

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL - UFRGS

**Escola de Engenharia**

Programa de Pós-Graduação em Engenharia de Minas, Metalúrgica e de Materiais - PPGE3M

**SANDRO MARCOS DE GOUVEIA**

**AVALIAÇÃO DE MÉTODOS DE  
MONITORAMENTO DA INTEGRIDADE  
DE VÁLVULA DE BLOQUEIO DO TIPO  
ESFERA PARA A INDÚSTRIA DE  
PETRÓLEO E GÁS**

Porto Alegre  
2024

**SANDRO MARCOS DE GOUVEIA**

**AVALIAÇÃO DE MÉTODOS DE  
MONITORAMENTO DA INTEGRIDADE  
DE VÁLVULA DE BLOQUEIO DO TIPO  
ESFERA PARA A INDÚSTRIA DE  
PETRÓLEO E GÁS**

Tese de doutorado apresentada ao Programa de Pós-Graduação em Engenharia de Minas, Metalúrgica e de Materiais - PPGE3M da Universidade Federal do Rio Grande do Sul - UFRGS como parte dos requisitos para a obtenção do título de Doutor em Engenharia.

Área de concentração: Ciência e Tecnologia dos Materiais

ORIENTADOR: Prof. Dr. Thomas Gabriel Rosauro Clarke

Porto Alegre  
2024

**SANDRO MARCOS DE GOUVEIA**

**AVALIAÇÃO DE MÉTODOS DE  
MONITORAMENTO DA INTEGRIDADE  
DE VÁLVULA DE BLOQUEIO DO TIPO  
ESFERA PARA A INDÚSTRIA DE  
PETRÓLEO E GÁS**

Esta tese foi analisada e julgada adequada para a obtenção do título de Doutor em Engenharia, área de concentração em Ciência e Tecnologia dos Materiais, e aprovada em sua forma final pelo Orientador e pela Banca Examinadora designada pelo Programa de Pós-Graduação em Engenharia de Minas, Metalúrgica e de Materiais da Universidade Federal do Rio Grande do Sul.

Orientador: \_\_\_\_\_  
Prof. Dr. Thomas Gabriel Rosauro Clarke, UFRGS  
Professor do Programa de Pós-Graduação em Engenharia de Minas,  
Metalúrgica e de Materiais - PPGE3M

Banca Examinadora:

Dr. Eng. Diego Rizzotto Rossetto,  
UTFPR, Pato Branco, Brasil

Dr. Eng. Diógenes Barbosa Teles,  
Micromazza Indústria de Válvulas, Vila Flores, Brasil

Dr. Eng. Lúcio de Abrêu Corrêa,  
Aix Marseille Univ, Marseille, França

Coordenador do PPGE3M: \_\_\_\_\_  
Prof. Dr. Rodrigo de Lemos Peroni

Porto Alegre, Agosto de 2024.

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

Reitor: prof. Dr. Carlos André Bulhões Mendes

Vice-reitoria: Profa. Dr. Patricia Pranke

ESCOLA DE ENGENHARIA

Diretora: Profa. Dra. Carla Schwengber ten Caten

Vice-direto: Prof. Dr. Afonso Reguly

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE MINAS,  
METALURGIA E DE MATERIAIS - PPGE3M

Coordenador: Prof. Dr. Rodrigo de Lemos Peroni

Vice-coordenadora: Profa. Dra. Annelise Koop Alves

#### CIP - Catalogação na Publicação

Gouveia, Sandro Marcos de  
AVALIAÇÃO DE MÉTODOS DE MONITORAMENTO DA  
INTEGRIDADE DE VÁLVULA DE BLOQUEIO DO TIPO ESFERA PARA  
A INDÚSTRIA DE PETRÓLEO E GÁS / Sandro Marcos de  
Gouveia. -- 2024.  
144 f.  
Orientador: Thomas Gabriel Rosauro Clarke.

Tese (Doutorado) -- Universidade Federal do Rio  
Grande do Sul, Escola de Engenharia, Programa de  
Pós-Graduação em Ciência dos Materiais, Porto Alegre,  
BR-RS, 2024.

