Machine Learning*. Essa técnica tem sido amplamente aplicada para determinar a previsão de vida de máquinas que sofrem com corrosão ((SHAIK; PEDAPATI; DZUBIR, 2022), (BELONSI et al., 2023), (KAHRAMAN et al., 2024)). A eficiência das RNAs está na forma como o processamento dos dados é executado, onde as operações aplicadas se aproximam daquelas realizadas pelo cérebro humano (REZENDE et al., 2021).

Outras abordagens de *Machine Learning* costumam usar blocos lógicos, como por exemplo a floresta randômica e a *support vector machine*, no seu processo de aprendizagem. Já as RNAs operam sobre uma rede paralela de nós. Esses nós têm a função de processar localmente as informações extraídas e, em seguida, por meio de um algoritmo de treinamento, ajustam suas respostas para alcançar a melhor solução (REZENDE et al., 2021).

Em termos de topologia, segundo Fleck et al. (2016), primeiro deve-se determinar o número de nós na camada de entrada. Esses nós de entrada serão usados para alimentar o modelo. Em seguida, determinar o número de camadas ocultas e a quantidade de nós em cada camada oculta, e, finalmente, a quantidade de neurônios de saída.

Vale ressaltar que uma das principais dificuldades no uso de redes neurais é determinar a arquitetura mais adequada para cada problema, pois esse processo é experimental e exige um tempo significativo de execução. Na prática, é necessário testar diversos métodos de aprendizado e diferentes configurações da rede para encontrar a melhor solução para um problema específico (FLECK et al., 2016).

Ademais, quando uma RNA é composta de três ou mais camadas de processamento, ela passa a ser classificada como uma rede neural profunda. Com isso, sua aplicação passa a ser de aprendizado profundo (DL - *Deep Learning*) (YU et al., 2015).

A fim de facilitar a interpretação, a figura 4.1 mostra como os temas DL, ML e IA se misturam.

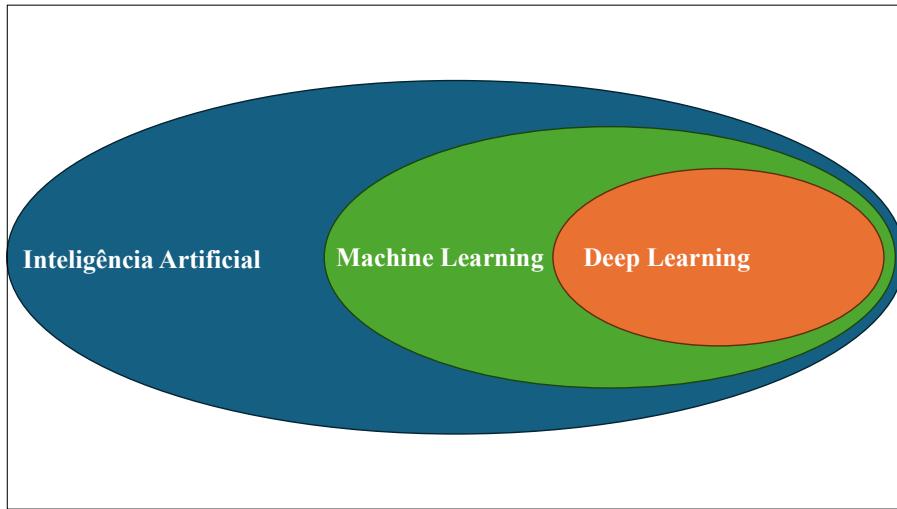


Figura 4.1 – Relação entre ML, DL e Inteligência Artificial, adaptado de Rezende et al. (2021)

4.1.1 *Algumas Aplicações*

Conforme abordado anteriormente, algoritmos de *Machine Learning* foram desenvolvidos para resolver problemas complexos, que a princípio são impossíveis de serem solucionados por algoritmos sequenciais ou métodos manuais.

Segundo Haykin (2001), a rede neural se assemelha ao cérebro humano em dois aspectos básicos: o conhecimento a ser adquirido pela rede a partir do ambiente, através dos processos de aprendizagem e as forças de conexão entre os neurônios.

No contexto de DL, as tarefas realizadas pelo modelo vão bem longe. Dentre as principais tarefas comumente aplicadas, pode-se citar:

- **Classificação:** A IA é treinada, geralmente com treinamento supervisionado, para determinar a qual grupo um elemento pertence. Fazendo assim a classificação das amostras.
- **Regressão:** Neste caso, existe uma relação de dependência entre a entrada e a saída do modelo. A regressão é usada neste trabalho juntamente com séries temporais. Na regressão, os dados de entrada, x, são correlacionados com os dados de saída, y.
- **Detecção de Anomalias:** Um conjunto de eventos é avaliado para que a correlação entre determinadas entradas configurem uma anomalia.

Como mencionado anteriormente, no presente trabalho, foi utilizado a regressão para detecção da vida remanescente em dutos submarinos. A regressão foi aliada a séries temporais, para manter a relação temporal do fenômeno de corrosão.

4.2 Redes Neurais Artificiais

As redes neurais artificiais (RNAs) são modelos computacionais, inspirados na estrutura da transmissão nervosa entre neurônios biológicos, que têm a capacidade de aprender através da observação repetida de dados históricos (GOODFELLOW, 2016). Claro que, os modelos computacionais são mais simples e restritos quando comparados a real arquitetura do sistema nervoso humano.

O modelo de neurônio artificial mais antigo e amplamente aceito foi proposto por Warren McCulloch e Walter Pitts em um artigo de 1943. Nesse trabalho, os autores definiram o neurônio artificial como um sistema binário, projetado para auxiliar na solução de diversos problemas relacionados a circuitos elétricos (JIANG et al., 2017; MCCULLOCH; PITTS, 1943).

O modelo MP Neuron, também conhecido como Discriminador Linear, conforme nomeado por McCulloch e Pitts, opera de maneira simples ao combinar todas as entradas binárias de dados. Com base no valor resultante dessa combinação, uma decisão é tomada por meio de uma função de transferência (MOURA JÚNIOR et al., 2008).

A saída do neurônio artificial depende da ativação ou não da função de transferência. Essa ativação depende do valor do limiar δ estabelecido previamente (HAYKIN, 2001). A figura 4.2 representa o modelo de Warren McCulloch e Walter Pitts de 1943.

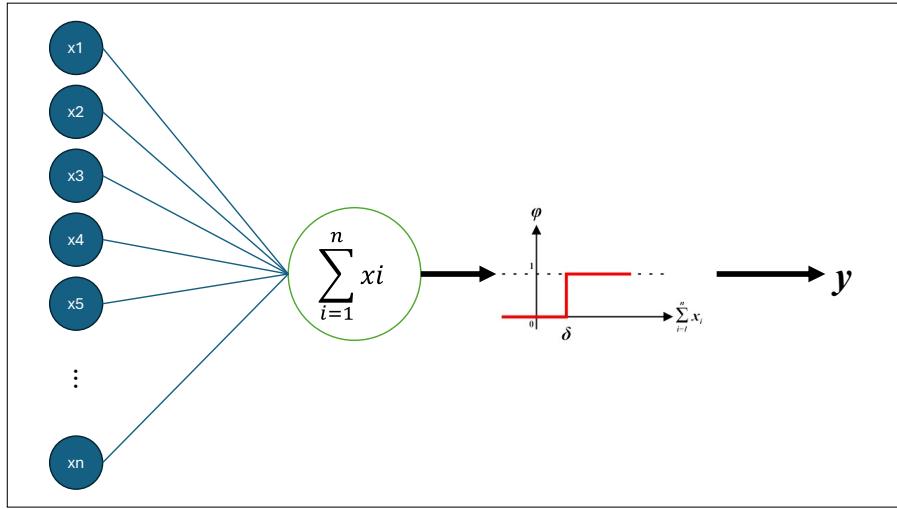


Figura 4.2 – Representação simples de um neurônio, adaptado de Rezende et al. (2021)

Pela análise da figura anterior, pode-se notar que para esse modelo a função de ativação é do tipo degrau unitário.

Após o modelo de Warren McCulloch e Walter, veio aquele que foi o modelo utilizado neste trabalho, sendo chamado de *Perceptron*. Esse modelo foi descrito pela primeira vez em 1958 por Frank Rosenblatt (ROSENBLATT, 1958).

O Perceptron foi a primeira Rede Neural Artificial a ser estruturada em camadas. Essa organização teve um impacto significativo na comunidade científica, sendo vista como uma evolução do modelo MP Neuron(ROSENBLATT, 1958).

As unidades de processamento do modelo Perceptron, chamadas de *Linear Threshold Units* (LTU), desempenham funções similares às do modelo MP Neuron. No entanto, elas introduzem pesos de ponderação (w_i) em cada conexão de entrada da rede, além de incluir um valor escalar (b), conhecido como bias, que ajusta a saída do modelo (HAYKIN, 2001). A relação dos pesos de ponderação (w_i) e o valor de bias (b) podem ser vistas na equação 4.1 e o modelo do perceptron pode ser visto na figura 4.3.

$$y_i = \phi \left(\sum_{i=1}^n (x_i w_i + b) \right) \quad (4.1)$$

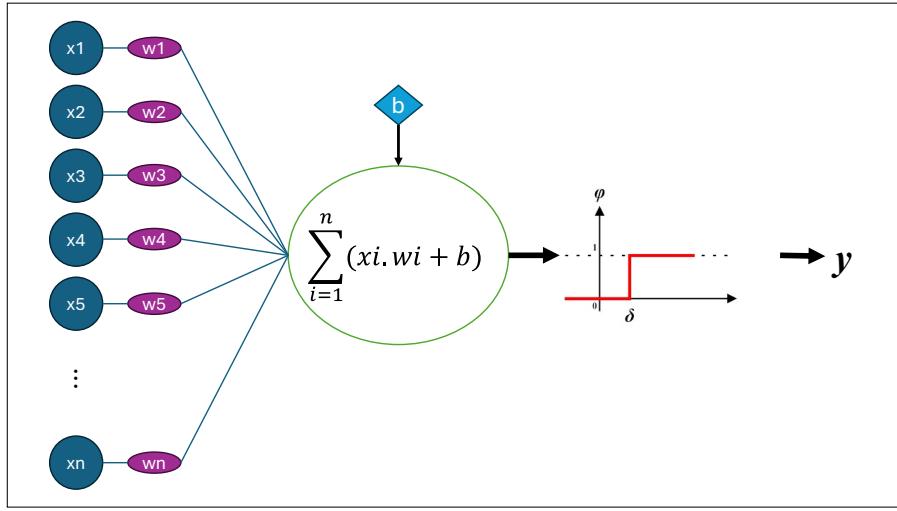


Figura 4.3 – Representação de um perceptron, adaptado de Rezende et al. (2021)

O bias deve ser ajustado de forma a calibrar a resposta da função de transferência, garantindo que os resultados obtidos estejam alinhados com o esperado. Por outro lado, os pesos de ponderação, também chamados de pesos sinápticos, são inicialmente atribuídos de maneira aleatória e, ao longo do treinamento da rede neural, passam por atualizações para melhorar o desempenho do modelo.

A rede Multilayer Perceptron (MLP) representa um avanço significativo em relação ao modelo Perceptron, sendo a primeira arquitetura de rede neural generalizada para múltiplas camadas de neurônios. Essa estrutura é composta por várias unidades menores de processamento, conhecidas como Perceptrons, que são organizadas em camadas e distribuídas em paralelo. A figura 4.4 mostra um exemplo dessa arquitetura.

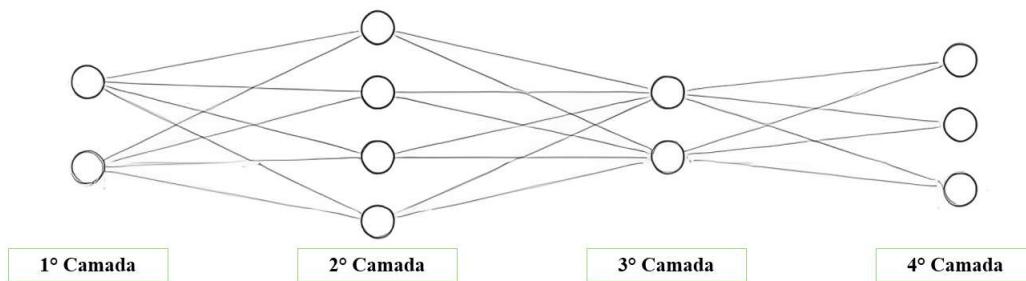


Figura 4.4 – Representação esquemática de um modelo MLP

A capacidade de integrar múltiplas unidades de processamento em um único sistema complexo, apresentada pelo modelo de rede *Multilayer Perceptron*, impulsionou diversas pesquisas e

avanços no campo das redes neurais artificiais (HAYKIN, 2001).