1. Válvulas de Bloqueio. 2. Assinatura de Pressão.  
3. Algoritmos. 4. Classificação de Danos. 5. Vida Útil  
Remanescente. I. Clarke, Thomas Gabriel Rosauro,  
orient. II. Título.

ATA Nº 689

ATA DE DEFESA DE TESE

Ao sexto dia de agosto de 2024, às oito horas, em Ambiente Virtual pela Universidade Federal do Rio Grande do Sul, realizou-se a defesa da Tese de Doutorado de **M. Sc. Sandro Marcos de Gouveia**, intitulada "**Avaliação de Métodos de Monitoramento da Integridade de Válvula de Bloqueio do Tipo Esfera para a Indústria de Petróleo e Gás**". A Comissão Examinadora, presidida pelo orientador do candidato, Prof. Dr. Thomas Gabriel Rosauo Clarke (PPGE3M/UFRGS), constituiu-se dos seguintes membros: Dr. Diógenes Barbosa Teles (Micromazza), Prof. Dr. Diego Rizzotto Rossetto (UTFPR) e Dr. Lúcio de Abreu Corrêa (Aix Marseille Univ/França). Após a apresentação do candidato pelo Presidente da Comissão, o mesmo expôs seu trabalho de Tese, sendo logo a seguir, arguido pelos membros da Comissão Examinadora. O candidato prestou esclarecimentos sobre sua Tese, respondendo às perguntas formuladas. Às 10 horas e 30 minutos, a Comissão Examinadora procedeu ao julgamento do trabalho. Consultados individualmente, os membros da Comissão Examinadora justificaram e emitiram os seguintes pareceres: Dr. Diógenes Barbosa Teles Aprovado, Prof. Dr. Diego Rizzotto Rossetto Aprovado e Dr. Lúcio de Abreu Corrêa Aprovado. Desta forma e de acordo com o regimento interno do PPGE3M a Tese foi Aprovada e considerada adequada para a concessão do título de "**Doutor em Engenharia – Área de Concentração: Ciência e Tecnologia dos Materiais**". O candidato deve efetuar as correções indicadas pelos examinadores dentro do prazo regimental. O professor Thomas Gabriel Rosauo Clarke agradeceu aos membros da Comissão Examinadora pela presença e colaboração recebida quando foi lida a presente Ata, que vai assinada por todos os membros da Comissão Examinadora, orientador e aluno.

Documento assinado digitalmente  
 THOMAS GABRIEL ROSAUO CLARKE  
Data: 06/08/2024 10:51:52 -0300  
Verifique em <https://validar.it.gov.br>

Prof. Dr. Thomas Gabriel Rosauo Clarke

Documento assinado digitalmente  
 DIÓGENES BARBOSA TELES  
Data: 06/08/2024 20:02:07 -0300  
Verifique em <https://validar.it.gov.br>

Dr. Diógenes Barbosa Teles

Prof. Dr. Diego Rizzotto Rossetto

Documento assinado digitalmente  
 DIEGO RIZZOTTO ROSSETTO  
Data: 06/08/2024 13:42:48 -0300  
Verifique em <https://validar.it.gov.br>

Documento assinado digitalmente  
 SANDRO MARCOS DE GOUEIA  
Data: 06/08/2024 12:31:30 -0300  
Verifique em <https://validar.it.gov.br>

**M. Sc. Sandro Marcos de Gouveia**

Dr. Lúcio de Abreu Corrêa

Documento assinado digitalmente  
 LUCIO DE ABREU CORREA  
Data: 06/08/2024 03:00:34 -0300  
Verifique em <https://validar.it.gov.br>

## **DEDICATÓRIA**

Primeiramente ao Senhor Jesus, criador de tudo e de todos.

Em segundo lugar, minha família, em especial a minha amada esposa Daniele.

Aos meus amados filhos: Caio, Samuel e Léah.

Obrigado pelo apoio e suporte, esta conquista é nossa!

## **AGRADECIMENTOS**

A Cristo, sempre.

A minha família.

Ao meu orientador.

Aos colegas e amigos dos grupos ProEngCDT Barro Vermelho e Gend.

Ao LAMEF.

A Micromazza - LTM.

A UFRGS.

A todos que, de alguma forma, contribuíram.