O MLP possui características que permitem resolver problemas não-lineares, superando a limitação do Perceptron de camada única. O desenvolvimento do MLP foi possível devido a inovações em algoritmos de treinamento, especialmente o *backpropagation*, que permite o ajuste eficiente dos pesos sinápticos através de múltiplas camadas. Os algoritmos de treinamento serão explicados na próxima seção deste trabalho.

4.2.1 Funções de ativação

A função de ativação é basicamente uma transformação aplicada à soma total das entradas de dados (NWANKPA et al., 2018).

Quando se empregam funções de ativação estritamente lineares, o processamento da informação se resume a um problema de regressão linear. No entanto, embora esses modelos apresentem limitações específicas, a maioria deles possui soluções simples, dispensando a necessidade de técnicas de modelagem neural (HAYKIN, 2001). Contudo, ao se utilizar funções de ativação não lineares, uma grande variedade de tarefas complexas pode ser resolvida utilizando RNAs (HAYKIN, 2001).

Entre as principais funções de ativação descritas na literatura, destacam-se: a função Degrau Unitário, a função Degrau Bipolar, a função Linear, a função *Sigmoidal*, a função Tangente Hiperbólica (Tanh), a função *Softmax*, a Unidade Linear Retificada (ReLU), a Unidade Linear Exponencial (ELU) e a Unidade Linear com Vazamento (Leaky ReLU). Todas as funções citadas e suas derivadas estão presentes na tabela 4.1 onde $u = \sum_{i=1}^n (x_i w_i + b)$ e δ é o valor do limiar de ativação.

4.2.2 Formas de Aprendizagem

Devido a sua capacidade de generalização, as RNAs se mostram uma ferramenta poderosa na resolução de problemas complexos (YU et al., 2015). Essa capacidade de generalização é obtida por meio do processo iterativo, onde, por meio de um algoritmo de treinamento, os parâmetros do modelo neural são otimizados afim de obter a melhor aproximação possível (RUMELHART; HINTON; WILLIAMS, 1986). Segundo Xue, Yang e Haykin (2007), em problemas de regressão e classificação, o ajuste dos parâmetros de uma RNA é realizado utilizando um algoritmo de retropropagação de erros, chamado de *backpropagation* (XUE; YANG; HAYKIN, 2007). Esse algoritmo tem por finalidade verificar o nível de desempenho da rede neural e, caso o nível esteja baixo, o mesmo ajustará seus parâmetros locais (pesos e baias), a fim de melhorar a assertividade do modelo (HAFEMANN, 2014).

O *backpropagation* ocorre em duas etapas (RUMELHART; HINTON; WILLIAMS, 1986).

Nome da Função	Formulação Matemática	Derivada
Linear	$\phi(u) = au$	$\phi'(u) = a$
Degrau Unitário	$\phi(u) = \begin{cases} 1, & \text{se } u \geq \delta \\ 0, & \text{se } u < \delta \end{cases}$	$\phi'(u) = 0$
Degrau Bipolar	$\phi(u) = \begin{cases} 1, & \text{se } u \geq \delta \\ -1, & \text{se } u < \delta \end{cases}$	$\phi'(u) = 0$
Sigmoidal	$\phi(u) = \frac{1}{1+e^{-u}}$	$\phi'(u) = \phi(u)(1 - \phi(u))$
TanH	$\phi(u) = \tanh(u)$	$\phi'(u) = 1 - \tanh^2(u)$
Softmax	$\phi(u) = \frac{e^u}{\sum_{k=1}^n e^{u_k}}$	diferentes para $i = k$ e $i \neq k$
ReLU	$\phi(u) = \max(0, u)$	$\phi'(u) = \begin{cases} 1, & \text{se } u \geq 0 \\ 0, & \text{se } u < 0 \end{cases}$
ELU	$\phi(u, \alpha) = \begin{cases} u, & \text{se } u \geq 0 \\ \alpha(e^u - 1), & \text{se } u < 0 \end{cases}$	$\phi'(u, \alpha) = \begin{cases} 1, & \text{se } u \geq 0 \\ \phi(u, \alpha) + \alpha, & \text{se } u < 0 \end{cases}$
Leaky ReLu	$\phi(u, \alpha) = \max(\alpha u, u)$	$\phi'(u, \alpha) = \begin{cases} 1, & \text{se } u \geq 0 \\ \alpha, & \text{se } u < 0 \end{cases}$

Tabela 4.1 – Principais funções de ativação utilizadas em redes neurais artificiais. Adaptado Rezende et al. (2021)

O primeiro estágio é chamado de *forward*, o sinal de entrada é propagado por toda a extensão da rede neural, passando por todas as camadas, até a saída (XUE; YANG; HAYKIN, 2007). Após a fase *forward*, a resposta do modelo neural é comparado com um padrão esperado, com uma função de perda sendo definida no final do processo (RUMELHART; HINTON; WILLIAMS, 1986). As principais funções de perda podem ser vistas na tabela 4.2.

Nome da Função de Perda	Formulação Matemática
RMSE	$L(y, t) = \frac{1}{2k} \sum_{i=1}^k \sqrt{(t_i - y_i)^2}$
Erro Médio Absoluto (MAE)	$L(y, t) = \frac{1}{2k} \sum_{i=1}^k t_i - y_i $
Crossentropy	$L(y, t) = - \sum_{i=1}^k (t_i \cdot \ln(y_i) + (1 - t_i) \cdot \ln(1 - y_i))$

Tabela 4.2 – Principais funções de perda utilizadas no treinamento de redes neurais artificiais.

Após o cálculo da função de erro, o algoritmo executa uma medida de desempenho global seguindo a equação 4.2.

$$E_j(w, b|x, t) = \frac{1}{n} \sum_{i=1}^n L(\phi(w_i x_i + b), t) \quad (4.2)$$

onde n representa a quantidade de neurônios na última camada, ϕ a função de ativação utilizada nesses neurônios, L a função de perda avaliada e E o erro mensurado para uma dada interação j do algoritmo de treinamento.

O propósito do processo de treinamento é permitir que a rede neural aprenda a partir dos dados, minimizando a diferença entre o valor previsto pelo modelo e o resultado esperado. Assim, treinar uma rede neural, com o algoritmo de *backpropagation*, consiste em encontrar parâmetros w e b que minimizem sua função de erro global (BUSCEMA, 1998).

CAPÍTULO V

METODOLOGIA HÍBRIDA PARA PREVISÃO DE VIDA DE SISTEMAS QUE SOFREM COM CORROSÃO

Este capítulo apresenta a metodologia proposta por esse trabalho que busca utilizar fundamentos da estatística para geração de dados sintéticos afim de treinar um modelo de IA para realizar a previsão de vida remanescente de dutos rígidos. A necessidade de dados sintéticos se deve em virtude da falta de um histórico de campanhas rico em informações do processo de degradação do ativo para o treinamento de uma rede neural. Então, até a construção desse banco de dados, a utilização de dados sintéticos se torna indispensável.

Primeiramente será apresentado as etapas da metodologia proposta. Em seguida, será feita a previsão da vida utilizando os dados de inspeção de um duto submarino. Por fim, a previsão de vida obtida será comparada com o resultado obtido pelo método estatístico, usando a distribuição T-student, e o método semi-estocástico.

A figura 5.1 representa as etapas da metodologia híbrida

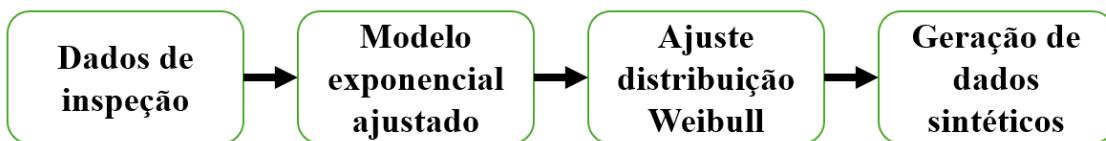


Figura 5.1 – Representação das etapas da metodologia híbrida

5.1 Exibição dos dados de inspeção

O equipamento em análise é um oleoduto de 6 Km. Ele possui várias espessuras de parede distintas, então, para essa análise será escolhido o maior trecho, com 20,6 mm de espessura nominal de comprimento igual a 5,86 Km.

Os dados de inspeção foram obtidos pelo ensaio não destrutivo via PIG MFL, sendo feitas 4 inspeções, 2013, 2016, 2021 e 2024. A profundidade de perda de parede e a posição das mesmas podem ser vistas nas figuras 5.2 até 5.5. Em cada uma das figuras, o eixo X é a posição da falha no duto e o eixo Y é a profundidade de corrosão.

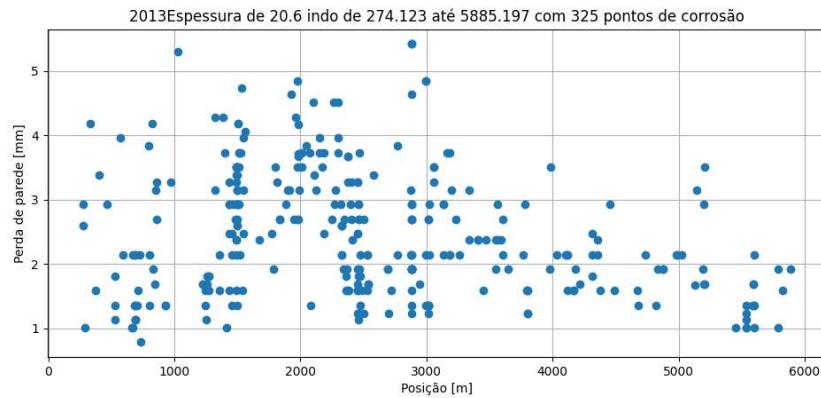


Figura 5.2 – Inspeção 2013

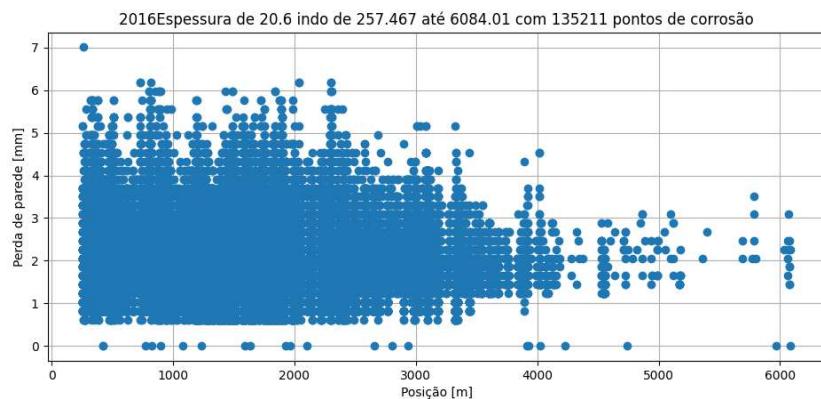


Figura 5.3 – Inspeção 2016

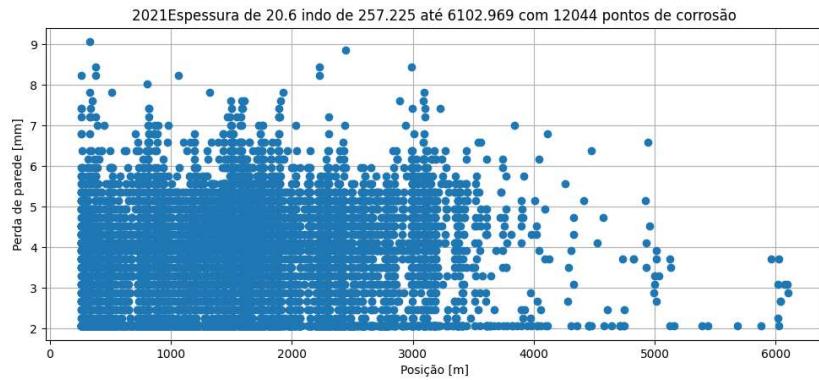


Figura 5.4 – Inspeção 2021

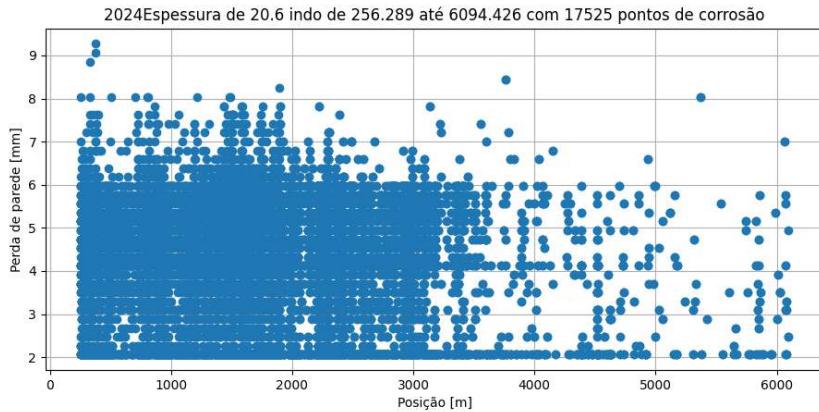


Figura 5.5 – Inspeção 2024

Foram registrados 325 pontos de corrosão em 2013, 135211 pontos de corrosão em 2016, 12044 pontos de corrosão em 2021 e 17525 pontos de corrosão em 2024. Afim de melhorar a visualização, os pontos de perda de parede foram organizados usando o diagrama de blocos.