*Os céus declaram a Glória de Deus.  
O firmamento anuncia a obra de suas mãos.  
Salmos 19:1*

## RESUMO

As válvulas de bloqueio do tipo esfera, também chamadas de (*Emergency Shutdown Valves*, ou ESDV) são componentes essenciais na indústria do petróleo e gás, especialmente na exploração e produção submarina. O monitoramento da integridade destes ativos críticos situados em locais de difícil acesso é fundamental. Uma abordagem para monitorar a integridade da válvula de segurança envolve a análise dos sinais de pressão e torque gerados durante suas operações de abertura e fechamento. Porém, a metodologia atual é realizada através da análise manual de pontos notáveis (*Key Points*, ou KPs), que necessita de um operador especializado e altamente treinado para localizar e apontar tais pontos. Algoritmos de processamento de sinais podem ser utilizados para automatizar esta tarefa, além de permitir também a identificação de eventuais danos nas válvulas de bloqueio. No entanto, estes algoritmos necessitam de um amplo banco de dados para o seu treinamento, o que pode ser escasso. Neste sentido, surge a oportunidade de utilizar dados sintéticos para treinar os algoritmos a fim de expandir o banco de dados. Soma-se a isto, a possibilidade de usar os algoritmos para o cálculo de Vida Útil Remanescente (*Remaining Useful Life* - RUL), para aumentar a confiabilidade e garantir a integridade das válvulas de segurança. Esta tese se propõe a avaliar técnicas de monitoramento em danos ocorridos em uma válvula de segurança do tipo esfera, durante testes de ciclagem. A avaliação será conduzida por 3 técnicas: i) KPs, ii) índices de dano (*Damage Index*, ou DIs) e iii) assinatura de pressão completa. Primeiramente, foi implementado a automatização de localização dos KPs através dos algoritmos de processamento por técnicas de regressão. Também foi analisada a classificação de dano usando os 3 conjuntos de dados por 3 algoritmos distintos. O método de Monte Carlo, foi aplicado para gerar os dados sintéticos para treinar os algoritmos e aumentar o banco de dados. Por fim, foi aplicado um algoritmo de redes neurais, para a previsão do RUL do equipamento durante sua falha. As análises mostraram notáveis resultados na automatização dos KPs, com o algoritmo *Gradiente Boosting* apresentando os menores erros. Para a classificação de dano, a assinatura de pressão se mostrou o melhor conjunto de dado. Para o cálculo do RUL, as redes neurais obtiveram excelentes resultados, frente aos algoritmos de processamento. Os dados sintéticos se mostraram ótimos conjunto de dados para se treinar um algoritmo, na falta de dados reais, usando-se principalmente o sinal por completo. Concluímos que os DIs possuem potencial para substituir o uso convencional dos KPs no monitoramento de válvula de segurança e que o cálculo de RUL pode ser aplicado para estimar a vida remanescente. Finalmente, a aplicação de algoritmos de processamento de sinais, apresentaram excelente potencial para a automatização dos KPs e a identificação de dano durante o monitoramento.

**Palavras-chave:** Válvulas de Bloqueio, Assinatura de Pressão, Algoritmos de Monitoramento, Classificação de Danos, Vida Útil Remanescente.