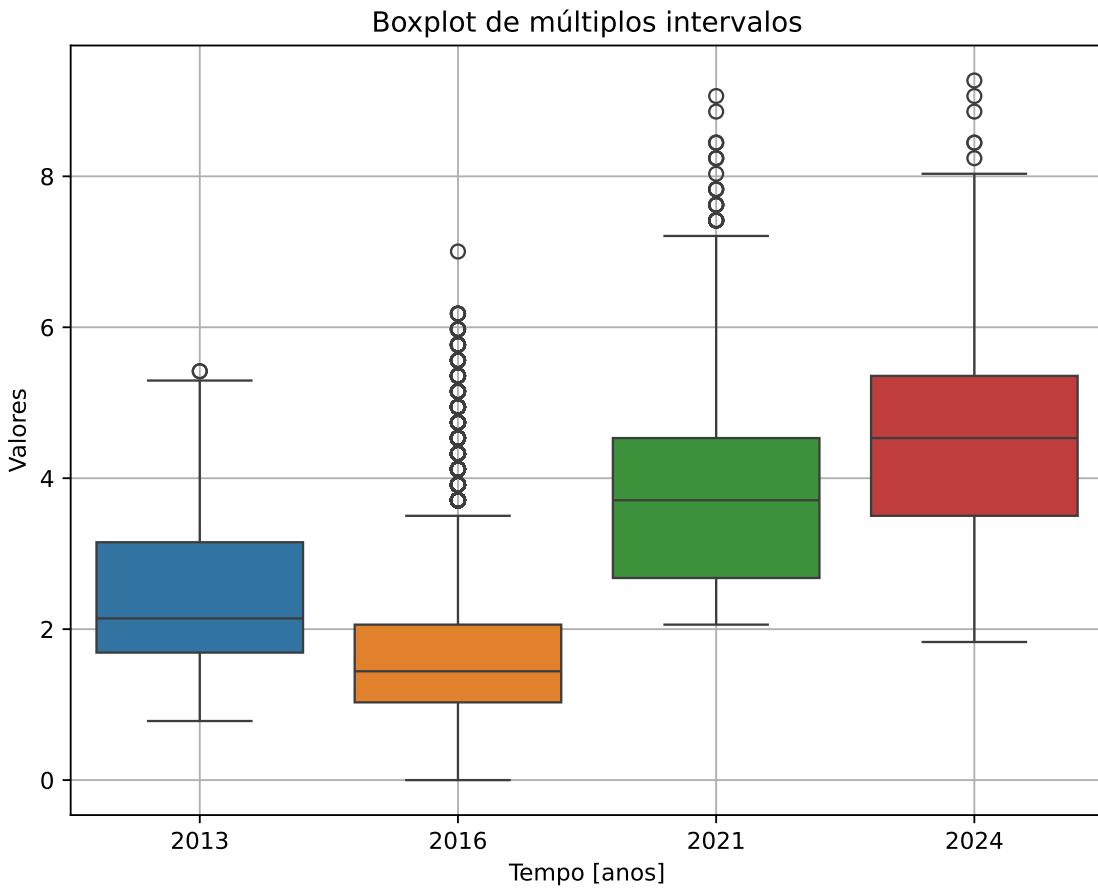


Figura 5.6 – Diagrama de blocos dos pontos de corrosão.

Na figura 5.6, o eixo vertical é a profundidade de perda de parede. Cada bloco representa os pontos de corrosão registrados em cada inspeção. Como fica claro nesta figura existe um crescimento da profundidade de corrosão. Além disso, como visto nos gráficos das figuras 5.2, 5.3, 5.4 e 5.5 boa parte das falhas se encontram nos primeiros quilômetros do trecho.

5.2 Geração dos dados sintéticos

Como discriminado na seção anterior, foram realizadas 4 inspeções no ativo escolhido para o estudo de caso deste trabalho. Claro que com apenas 4 pontos no tempo, não é possível treinar uma rede neural. Neste contexto, em função da escassez de informações foram gerados dados sintéticos que representam o crescimento da profundidade de corrosão em função do tempo, e que serão utilizados para treinar e testar um modelo de rede neural artificial. Por isso, as inspeções de 2013 até 2021 foram separadas para gerar tais dados sintéticos, enquanto que a campanha de 2024 foi separada para servir de validação do modelo de IA.

Para gerar os dados sintéticos, foi utilizado a biblioteca do *Python*, *scipy*. Essa biblioteca realiza testes de aderência, usando funções de distribuição de probabilidade acumulada (PDF) e o método da máxima verossimilhança (MLE - *Maximum likelihood estimation*), os parâmetros de forma, escala e localização da distribuição Weibull que melhor se aderem aos dados disponíveis de inspeção PIG. Contudo, como no caso em análise, são apenas 3 pontos de inspeção que serão usados para gerar os dados sintéticos, e com apenas 3 pontos a biblioteca retorna uma mensagem de alerta, devido a baixa quantidade de pontos, foi identificado que o mínimo necessário seriam 10 pontos.

Portanto, visando gerar mais pontos para o teste de máxima verossimilhança, foi utilizado uma função exponencial ajustada a média da perda de parede. Segundo Bazán e Beck (2013), a função exponencial segue a tendência de crescimento da profundidade de corrosão de inúmeros ativos industriais que sofrem com esse fenômeno. Sendo assim, é usado uma função exponencial para gerar 10 pontos adicionais para o teste de máxima verossimilhança.

5.2.1 *Modelo exponencial ajustado*

Segundo Bazán e Beck (2013), a corrosão pode ser representada por uma lei de potência dada pela seguinte equação:

$$D_{\max}(t) = k(t - t_0)^a \quad (5.1)$$

Onde t_0 é o ano de comissionamento do duto, t é o ano da inspeção, a é o expoente da lei de potência e k fator de proporcionalidade. Os fatores a e k são definidos a partir de um ajuste com os dados de inspeção. Bazán e Beck (2013) utiliza a perda média da perda de espessura do registro dos dados de inspeção.

Para aplicar essa ideia, o duto foi dividido em trechos de 250 metros cada com o objetivo de determinar a vida remanescente e a posição da possível falha no futuro. A figura 5.7 demonstra como são as etapas de previsão propostas aqui para cada seção do duto.

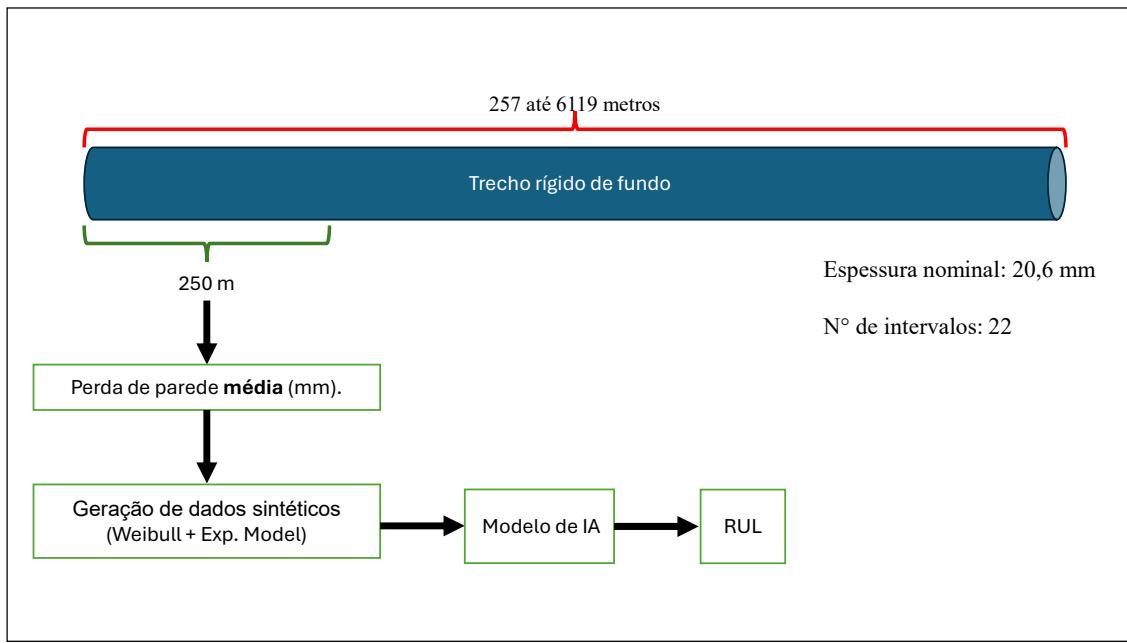


Figura 5.7 – Diagrama de divisão das secções dos intervalos do duto.

A partir da divisão dos dados de inspeção em intervalos de 250 metros, é possível determinar a perda de parede média em cada um dos trechos. A figura 5.8 representa as perdas médias de parede em cada intervalo.

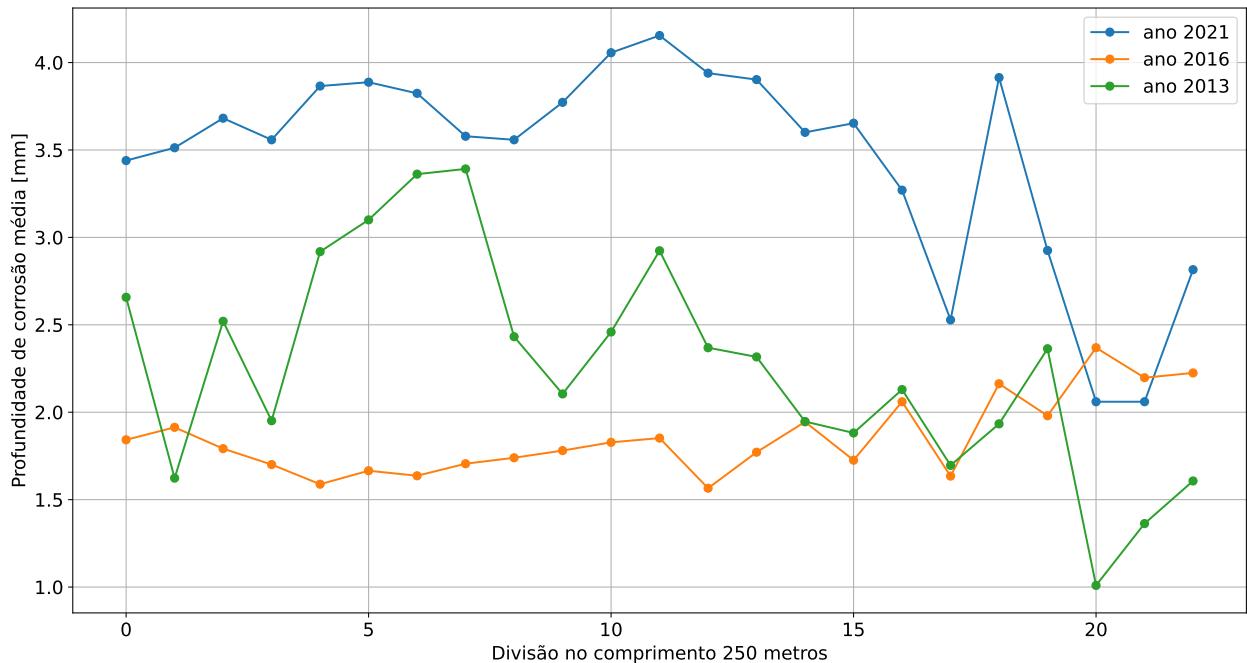


Figura 5.8 – Perda de parede média em cada intervalo de 250 metros.

Como fica claro na figura 5.8, a campanha de 2016 apresenta perdas médias superiores ao ano de 2021. Isso ocorre devido à incerteza associada aos aparelhos de inspeção de dutos. Diante disso, os dados de inspeção da campanha de 2016 não foram considerados no procedimento de geração dos dados sintéticos. A tabela 5.1 mostra as perdas médias de parede nos primeiros 15 intervalos de 250 metros.

Intervalo Ano	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
2013	2,66	1,62	2,52	1,95	2,92	3,1	3,36	3,39	2,43	2,10	2,46	2,92	2,37	2,32	1,95
2021	3,44	3,51	3,68	3,56	3,87	3,89	3,82	3,58	3,56	3,77	4,06	4,15	3,94	3,90	3,60

Tabela 5.1 – Tabela com a perda de parede média em milímetros dos intervalos 1 ao 15.

Uma vez definido as inspeções que serão utilizadas para geração dos dados sintéticos, o ajuste da curva exponencial é então realizado. A título de ilustração, a figura 5.9 mostra a curva ajustada para o primeiro intervalo de inspeção.

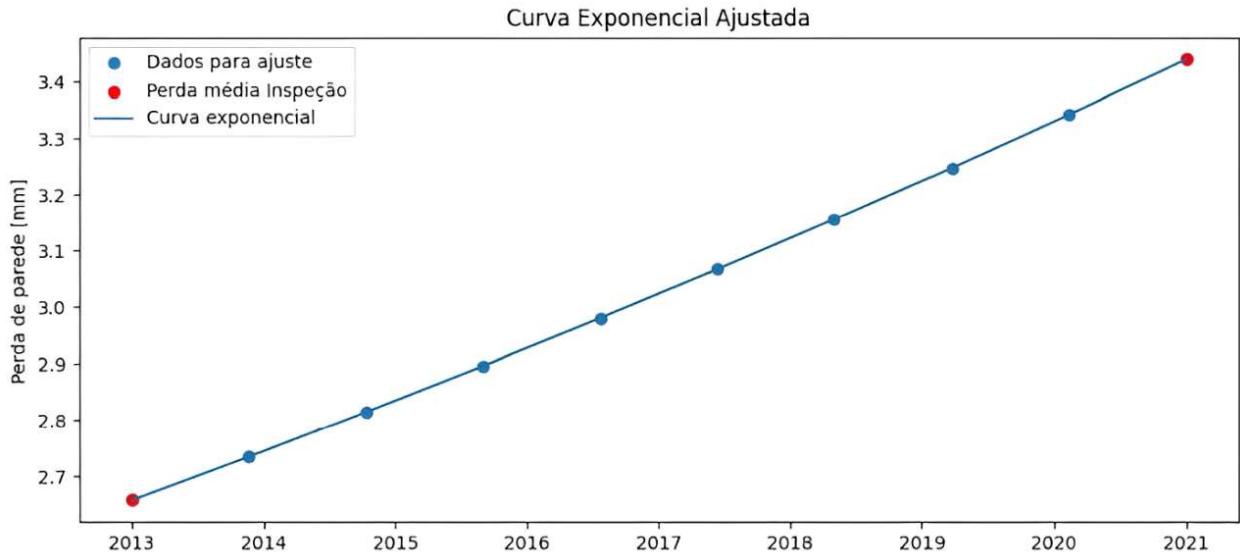


Figura 5.9 – Perda média de parede nos primeiros 250 metros.

5.2.2 Ajuste da distribuição Weibull

Segundo Osarumwense e Rose (2014), a distribuição de Weibull é vista atualmente como a melhor distribuição dentre a família das distribuições de falha (Exponencial, Rayleigh, Lognormal, Normal etc). Ela possui melhor ajuste a dados de vida, em função do parâmetro de forma presente na distribuição (OSARUMWENSE; ROSE, 2014). Além disso, essa distribuição é muito utilizada

em previsão de falhas, justificando o seu uso neste trabalho para tratar os dados de corrosão de dutos submarinos em operação que sofrem com corrosão. Por fim, vale salientar que essa distribuição apresenta uma boa acurácia mesmo para poucas amostras (OSARUMWENSE; ROSE, 2014).

A distribuição Weibull é uma distribuição contínua com uma função densidade de probabilidade da seguinte forma:

$$f(x) = \left(\frac{\beta}{\eta}\right) \cdot \left(\frac{x-\gamma}{\eta}\right)^{\beta-1} e^{-\left(\frac{x-\gamma}{\eta}\right)^\beta} \quad \beta > 0, \eta > 0, \gamma > 0 \quad (5.2)$$

Onde β , η e γ são, respectivamente, os parâmetros de forma, escala e localização da distribuição de Weibull. Caso γ seja igual a zero, a distribuição Weibull fica definida por 5.3.

$$f(x) = \left(\frac{\beta \cdot x^{\beta-1}}{\eta^\beta}\right) e^{-\left(\frac{x}{\eta}\right)^\beta} \quad \beta > 0, \eta > 0, \quad (5.3)$$

A variação do parâmetro de forma é que torna essa distribuição de probabilidade tão útil. Nas imagens a seguir, fica evidente como ela se comporta quando se varia o parâmetro de escala, figura 5.10, e quando o parâmetro de forma é variado, visto na figura 5.11, mantendo o parâmetro de localização igual a zero.

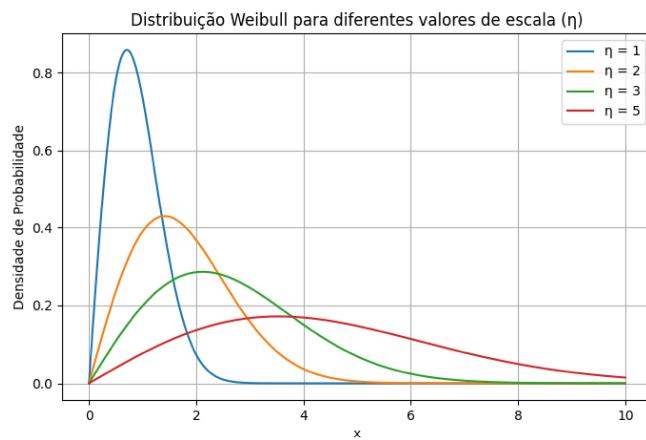


Figura 5.10 – Distribuição de Weibull variando parâmetro de escala.

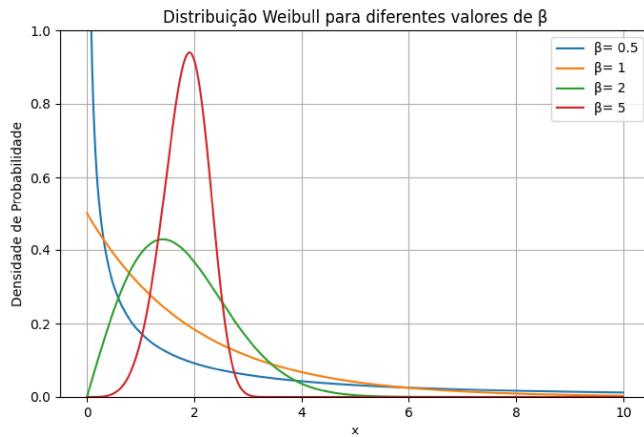


Figura 5.11 – Distribuição de Weibull variando parâmetro de forma.

Com isso, utilizando os dados extras provenientes das curvas exponenciais, os dados serão agora ajustados a uma distribuição de probabilidade de Weibull por meio do método de máxima verossimilhança. Ao ter 10 pontos a biblioteca stats do Python pode determinar os parâmetros da distribuição Weibull que melhor se aderem aos novos dados. Esse processo será executado para todos os intervalos do duto, e este é o último passo para a geração dos dados sintéticos.

A figura 5.12 mostra o histograma com os dados utilizados na geração dos dados teóricos, no primeiro intervalo, comparado com a curva teórica da distribuição de probabilidade Weibull que melhor se ajusta aos dados.

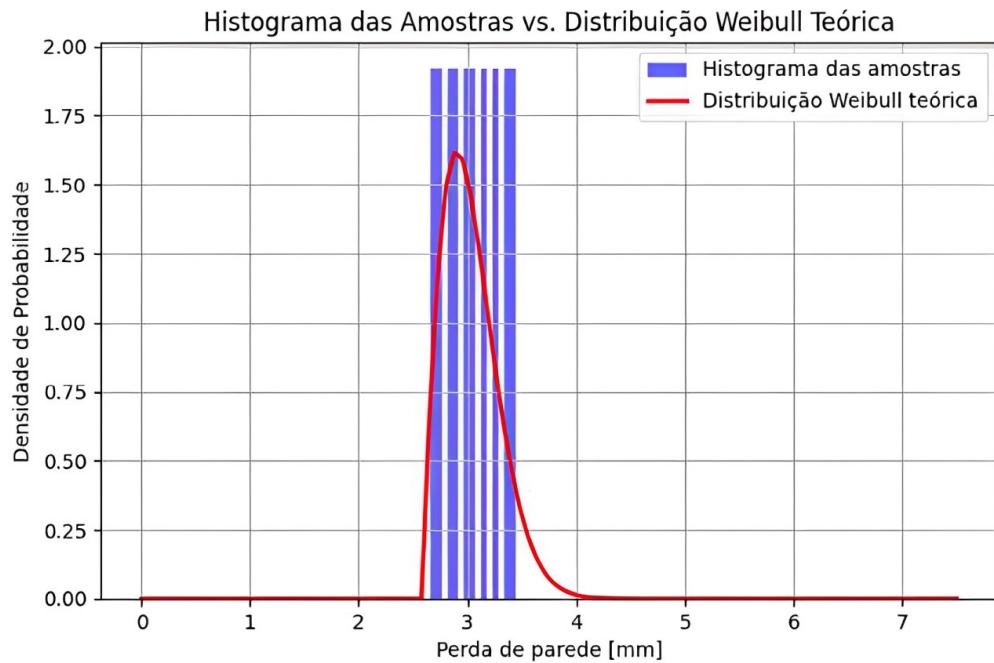


Figura 5.12 – Comparação curva ajustada aos dados.

Uma vez definido os parâmetros da distribuição Weibull que melhor se aderem aos dados de inspeção, chega-se na etapa de definição de quantos dados serão gerados. Por necessitarem de uma relação temporal, fica a critério usar como medida de tempo anos, meses, dias ou até mesmo horas, lembrando que a escolha do passo de tempo depende da quantidade de inspeções disponíveis e o espaçamento entre elas. Por exemplo, no caso em análise, são utilizadas duas inspeções separadas por 8 anos de distância. A tabela 5.2 mostra quantos dados são gerados para cada unidade de tempo adotada.

Unidade de tempo	Quantidade de dados sintéticos
Horas	70080
Dias	2920
Semanas	384
Meses	96
Anos	8

Tabela 5.2 – Determinação da unidade de tempo.

Foram considerados dias de 24 horas, anos com 365 dias e meses com 4 semanas para a determinação da quantidade de dados. E como fica claro na tabela 5.2, ao utilizar semanas, meses e anos para geração dos dados sintéticos, os dados gerados ainda não são suficientes para realizar o treinamento de uma rede neural artificial. Contudo, ao utilizar dias e horas a quantidade de dados se torna satisfatória. Afim de evitar um gasto computacional elevado, foi adotado como passo de tempo o valor de dias.

Portanto foram gerados 2920 dados sintéticos para cada intervalo. A figura 5.13 mostra os dados sintéticos comparados com a curva teórica do intervalo 1.