## ABSTRACT

Shutdown valves, also known as Emergency Shutdown Valves (ESDV), are essential components in the oil and gas industry, especially in subsea exploration and production. Monitoring the integrity of these critical assets located in hard-to-reach places is crucial. One approach to monitoring the integrity of the safety valve involves analyzing the pressure and torque signals generated during their opening and closing operations. However, the current methodology relies on the manual analysis of Key Points (KPs), which requires a specialized and highly trained operator to locate and identify these points. Signal processing algorithms can be used to automate this task and also allow the identification of potential damages in the safety valves. Nevertheless, these algorithms require a large database for their training, which can be scarce. In this context, there is an opportunity to use synthetic data to train the algorithms to expand the database. Additionally, there is the possibility of using these algorithms to calculate the Remaining Useful Life (RUL) to increase reliability and ensure the integrity of the safety valves. This thesis aims to evaluate monitoring techniques for damages occurring in a sphere-type safety valve during cycling tests. The evaluation will be conducted using three techniques: i) KPs, ii) Damage Indexes (DIs), and iii) full pressure signatures. Firstly, the automation of KP localization was implemented using regression-based signal processing algorithms. Damage classification was also analyzed using the three data sets with three distinct algorithms. The Monte Carlo method was applied to generate synthetic data to train the algorithms and expand the database. Finally, a neural network algorithm was applied to predict the RUL of the equipment during its failure. The analyses showed remarkable results in the automation of KPs, with the Gradient Boosting algorithm presenting the best scores. For damage classification, the pressure signature proved to be the best data set. For RUL calculation, neural networks obtained excellent results compared to other processing algorithms. The synthetic data proved to be an excellent data set for training an algorithm in the absence of real data, mainly using the complete signal. We concluded that DIs have the potential to replace the conventional use of KPs in safety valve monitoring and that RUL calculation can be applied to estimate the remaining life. Finally, the application of signal processing algorithms showed excellent potential for the automation of KPs and the identification of damage during monitoring.

**Palavras-chave:** Shutdown Valves, Pressure Signature, Monitoring Algorithms, Damage Classification, Remaining Useful Life.

## LISTA DE FIGURAS

1	Projeção de barris de petróleo até 2030 para as maiores produtoras do mundo. . .	21
2	Estimativa de novas ANM novas entre 2024 e 2028. Cada ANM contém algumas válvulas de bloqueio para garantirem a operação segura que envolve a extração e transporte dos fluidos advindos dos poços submarinos. . . . .	23
3	Dois exemplos distintos do uso de ESDV, onde uma se encontra instalada em uma planta <i>onshore</i> e a outra em um ambiente <i>offshore</i> . . . . .	24
(a)	Válvula instalada em uma tubulação. . . . .	24
(b)	Válvula (ESDV) instalada em uma ANM. . . . .	24
4	Exemplo de uma válvula de bloqueio com: acionamento por pistão (hidráulico) e retorno por mola( <i>Fail Safe Close</i> ), sistema de <i>Scotch-Yoke</i> e válvula esfera ( <i>Trunnion</i> ). . . . .	32
5	Uma Árvore de Natal Molhada e a localização de uma válvula do tipo ESDV posicionada na estrutura. . . . .	33
6	Plataforma <i>Piper Alpha</i> , em 1988, em chamas. Mais tarde, o inquérito do Lord Cullen, apontaria que, dentre outras medidas, as ESDVs poderiam mitigar as consequências catastróficas deste desastre interrompendo o escoamento dos fluidos inflamáveis. . . . .	35
7	Apresentação de um atuador utilizado na abertura e fechamento de uma válvula de bloqueio. Na região em azul, o monitoramento do equipamento é realizado utilizando-se um sensor de pressão localizado na câmara do atuador. . . . .	37
8	Representação da diferença entre o <i>Scotch-Yoke</i> simétrico e não simétrico. . . . .	38
(a)	Diferenças entre <i>SY</i> simétricos e <i>Canted</i> . . . . .	38
(b)	Forças envolvidas no <i>SY</i> em função do braço de alavanca variável $L_s$ e do cosseno de $\alpha$ . . . . .	38
9	Influência da montagem do <i>SY</i> em função do torque fornecido. A linha em vermelho representa o torque fornecido pelo <i>Scotch-Yoke</i> , já a linha azul representa o valor de torque que a válvula demanda para mover o obturador. Estes exemplos consideram o máximo diferencial de pressão entre montante e jusante. . . . .	39
(a)	<i>SY Canted</i> com torque maior no início. . . . .	39
(b)	<i>SY</i> Simétrico . . . . .	39
(c)	<i>SY Canted</i> com torque maior no fim. . . . .	39
10	Válvula gaveta (esquerda) e esfera (direita). As mais utilizadas em sistemas de emergências. Notar que a gaveta possui um obturador em forma de “cunha”, que se move paralelo à haste. Para a esfera, o obturador é esférico e seu movimento é angular em relação ao eixo da haste. . . . .	41
11	Relação pressão máxima e temperatura para diversas classes de válvulas esferas. . . . .	41
12	Diferença entre válvulas esferas flutuantes e <i>trunnion</i> e quais sedes executam a vedação quando, em ambos os casos, a pressão na tubulação, está localizada a montante da válvula, ao lado esquerdo da Figura. . . . .	43
13	Configuração Simples Pistão Efeito (SPE) nas sedes de uma válvula. . . . .	44
(a)	Balanco de áreas na sede SPE, quando a pressão se localiza na montante da válvula. . . . .	44
(b)	Balanco de áreas na sede SPE, quando a pressão se localiza na cavidade da válvula. . . . .	44
14	Configuração Duplo Pistão Efeito (DPE) nas sedes de uma válvula. . . . .	44