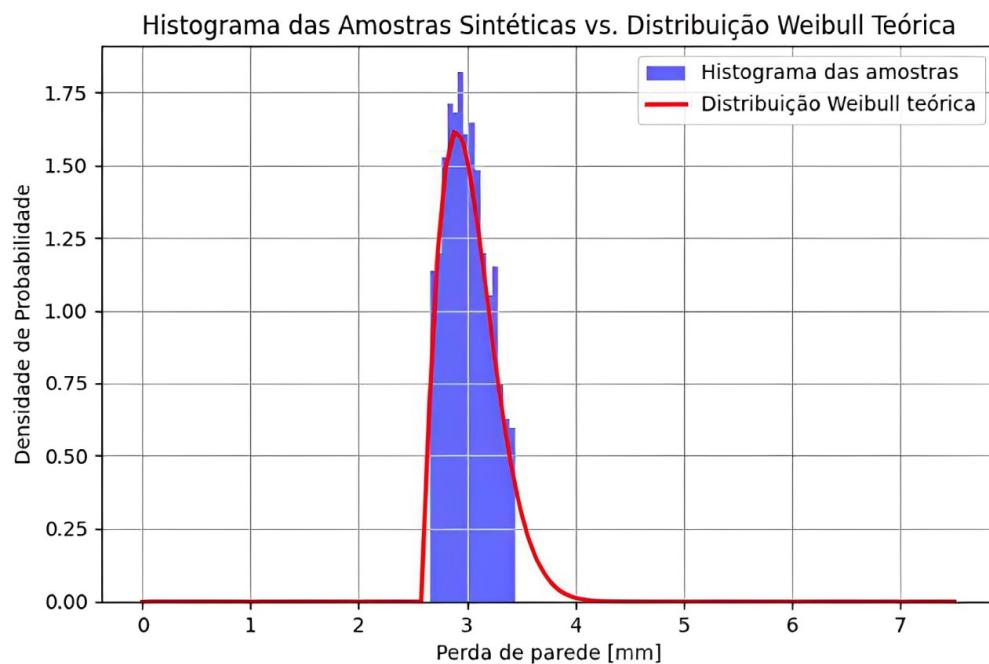


Figura 5.13 – Comparaçāo dados sintéticos e curva ajustada aos dados.

5.3 Treinamento da rede MLP

Uma vez gerado os dados sintéticos, passa-se para a etapa de montagem e treinamento da rede MLP que irá efetuar a previsão de vida remanescente do duto submarino objeto de estudo desse trabalho.

5.3.1 Normalização dos dados

Essa etapa é importante, pois os dados sintéticos precisam estar normalizados entre 0 e 1 a fim de aumentar a estabilidade da rede. Nesse trabalho, a normalização é feita da seguinte forma:

$$X_{\text{norm}} = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (5.4)$$

Onde:

- X - Valor original do dado.
- X_{\min} - Menor valor do conjunto de dados.
- X_{\max} - Maior valor do conjunto de dados.
- X_{norm} - Valor normalizado no intervalo $[0, 1]$.

O intuito da normalização é transformar todos os dados sintéticos em valores que estão entre 0 e 1. Os valores máximo e mínimo do conjunto de dados são separados para a posterior desnormalização que é feita usando a mesma equação.

Vale ressaltar que a rede irá prever a vida remanescente em cada intervalo do duto, logo, a normalização deverá ser feita para os dados sintéticos de cada intervalo. Todo o processo deverá ser repetido para outro intervalo, onde os valores máximos e mínimos serão distintos dos demais intervalos.

A forma de previsão do modelo será a previsão de séries temporais, utilizando o modelo de passo único. Ou seja, a entrada da rede é a informação no tempo atual e a saída da rede será o valor no tempo futuro, sendo assim uma entrada e uma saída.

5.4 Construção e treinamento da rede MLP

A rede MLP foi montada utilizando a linguagem de programação *Python* e a biblioteca *Tensorflow*.

O *Tensorflow* é uma biblioteca de código aberto, escrita em *Python*, que foi lançada em 2015 pela *Google Brain Research Group* para estudos de *machine learning* e redes neurais profundas (RAMPASEK; GOLDENBERG, 2016). Ele é executável em uma ou mais unidades de CPUs, o que aumenta a sua gama de aplicação (REZENDE et al., 2021).

Afim de determinar a melhor arquitetura MLP para o problema em questão, inicialmente deve se determinar as dimensões dos dados de entrada e saída da rede. Por se tratar de um fenômeno

dependente do tempo, e o envolvimento de séries temporais, a entrada da rede é apenas um valor, que representa a perda de parede no dia atual. E como saída, a previsão da perda de parede no dia seguinte.

Dessa forma tem-se uma análise unidimensional. A rede será formada por uma camada de entrada, uma segunda camada densa oculta, formada por 80 neurônios, com função de ativação *relu*, e uma camada de saída.

Para inicializar a construção do modelo, deve-se primeiramente importar a biblioteca *Tensorflow* para a memória do sistema e, em seguida, definir a camada de entrada. A entrada consiste em apenas de um único valor, ou seja, apenas 1 neurônio de entrada.

Na camada oculta, foram utilizados 80 neurônios com função de ativação *Relu* e sem a utilização de *Bias*. Por fim a camada de saída com apenas um único neurônio.

A função *model* no código efetua o sequenciamento e a construção das camadas neurais que compõem a rede, sendo esse processo baseado nos tensores pré-definidos. É possível ver toda a construção do modelo no apêndice A.

Após a construção do modelo é preciso utilizar a função "*compile*". Essa função realiza a configuração dos processos de treinamento e aprendizagem da arquitetura neural, sendo delimitado a função de perda e o método de otimização conforme os parâmetros a ela fornecidos.

Em seguida é definida a função de perda, sendo o erro médio absoluto (MAE), que foi representado na tabela 4.1 e o método de otimização *RMSprop* (*Probabilistic Root Mean Square*). Além disso, vale ressaltar que a taxa de aprendizado e o fator de decaimento do gradiente foram definidos a partir de experiências prévias.

Após a execução de todo o processo de construção e configuração do modelo, parte-se para a etapa de treinamento e aprendizado da rede, na qual o modelo é ajustado de acordo com as amostras de treinamento e valores alvos a ele fornecidos.

Nessa etapa o vetor com os dados de treino, que representam 80% de todos os 2920 dados sintéticos serão usados treinamento do modelo. Foram definidos 10000 épocas, contudo, para evitar o *overfitting*, que é o sobreajuste do modelo, é definido uma parada antecipada, que ocorre quando 15 épocas possuem um erro parecido.

Todo esse histórico processual, é então armazenado em uma estrutura de dados a fim de propiciar análises posteriores, tais como a verificação da curva de aprendizado e a medição da acurácia obtida. A figura 5.14 mostra a evolução do MAE. A figura 5.15 mostra a evolução do MSE.

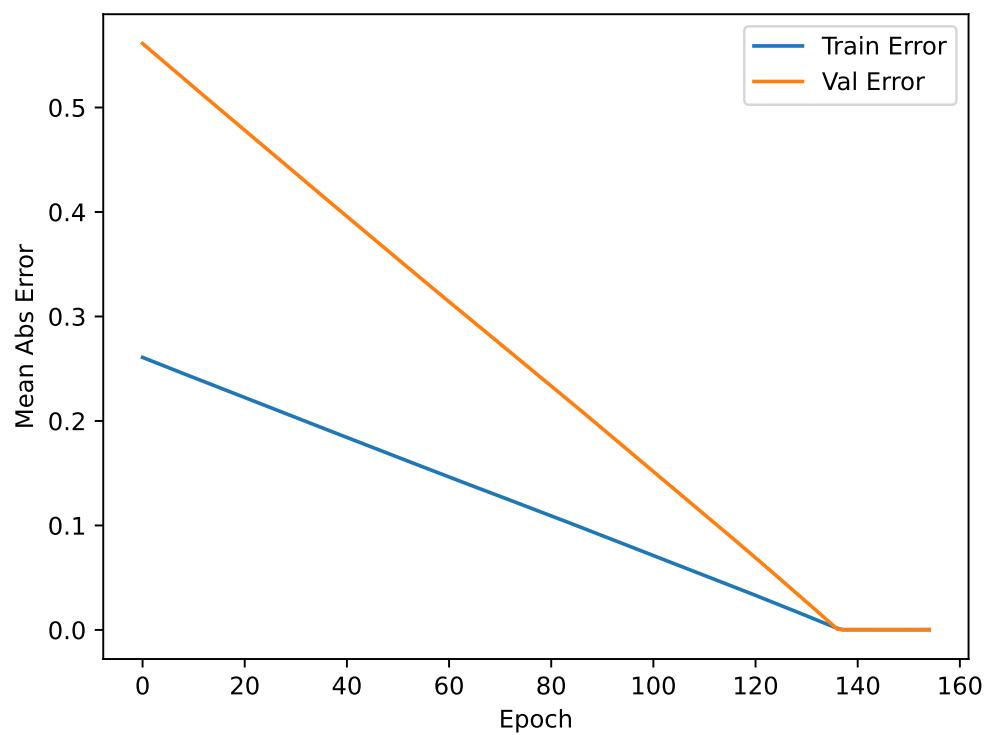


Figura 5.14 – Histórico processual erro médio absoluto para treinamento da rede aos dados do intervalo 1.

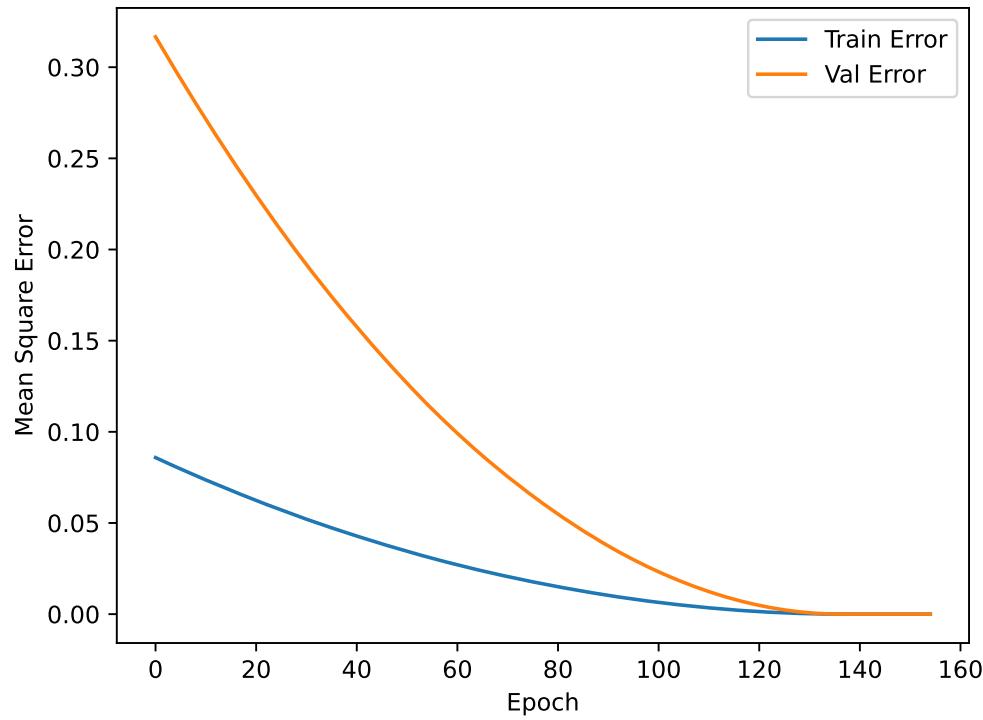


Figura 5.15 – Histórico processual erro médio quadrático para treinamento da rede aos dados do intervalo 1.

Uma vez que o modelo é treinado. Utiliza-se a rede para prever os dados de treino e de teste. A figura 5.16 mostra como a rede prevê os dados de treino e teste, e compara os resultados com os dados sintéticos que foram gerados.

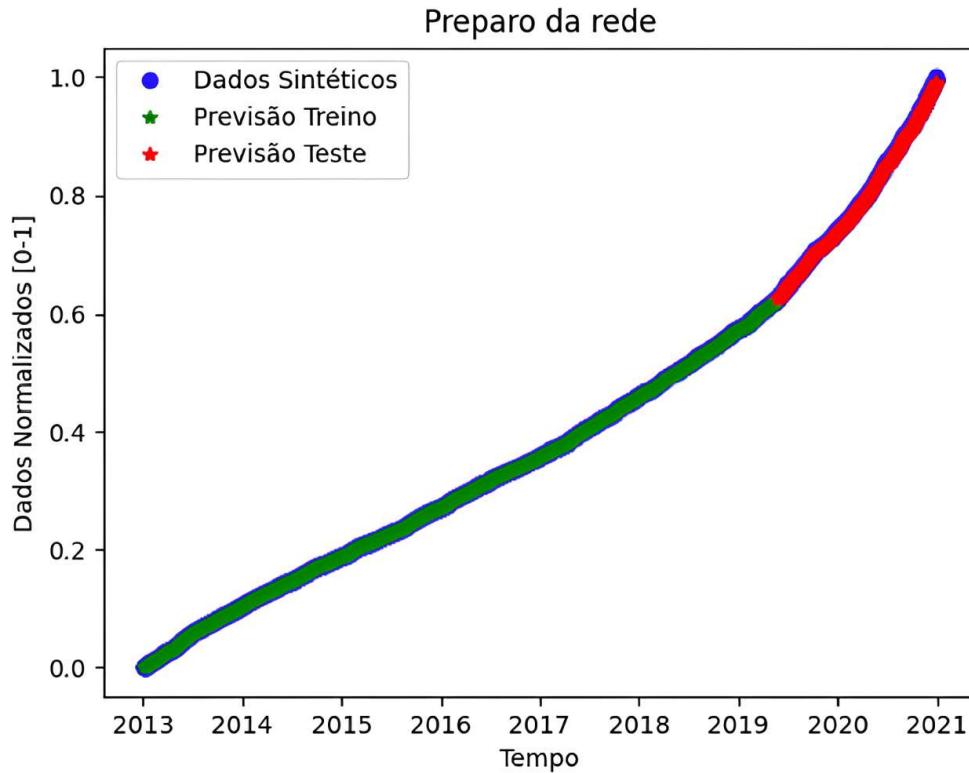


Figura 5.16 – Comparativo treino, teste e dados sintéticos do intervalo 1.

Além da visualização do gráfico, vale a pena ressaltar que o erro médio foi de 0,0004, demonstrando assim que o modelo consegue seguir a tendência de crescimento da corrosão com o tempo para o duto submarino objeto de estudo.

5.5 Previsão de vida remanescente (RUL)

A partir do fim do treino do modelo, a rede está pronta para realizar a previsão da vida remanescente. A rede determina o crescimento da corrosão para além do tempo da última inspeção. Essa previsão é feita a partir da extrapolação dos dados usando a métrica de passo único de séries temporais.

O fim da vida do duto ocorre quando a profundidade de corrosão alcança 80% de espessura nominal da parede. A figura 5.17 representa como é feita a determinação do fim da vida do duto de petróleo.

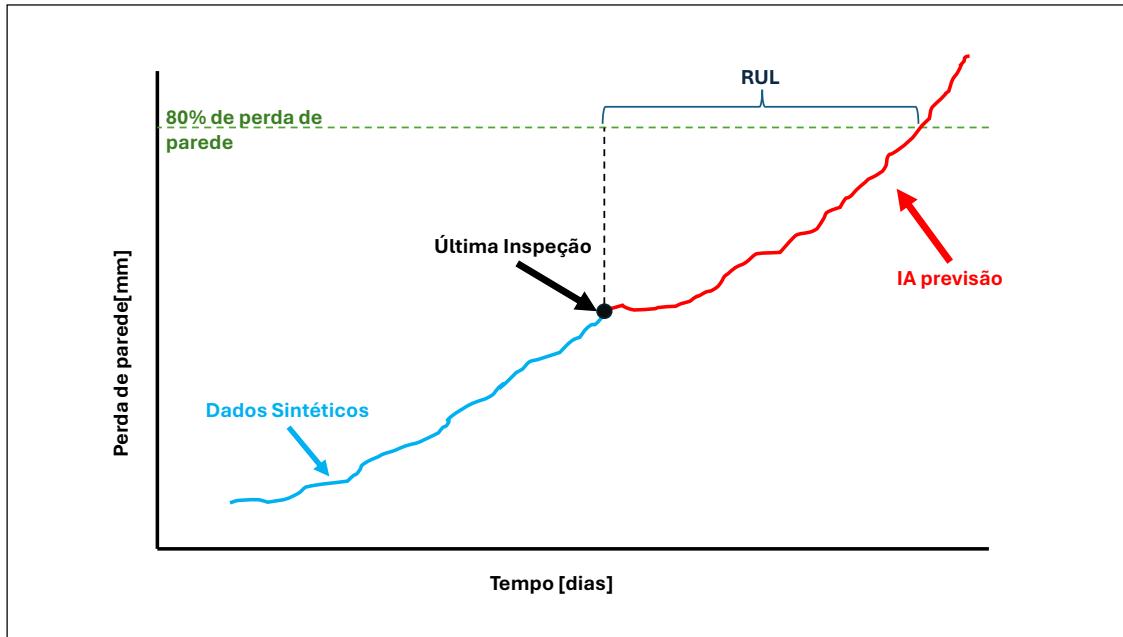


Figura 5.17 – Representação de determinação da vida remanescente usando IA.

Assim, a previsão de vida para o intervalo 1 e seu intervalo de confiança é definido por:

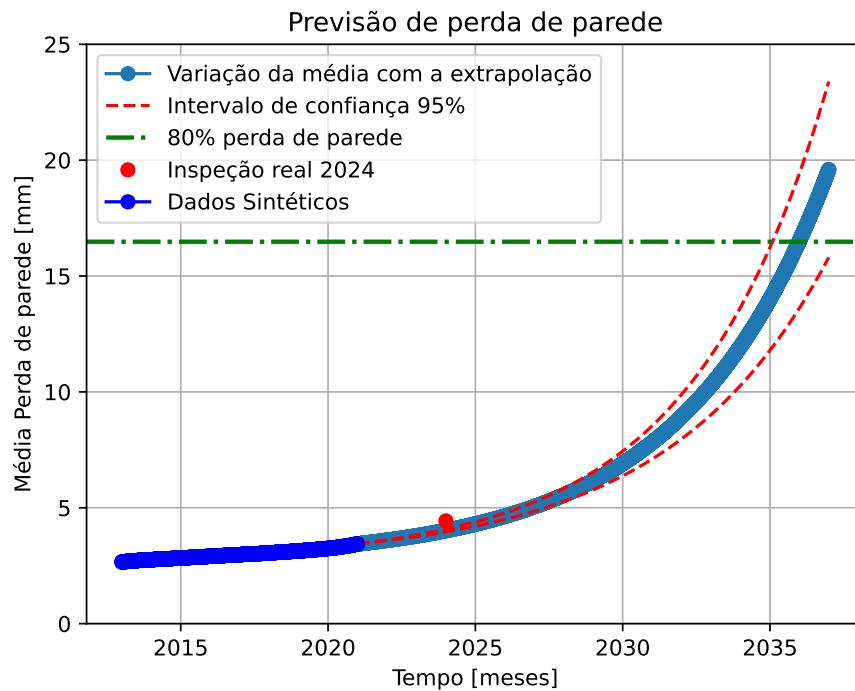


Figura 5.18 – Previsão de vida remanescente intervalo 1.

Como visto na figura 5.18, o intervalo de confiança foi determinado usando o desvio padrão dos resultados obtidos. Além disso, foram feitas 20 extrações de dados e o respectivo salvamento para então definir o intervalo de confiança.

Por fim, a perda média registrada no intervalo 1 que foi medida no ano de 2024 foi utilizado como validação do método, pois, como fica claro, a rede segue a tendência de crescimento da falha.

5.6 Resultados

A tabela 5.3 mostra a previsão de vida para os 9 intervalos iniciais do duto em análise.

Intervalo	1	2	3	4	5	6	7	8	9
RUL	14 anos	9 anos	12 anos	10 anos	13 anos	14 anos	16 anos	21 anos	14 anos

Tabela 5.3 – Previsão de vida dos primeiros 9 intervalos de 250 metros do duto.

A fim de realizar uma validação dos dados de crescimento da corrosão gerados pela rede, foi utilizado a inspeção realizada em 2024 como base de comparação. Os dados de perda de parede foram agrupados em intervalos de 250 metros e a perda de parede média em cada trecho foi determinada. Fazendo o erro absoluto entre o valor da perda média em 2024 e o valor da perda média definida pela IA no ano de 2024 chega-se na figura 5.19.

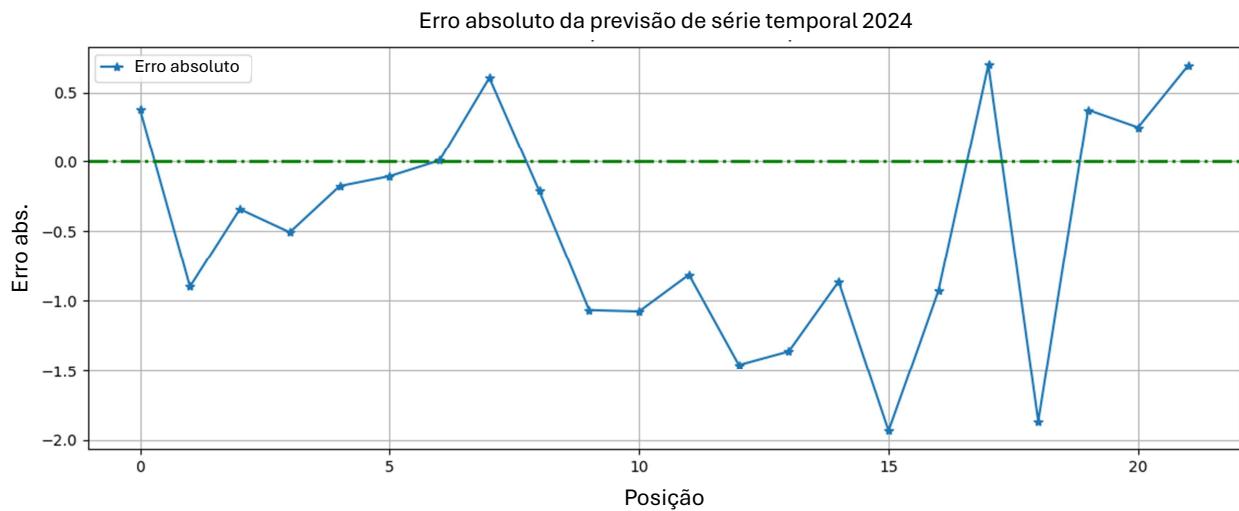


Figura 5.19 – Erro absoluto (Inspeção 2024 - IA 2024).

A figura 5.19 mostra a variação do erro absoluto em cada intervalo do duto. A parte negativa, abaixo da linha verde, representa os pontos em que o modelo de IA previu uma perda de parede superior a registrada na inspeção. Logo, nesses pontos negativos, a rede foi mais conservadora, adotando uma taxa de corrosão superior.

Nos pontos onde o erro absoluto é positivo, a rede foi menos conservadora, contudo, ela ainda segue a tendência de crescimento da falha em cada intervalo.

Por fim, ao comparar o vetor com os dados de previsão obtidos pela rede de IA com os valores da inspeção de 2024 observa-se um erro médio percentual de 23,75 %. O baixo erro comprova a eficácia da metodologia e como a rede consegue seguir a tendência de crescimento das falhas por corrosão.

Como análise complementar, foi feita a previsão de vida utilizando o método T-student para se ter uma base de comparação com as previsões feitas pela rede, utilizando a equação 3.3. A vida remanescente obtida usando este método, tendo como ano de referência 2021, foi de 5,59 anos de vida. Logo, seguindo esse método, o duto deve durar até 2026.

Ao se utilizar o método semi-estocástico alguns pontos já estão acima do limite geométrico admissível da corrosão em 2021. A figura 5.20 mostra a geometria máxima de falha admissível a cada 10 anos comparados com os dados da inspeção em 2021. Muitos pontos de corrosão apresentam um baixo comprimento e uma alta profundidade, caracterizando uma corrosão por pite.