(a)	Balanco de áreas na sede DPE, quando a pressão se localiza na montante da válvula. . . . .	44
(b)	Balanco de áreas na sede DPE, quando a pressão se localiza na cavidade da válvula. . . . .	44
15	Distribuição do tipo de falha ocorrida em um estudo em uma população de 250.000 válvulas, destaque para as falhas do tipo vazamento. . . . .	47
16	Detalhamento das falhas em válvulas de bloqueio, sendo que, as falhas em sedes correspondem por 76% de todas as falhas ocorridas no equipamento. . . . .	47
17	Defeitos em sedes poliméricas. . . . .	48
18	Defeitos em sedes utilizadas em válvulas de bloqueio. . . . .	48
19	Normas aplicadas em válvulas do tipo esfera em relação a ABNT 15827. . . . .	50
20	Teste hiperbárico aplicado em ESDVs. . . . .	51
21	Assinaturas de pressão e torque. . . . .	53
22	Tendência dos pontos notáveis após testes de qualificação e o seu potencial em resumir o comportamento da ESDV ao longo do tempo. . . . .	54
23	Relação da pressão e velocidade em função da abertura da esfera. Notar quando a mínima passagem é criada ( <i>crack-open</i> ), na posição de 20%, a velocidade aumenta, se concentrando em uma região específica, resultando na diminuição da pressão, sendo esta, o momento propenso a existência de cavitação. . . . .	55
24	Região de maior deformação na esfera, conduzida por uma análise estrutural por MEF de uma válvula esfera. Considerar a região apresentada pelo círculo preto, onde existe a maior deformação na esfera. . . . .	56
25	Softwares comerciais direcionados ao monitoramento de ESDV utilizando as assinaturas de pressão e emissão acústica como formas de monitoramento no âmbito industrial. . . . .	59
(a)	Software V-Map. . . . .	59
(b)	Software IMtex . . . . .	59
(c)	Software ValControls. . . . .	59
(d)	Software ValveWatch. . . . .	59
26	Modelos matemáticos, sejam estáticos ou dinâmicos, estão apresentados através da assinatura de pressão por diferentes autores e evidenciam o potencial de simulação de comportamentos associado a falhas nas ESDVs. . . . .	60
(a)	Modelo Matemático Mashiba . . . . .	60
(b)	Modelo Matemático Euthymíou . . . . .	60
(c)	Modelo Matemático Gouveia . . . . .	60
(d)	Modelo Matemático Souza . . . . .	60
27	Domínio da Inteligência Artificial, Aprendizado de Máquina e Aprendizado Profundo. . . . .	62
28	Típico exemplo de problemas de classificação utilizando a decisão "é spam"ou "não é spam"associado aos e-mails recebidos. . . . .	64
29	Representações das regressões lineares e não lineares. . . . .	65
(a)	Exemplos de regressões lineares de primeira ordem. Na adaptação aos dados, somente o coeficiente angular é alterado mudança a inclinação da reta. . . . .	65
(b)	Exemplos da função <i>Sigmoid</i> que pode ser aplicado em problemas de regressões lineares afim de fornecer soluções não-lineares. . . . .	65
30	Agrupamento de sinais aplicado aos dados de uma válvula de bloqueio que apresentou dois tipos de danos. . . . .	66
31	Exemplos de diversos algoritmos de redução da dimensionalidade. . . . .	67