O método semi-estocástico determina o limite da vida remanescente quando os pontos de inspeção ultrapassam a linha de pressão operacional, 4 MPa para esse duto. Sendo assim, para o caso em estudo, o metodo semi-estocástico já define que o duto opera em condições de falha desde 2021. A figura 5.20 mostra também como que a tolerância geométrica para a corrosão diminui com o passar do tempo.

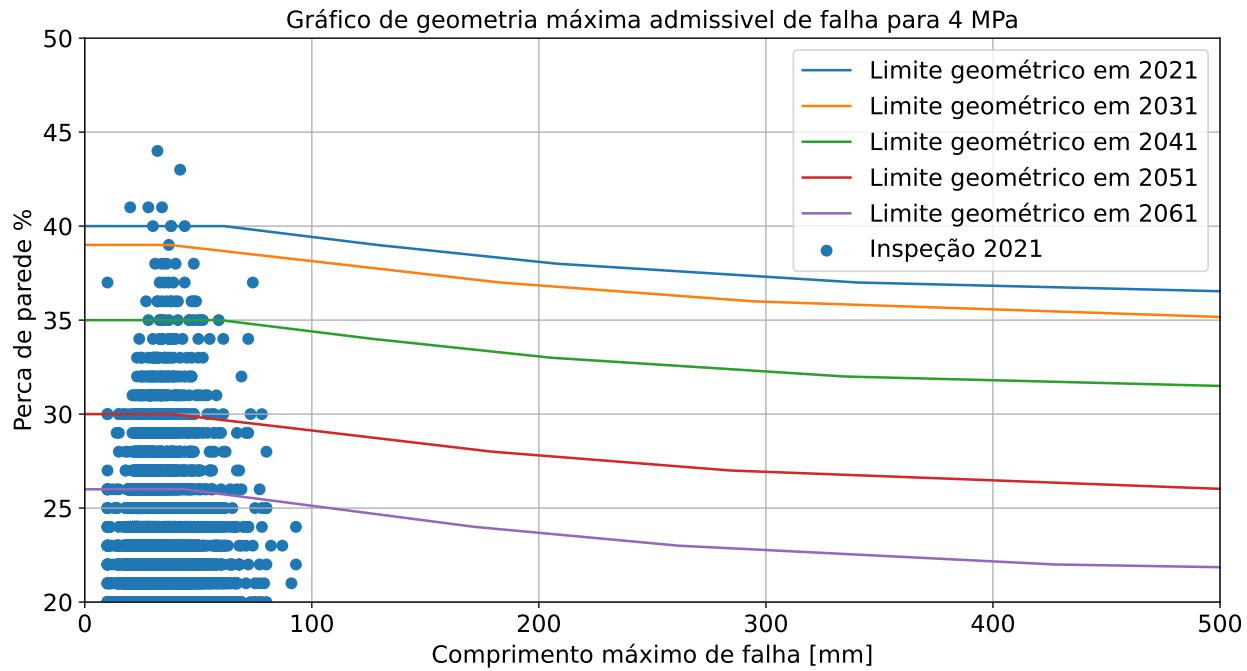


Figura 5.20 – Previsão usando análise Semi-estocástica.

Esse comportamento do método semi-estocástico é o esperado, uma vez que ele é o mais conservador dentre os métodos abordados. Pois ele provém da junção de métodos estatísticos com uma norma técnica e utiliza uma taxa de corrosão linear.

Os resultados deixam claro que, o método T-student é um método muito conservador. O que pode acarretar em altos custos para as empresas. Já a previsão por IA, apresentou uma boa estabilidade e conseguindo atender a tendência de crescimento da corrosão.

Além disso, por ser usado a abordagem de previsão de séries temporais, a rede se mostrou bem generalista, sendo possível atingir diferentes previsões para diferentes pontos do duto. Mostrando assim a alta capacidade que esse método pode alcançar.

5.7 Trabalhos futuros e aplicação em dutos não Pigaveis

Segundo Mills, Jackson e Richardson (2017) estima-se que apenas 0,5% das redes de dutos sejam inacessíveis à tecnologia convencional de PIG, enquanto os 99,5% restantes geralmente consistem em linhas retas de grande diâmetro, pigáveis. Embora essa proporção pareça pequena, os 12.500 km restantes representam os dutos mais valiosos da rede: as Instalações Acima do Solo (Above Ground Installations – AGIs). Muitas dessas redes não pigáveis já estão atingindo o final de sua vida útil de projeto e estão previstas para substituição. No entanto, como a condição de suas paredes internas é desconhecida, torna-se impossível determinar quais trechos devem ter prioridade

na substituição.

Tendo em vista esse problema relatado por Mills, Jackson e Richardson (2017) testes utilizando uma quantidade menor de dados de inspeção foram realizados afim de emular a falta de informação presente nos dutos não pigáveis. Esse procedimento foi feito pensando expandir a metodologia para dutos nos quais o PIG não consegue operar dentro da linha, obrigando assim a inspeção externa dos dutos em apenas alguns pontos de monitoramento.

Por ser monitorado em apenas algumas regiões, os dutos não pigáveis precisam que as áreas não inspecionadas passem por uma estimativa de perda de parede. Essa estimativa não depende do tempo, mas sim da posição do mesmo.

Tendo isso em vista, a utilização de metamodelos para representar a profundidade de perda de parede em pontos não inspecionados, vem se mostrando muito eficientes. Segundo Sicchieri et al. (2019) o metamodelo tem como função ajustar um modelo com base em amostras que visa substituir o modelo original. O metamodelo precisa ser representativo, e ter um baixo custo computacional.

Com isso, uma das formas de construir esse metamodelo é utilizando o metamodelo Kriging. Ainda segundo Sicchieri et al. (2019) os metamodelos Kriging são flexíveis e possuem um vasto campo de aplicação a ser explorado.

Afim de mostrar como podemos aplicar tal metodologia ao problema dos dutos não pigáveis escolhemos a inspeção realizada em 2024, a figura 5.5 mostra os pontos de corrosão e a profundidade de perda de parede nessa inspeção.

Com o intuito de emular um duto não pigável, foram pegos 6 pontos, cada ponto é a maior perda de parede em um metro de inspeção, totalizando assim, 6 metros de informação, para um duto de aproximadamente 6 quilômetros.

Esses pontos foram determinados de forma aleatória, exceto o ponto inicial e o final, que representam a entrada e a saída do duto. A figura 5.21 mostra a linha média e o intervalo de confiança gerado a partir do método kriging e sua comparação com a perda de parede nos locais que não foram utilizados para o metamodelo.

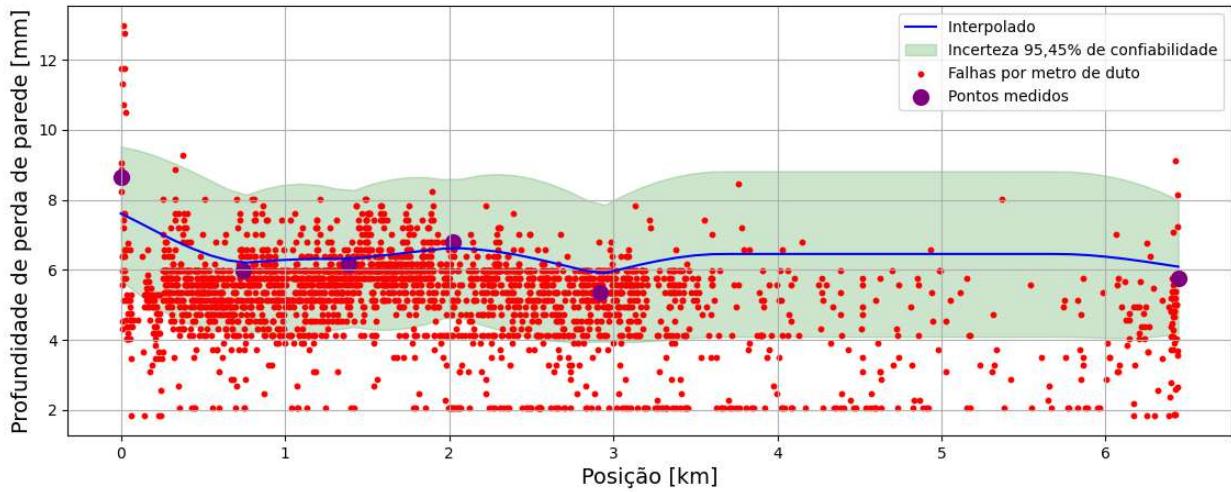


Figura 5.21 – Método Kriging.

Ao comparar os dados do metamodelo com os dados do PIG chegamos em um erro médio absoluto de 1,33 mm. Esse erro varia conforme se aumentam a quantidade de dados utilizados pelo metamodelo, isso ocorre devido a incerteza associada ao método e varia conforme a representatividade dos pontos escolhidos para representar a população. Podemos ver essa variação na imagem abaixo.

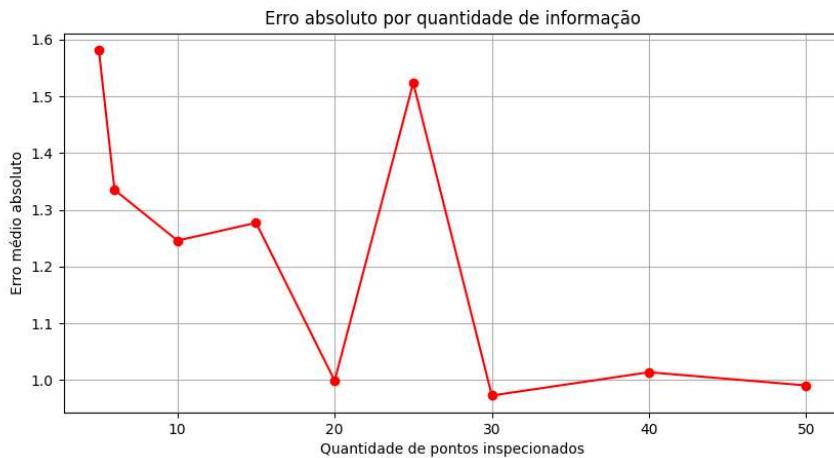


Figura 5.22 – Erro absoluto.

É de conhecimento que a indústria de petróleo e gás utiliza a batimetria para determinar os pontos de inspeção em dutos não pigáveis. Adotando que esses pontos são representativos é possível sim utilizar essa metodologia a fim de determinar a perda de parede em regiões não inspecionadas.

CAPÍTULO VI

CONSIDERAÇÕES FINAIS

A partir dos resultados apresentados neste trabalho, pode-se concluir que a metodologia híbrida proposta aqui possui um alto potencial a ser explorado e uma grande escalabilidade para outros ativos industriais que sofrem com corrosão. Principalmente no momento em que o histórico de inspeção desses ativos for vasto o suficiente para não precisar mais do uso dos dados sintéticos.

O uso de dados sintéticos se mostrou eficiente e bem conservador, sendo justamente indicado para situações onde não se tem disponível um histórico rico de inspeções. Neste caso, a utilização de uma curva exponencial ajustada aos dados de inspeção para gerar alguns pontos extras para o ajuste da distribuição Weibull se mostrou muito eficiente, garantindo que o sistema mantenha sua coerência física sem prejudicar a aleatoriedade com que esse fenômeno ocorre na natureza.

A rede MLP utilizada neste trabalho para previsão de vida de dutos submarinos se mostrou adaptativa aos dados. Com um tempo de processamento de aproximadamente 1 minuto por treinamento e teste, sem utilizar muita memória da máquina, a arquitetura se provou eficiente para este tipo de problema.

Foi constatado também algumas limitações para o método semi-estocástico. Devido sua junção com métodos estatísticos tornam essa abordagem muito conservadora, de modo que 30% de perda de parede se torna um critério de parada.

Também foi possível constatar que o método T-student é de fácil implementação, contudo, também é muito conservador, e trata o duto como um todo, sem diferenciar os pontos de corrosão.

Em suma, o método híbrido proposto nesse trabalho apresentou uma boa performance. Com estimativas de vida remanescentes conservadoras, contudo, sem ser tão conservador quanto o método semi estocástico e o método T-student. Isso proporciona uma redução na quantidade de inspeções realizadas no decorrer da operação do duto, reduzindo custos e mantendo a produção de forma constante.