32	Problemas de <i>Overfitted</i> e <i>Underfitted</i> aos dados, muitas vezes estão associados a quantidade de características ( <i>features</i> ) usadas durante o treino. Logo uma redução na dimensionalidade é aplicada. . . . .	68
33	Ilustração simplificada do funcionamento do PCA (Análise da Componente Principal) na redução da dimensionalidade dos dados. O PCA identifica os eixos que capturam a maior variância nos dados, permitindo uma representação mais compacta das informações originais. . . . .	69
34	Representação de um neurônio biológico (esquerda) e um artificial (direita). . . .	69
35	Funções de ativação utilizadas em ANNs ( <i>deep learning</i> ). . . . .	71
36	Unidade de memória de uma LSTM . . . . .	74
37	Fluxograma aplicado ao conjunto de dados. . . . .	78
38	Relação entre o erro do treino e teste. . . . .	79
39	Conceito do <i>RUL</i> juntamente com os limites máximos de operação e o momento da falha. . . . .	82
40	<i>RUL</i> representado pela função <i>Piece-Wise</i> . . . . .	83
41	Metodologias para os cálculos de <i>RUL</i> . Em vermelho, a metodologia aplicada nesta tese, sendo Redes Neurais, pertencentes ao grupo abordado por <i>Data Driven</i> . . . . .	83
42	Testes de vedação realizados antes e após os testes cíclicos. . . . .	85
43	Esquemático do teste executado nos testes cíclicos. . . . .	86
44	Detalhes da ESDV e da Manta Térmica utilizada. . . . .	87
45	Sinais gerados durante os testes e sem o processamento. O eixo y no lado da esquerda, representa a pressão no atuador, medidos em Bar. Já o eixo t da direita, representa os valores de Torque, medidos em N.m. . . . .	88
46	Demonstração da interface gráfica desenvolvida pelo autor para realizar a identificação, marcação manual e armazenamento dos KPs (A2, A3, A4 e A5) presente em cada um dos 323 ciclos, ou eventos, nas assinaturas pressões abordadas neste trabalho. Pacote PyQt5, linguagem Python . . . . .	89
47	Tendência temporal, medidos em ciclos, de cada <i>Key Point</i> extraído das assinaturas de pressão da válvula ESDV durante os ensaios cíclicos. . . . .	90
48	Tendência de cada DI de pressão da ESDV. . . . .	92
49	Intervalo percentual dos dados respeitando as distribuições do segundo momento estatístico, $\sigma$ . . . . .	94
50	Fluxograma desta tese aplicado nas abordagens de: regressão dos <i>Key Points</i> , classificação de dano usando dados reais e sintéticos e cálculo do <i>Remaining Useful Life</i> ( <i>RUL</i> ). Todos têm em comum o uso dos mesmo algoritmos de processamento de sinais. . . . .	97
51	Vista dos defeitos encontrados na sede ao lado montante da válvula ESDV. . . .	99
52	Gráfico mostra o comportamento do coeficiente de torque ( $y_1$ ) e pressões na montante e jusante ( $y_2$ ) da válvula em função das porcentagens de abertura ( $x$ ). Percebe-se que o coeficiente de Torque tende a aumentar no momento do <i>Crack-Open</i> . . . . .	100
53	Histograma dos KPs a fim de identificar um comportamento bi-modal relacionado com dois estados: normais e degradados da ESDV em estudo. . . . .	102
(a)	Histograma <i>Key Point</i> A2 . . . . .	102
(b)	Histograma <i>Key Point</i> A3 . . . . .	102
(c)	Histograma <i>Key Point</i> A4 . . . . .	102
(d)	Histograma <i>Key Point</i> A5 . . . . .	102

54	Identificação da mudança de comportamento através da aplicação de <i>Principal Component Analysis</i> (PCA) aos dados de assinatura. Notar o ciclo 190, através do círculo vermelho. . . . .	103
(a)	Assinaturas. . . . .	103
(b)	Assinaturas Após PCA. . . . .	103
55	Tendência temporal, por ciclos, de cada KP após a localização do ciclo onde o dano se iniciou. Nota-se que o KP A3 aparenta ser mais sensível ao dano, visto que foi o único que apresentou um comportamento estável antes do ciclo 190 e uma subida após este ciclo. . . . .	104
56	<i>Damage Index</i> (DIs) aplicados nos conjunto de dados resultantes dos dados de pressão. As linhas tracejadas em vermelho representam o dano. O eixo y esta normalizado entre 0 e 1. O eixo x representa os ciclos realizados durante os ensaios cíclicos. . . . .	105
57	<i>Damage Index Score Energy Phase</i> — DI 10 aplicados aos dados. Nota-se ele é capaz, mesmo com ruídos, de capturar um comportamento antes e após o ciclo 190. . . . .	105
58	<i>Remaining Useful Life</i> (RUL) curva para descrever o estado de degradação do equipamento. Foram utilizados uma curva <i>Piece-Wise</i> para capturar o estágio de degradações. . . . .	106
59	Aplicação de <i>Lag 1</i> nos dados para verificar qual os valores limites antes e após o dano, no ciclo 190. Isto será para estipular o <i>Threshold</i> na seleção das assinaturas sintéticas, sendo 0.4 para assinaturas sem defeitos (anteriores ao ciclo 190) e 1 para assinaturas com defeitos (posteriores ao ciclo 190). . . . .	107
60	Assinaturas Sintéticas geradas pelo método de Monte Carlo para os dados sem defeitos. . . . .	108
(a)	Monte Carlo. . . . .	108
(b)	Após Média Móvel. . . . .	108
(c)	Aplicação de Limite no Lag 1. . . . .	108
(d)	Assinaturas Sintéticas. . . . .	108
61	Assinaturas Sintéticas geradas pelo método de Monte Carlo para os dados sem defeitos. . . . .	109
(a)	Monte Carlo. . . . .	109
(b)	Média Móvel para suavizar. . . . .	109
(c)	Lag 1 para identificar limites. . . . .	109
(d)	Assinaturas Sintéticas. . . . .	109
62	Exemplos de assinaturas sintéticas geradas pelo método de Monte Carlo, tanto para os sinais sem defeito como para os sinais com defeito. . . . .	109
(a)	Assinaturas sem Dano. . . . .	109
(b)	Assinaturas com Dano. . . . .	109
63	Resultado da regressão do <i>Key Point A3</i> utilizando o algoritmo kNN. Os dados de entrada foram a assinatura de pressão. . . . .	110
(a)	kNN - Real x Real. . . . .	110
(b)	kNN - Sintético x Real. . . . .	110
64	Resultado da regressão do <i>Key Point A3</i> utilizando o algoritmo LR. Os dados de entrada foram a assinatura de pressão. . . . .	111
(a)	LR - Real x Real. . . . .	111
(b)	LR - Sintético x Real. . . . .	111
65	Resultado da regressão do <i>Key Point A3</i> utilizando o algoritmo GBC. Os dados de entrada foram a assinatura de pressão. . . . .	111