6.1 Trabalhos futuros

Por fim, para trabalhos futuros é possível aprimorar os seguintes pontos:

- Expandir a análise para dutos não pigáveis.
- Estudar demais arquiteturas de rede para aplicação em fenômenos de corrosão.
- Usar a abordagem para definir pontos para reparo em zonas não pigáveis.

REFERÊNCIAS BIBLIOGRÁFICAS

- ADDOR, P. N. Avaliação da corrosão em dutos rígidos submarinos em operação: comparação entre as técnicas de monitoramento da corrosão interna e inspeção com pigs instrumentados. 2009.
- ADDOR, P. N.; FERREIRA, J. Z.; NICOLETTI, É. S. M.; DIAS, A. Comparação entre taxas de corrosão calculadas a partir de trocas de cupons de perda de massa e de inspeção interna com pig instrumentado em oleoduto rígido submarino. 2010.
- ALVES, L. F.; LOPES, P. R. Inspection of non-piggable pipelines at petrobras-un bahia; inspecao de dutos nao-pigaveis na petrobras-un bahia. 2005.
- BACELAR, L.; SOUZA, M.; DEMETINO, G. Desenvolvimento de um sistema de aquisição de dados sem fio para pig de limpeza instrumentado. In: SBC. **Escola Regional de Computação Bahia, Alagoas e Sergipe (ERBASE)**. [S.l.], 2019. p. 190–195.
- BAZÁN, F. A. V.; BECK, A. T. Stochastic process corrosion growth models for pipeline reliability. **Corrosion Science**, Elsevier, v. 74, p. 50–58, 2013. doi:10.1016/j.corsci.2013.04.011.
- BELONSI, M.; LIMA, A. de; DUARTE, M.; FERRARESI, R.; SILVA, W. da. A methodology based on 1d-cnn and bootstrap method to estimate the remaining useful life of industrial assets suffering from generalized corrosion. **Mathematical Problems in Engineering**, Wiley Online Library, v. 2023, n. 1, p. 4203541, 2023.
- BILAL, M.; OYEDELE, L. O.; QADIR, J.; MUNIR, K.; AJAYI, S. O.; AKINADE, O. O.; OWOLABI, H. A.; ALAKA, H. A.; PASHA, M. Big data in the construction industry: A review of present status, opportunities, and future trends. **Advanced engineering informatics**, Elsevier, v. 30, n. 3, p. 500–521, 2016. doi:10.1016/j.aei.2016.07.001.
- BUSCEMA, M. Back propagation neural networks. **Substance use & misuse**, Taylor & Francis, v. 33, n. 2, p. 233–270, 1998.
- CAMARGOS, P. M. N.; OLIVEIRA, V. H. G. D. Extensão de vida útil de dutos rígidos submarinos. 2018.
- CINTRA, F. M. R. N. **Aplicação do modelo t-student para análise dos resultados de ensaios de proficiência**. Tese (Doutorado) — Universidade de São Paulo, 2004.
- COSTA JÚNIOR, H. A. Uso do método box-behnken para diminuição de incerteza de medição da técnica de inspeção por pig mfl. 2021.

- FLECK, L.; TAVARES, M. H. F.; EYNG, E.; HELMANN, A. C.; ANDRADE, M. A. d. M. Redes neurais artificiais: Princípios básicos. **Revista Eletrônica Científica Inovação e Tecnologia**, v. 1, n. 13, p. 47–57, 2016.
- GEREMIA, G. Sistema autônomo de inspeção de dutos. 2012.
- GOODFELLOW, I. **Deep learning**. [S.l.]: MIT press, 2016.
- HAFEMANN, L. G. An analysis of deep neural networks for texture classification. 2014.
- HAYKIN, S. **Redes neurais: princípios e prática**. [S.l.]: Bookman Editora, 2001.
- HO, M.; EL-BORGI, S.; PATIL, D.; SONG, G. Inspection and monitoring systems subsea pipelines: A review paper. **Structural Health Monitoring**, SAGE Publications Sage UK: London, England, v. 19, n. 2, p. 606–645, 2020. doi:10.1177/1475921719837718.
- JIANG, Y.; YANG, C.; NA, J.; LI, G.; LI, Y.; ZHONG, J. A brief review of neural networks based learning and control and their applications for robots. **Complexity**, Wiley Online Library, v. 2017, n. 1, p. 1895897, 2017.
- KAHRAMAN, C. L.; ROMAN, D.; KIRSCHBAUM, L.; FLYNN, D.; SWINGLER, J. Machine learning pipeline for power electronics state of health assessment and remaining useful life prediction. **IEEE Access**, IEEE, 2024.
- KOCH, G. H.; BRONGERS, M. P.; THOMPSON, N. G.; VIRMANI, Y. P.; PAYER, J. H. et al. **Corrosion cost and preventive strategies in the United States**. [S.l.], 2002.
- KOHAVI, R. Glossary of terms. **Machine learning**, v. 30, p. 271–274, 1998. doi:10.1023/A:1017181826899.
- LEMOS, I.; LIMA, A. de; DUARTE, M.; SILVA, W. A methodology to estimate the remaining residual life of components of processes subjected to corrosion using the extreme value theory combined with the first-order reliability method. **Journal of the Brazilian Society of Mechanical Sciences and Engineering**, Springer, v. 43, p. 1–13, 2021. doi:10.1007/s40430-021-03202-2.
- LEMOS, I. P.; LIMA, A. M. G.; MARTINS, F. D. F.; SILVA, W. C. D. da. Uma abordagem pela teoria de valores extremos: Determinação do tamanho amostral para inspeção de equipamentos de processo utilizando a distribuição generalizada de pareto e o peak-over-threshold method. **Revista de Matemática da UFOP**, v. 1, 2020.
- MASSA, A. L. L. Contribuição ao estudo de flambagem em dutos rígidos submarinos conduzindo fluidos aquecidos. **UFRJ, Tese M. Sc., Ciências em Engenharia Oceânica**. Rio de Janeiro, 2003.
- MAZZINI, C. E. Comparação de métodos de inspeção de integridade de dutos: Método pig e cis/dcvg. **Projeto de graduação, Departamento de Engenharia Mecânica. Universidade Federal do Espírito Santo, Vitória**, 2009.
- MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, Springer, v. 5, p. 115–133, 1943. doi:10.1007/BF02478259.

- MILLS, G. H.; JACKSON, A. E.; RICHARDSON, R. C. Advances in the inspection of unpiggable pipelines. **Robotics**, MDPI, v. 6, n. 4, p. 36, 2017. doi:10.3390/robotics6040036.
- MOURA JÚNIOR, J. d. R. V. et al. Uma contribuição aos sistemas de monitoramento de integridade estrutural aplicada a estruturas aeronáuticas e espaciais. Universidade Federal de Uberlândia, 2008.
- MULLAINATHAN, S.; SPIESS, J. Machine learning: an applied econometric approach. **Journal of Economic Perspectives**, American Economic Association 2014 Broadway, Suite 305, Nashville, TN 37203-2418, v. 31, n. 2, p. 87–106, 2017. doi:10.1257/jep.31.2.87.
- NACE, N. Rp0775-2005. **Standard Recommended Practice: Preparation, Installation, Analysis, and Interpretation of Corrosion Coupons in Oilfield Operations**, NACE, 2005.
- NOOR, N. M.; YAHAYA, N.; DIN, M. M.; OZMAN, N. A. N. Prediction of corroding pipeline remaining life-time using semi-probabilistic approach. **Malaysian Journal of Civil Engineering**, v. 21, n. 2, 2009. doi:10.11113/mjce.v21.15786.
- NWANKPA, C.; IJOMAH, W.; GACHAGAN, A.; MARSHALL, S. Activation functions: Comparison of trends in practice and research for deep learning. **arXiv preprint arXiv:1811.03378**, 2018.
- OSARUMWENSE, O.-I.; ROSE, N. C. Parameters estimation methods of the weibull distribution: A comparative study. **Elixir Statistics**, v. 69, p. 23177–23184, 2014.
- PEREIRA JUNIOR, D. M. Avaliação de defeitos de corrosão para a estimativa de vida útil em tubulação de transporte de minério de bauxita. 2021.
- RAMPASEK, L.; GOLDENBERG, A. Tensorflow: biology's gateway to deep learning? **Cell systems**, Elsevier, v. 2, n. 1, p. 12–14, 2016. doi:10.1016/j.cels.2016.01.009.
- REZENDE, S. W. F. d. et al. Técnicas de aprendizado profundo aplicadas ao monitoramento de integridade estrutural por impedância eletromecânica. Universidade Federal de Goiás, 2021.
- ROSÁRIO, P. A. G. **Análise de valores extremos para níveis pluviométricos em barcelos**. Tese (Doutorado), 2013.
- ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological review**, American Psychological Association, v. 65, n. 6, p. 386, 1958. doi:10.1037/h0042519.
- RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. **nature**, Nature Publishing Group UK London, v. 323, n. 6088, p. 533–536, 1986.
- SHAIK, N. B.; PEDAPATI, S. R.; DZUBIR, F. A. B. Remaining useful life prediction of a piping system using artificial neural networks: A case study. **Ain Shams Engineering Journal**, Elsevier, v. 13, n. 2, p. 101535, 2022. doi:10.1016/j.asej.2021.06.021.
- SICCHIERI, L. C. et al. Metamodelagem kriging aplicada em modelos de mancais termo-hidrodinâmicos. Universidade Federal de Uberlândia, 2019.

SILVA, G. Caracterização de cupons de corrosão através de diferentes técnicas comparativas. [S.I.]: UENF, 2014.

SILVA, M. V.; PEREIRA, M. C.; CODARO, E. N.; ACCIARI, H. A. Corrosão do aço-carbono: uma abordagem do cotidiano no ensino de química. **Química Nova**, SciELO Brasil, v. 38, n. 2, p. 293–296, 2015. doi:10.5935/0100-4042.20140313.

VANAEI, H.; ESLAMI, A.; EGBEWANDE, A. A review on pipeline corrosion, in-line inspection (ili), and corrosion growth rate models. **International Journal of Pressure Vessels and Piping**, Elsevier, v. 149, p. 43–54, 2017. doi:10.1016/j.ijpvp.2016.11.007.

XUE, Y.; YANG, L.; HAYKIN, S. Decoupled echo state networks with lateral inhibition. **Neural Networks**, Elsevier, v. 20, n. 3, p. 365–376, 2007. doi:10.1016/j.neunet.2007.04.014.

YARVEISY, R.; KHAN, F.; ABBASSI, R. Data-driven predictive corrosion failure model for maintenance planning of process systems. **Computers & Chemical Engineering**, Elsevier, v. 157, p. 107612, 2022.

YU, W.; ZHUANG, F.; HE, Q.; SHI, Z. Learning deep representations via extreme learning machines. **Neurocomputing**, Elsevier, v. 149, p. 308–315, 2015. doi:10.1016/j.neucom.2014.03.077.

ZIBETTI, D. H. Estudo das possíveis causas para ocorrência de corrosão nos tubos de um trocador de calor tipo condensador. 2023.

APÊNDICE A

CÓDIGOS CONSTRUÇÃO DE REDE NEURAL ARTIFICIAL

Importando biblioteca *tensorflow* no *Python* e criando modelo de rede MLP:

```
import tensorflow as tf

model = tf.keras.Sequential([tf.keras.layers.InputLayer(input_shape=(1,)),
                            tf.keras.layers.Dense(80, activation= 'relu',use_bias= False),
                            tf.keras.layers.Dense(1, use_bias= False)] )
```

Definindo otimizador e a função de erro:

```
optimizer = tf.keras.optimizers.RMSprop(0.00001)
model.compile(loss='mae', optimizer=optimizer, metrics=['mae', 'mse'])
```

Para se realizar o treinamento de uma MLP no *python*, usa-se a função *fit*. Também é possível definir o critério de parada no treinamento, número de épocas, e dados para validação

```
early_stop = tf.keras.callbacks.EarlyStopping(monitor = 'loss', patience=15 )

history = model.fit(x_train,
                     y_train,
                     epochs=10000,
                     validation_split = 0.2,
                     verbose = 2,
                     callbacks = early_stop)
```

Previsão dos dados de teste e previsão dos dados de treino:

```
previsao_treino = model.predict(x_train)
previsao_teste  = model.predict(x_test)
```