(a)	GBC - Real x Real. . . . .	111
(b)	GBC - Sintético x Real. . . . .	111
66	Resultado em disposição temporal (ciclos) da regressão do KP A3 usando o algoritmo GBC. . . . .	112
(a)	GBC - Real x Real. . . . .	112
(b)	GBC - Sintético x Real. . . . .	112
67	Resultado da classificação pelo <i>Key Point</i> usando os três algoritmos, kNN, LR e GBC. A linha azul representa o modelo kNN, a laranja o LR e o GBC é representado pela linha verde. Os resultados são demonstrados através da curva ROC. Os dados de entrada utilizados foram os KPs A3. . . . .	113
(a)	ROC - Real x Real. . . . .	113
(b)	ROC - Sintético x Real. . . . .	113
68	Resultado da classificação usando os três algoritmos (kNN, LR e GBC). Cada <i>boxplot</i> representa a todos os 28 resultados dos DIs. O eixo y representa o <i>score</i> final mensurado pela curva ROC. Os dados de entrada utilizados foram os DIs . . . . .	116
(a)	kNN - Real x Real. . . . .	116
(b)	kNN - Sintético x Real. . . . .	116
69	Um plot do tipo <i>boxplot</i> dos resultados separados das famílias de DIs. . . . .	116
(a)	DIs de Correlação. . . . .	116
(b)	DIs de Energia. . . . .	116
(c)	DIs de Amplitude. . . . .	116
70	Representação dos DIs de forma temporal (ciclos). . . . .	117
(a)	Cross Correlation. . . . .	117
(b)	Energy Ratio. . . . .	117
(c)	Energy Shared Normalizada. . . . .	117
71	Resultado da classificação usando os três algoritmos, kNN, LR e GBC com dados provenientes da assinatura de pressão. A linha azul representa o kNN, a laranja LR e o GBC é representado pela linha verde. Os resultados são demonstrados através da curva ROC. . . . .	118
(a)	ROC - Real x Real. . . . .	118
(b)	ROC - Sintético x Real. . . . .	118
72	Matriz de Confusão dos resultados do algoritmo GBC utilizando assinaturas de pressão como entrada na classificação dos danos. . . . .	119
(a)	Matriz de Confusão - Real x Real. . . . .	119
(b)	Matriz de Confusão - Sintético x Real. . . . .	119
73	Regressão do RUL para os algoritmos propostos. As entradas foram os sinais de assinatura e as saídas esperadas a Vida Remanescente da ESDV. . . . .	120
(a)	KNN. . . . .	120
(b)	LR. . . . .	120
(c)	GBR. . . . .	120
(d)	LSTM. . . . .	120
74	Erros residuais das previsões de RUL. . . . .	121
75	RUL nos eventos finais, onde a degradação da sede polimérica se inicia. . . . .	121
76	Configuração utilizada para realizar a contagem de bolhas, em caso de vazamento após o fim dos testes cíclicos. . . . .	137
77	Configuração utilizada para realizar os ensaios cíclicos. . . . .	139

78	Desmontagem da válvula após os testes cíclicos. . . . .	140
79	Loss da LSTM em função das Épocas. . . . .	141
80	Resultado da regressão utilizando o algoritmo kNN. Com o treinamento ocorrendo com os dados reais. Os dados de entrada foram o <i>Key Point A3</i> . . . . .	142
(a)	Real x Real. . . . .	142
(b)	Sintético x Real. . . . .	142
81	Resultado da regressão utilizando o algoritmo LR. Com o treinamento ocorrendo com os dados reais. Os dados de entrada foram o <i>Key Point A3</i> . . . . .	142
(a)	Real x Real. . . . .	142
(b)	Sintético x Real. . . . .	142
82	Resultado da classificação usando os <i>Damage Index</i> como entrada. O treino foi realizado com os dados sintéticos. . . . .	143
(a)	DIs de Correlação. . . . .	143
(b)	DIs de Energia. . . . .	143
(c)	DIs de Amplitude. . . . .	143

## LISTA DE TABELAS

1	Acidentes envolvendo a liberação de hidrocarbonetos em tubulações na última década. . . . .	35
2	Tipos de válvulas para diferentes aplicações. Adaptado de Gasparetto (2014); Mathias (2014). . . . .	40
3	Tamanhos máximos, em polegadas, para válvulas de esfera flutuante por classe. .	42
4	Propriedades melhoradas do PTFE obtidas por diferentes cargas. . . . .	46
5	Matriz de Confusão . . . . .	76
6	Funções para gerar os DIs. Parte 1. . . . .	80
7	Funções para gerar os DIs. Parte 2. . . . .	81
8	Dados da válvula e do atuador hidráulico. . . . .	85
9	Parâmetros utilizados para construir a <i>Long Short Term Memory</i> (LSTM). . . .	95
10	Razões entre os dados reais e sintéticos para os sinais com e sem a presença do dano. . . . .	110
11	Tabela com os resultados da curva ROC para todos os DIs. Resultados utilizando os dados Reais para treino e Reais para teste. . . . .	114
12	Tabela com os resultados da curva ROC para todos os DIs. Resultados utilizando os dados Sintéticos para treino e Reais para teste . . . . .	115

## LISTA DE ABREVIATURAS

ESDVs	<i>Emergency Shutdown Valves</i> (Válvula de Fechamento de Emergência)
KPs	<i>Key Points</i> (Pontos Notáveis ou chaves)
IA	<i>Intelligence Artificial</i> (Inteligência Artificial)
ML	<i>Machine Learning</i> (Aprendizado de Máquina)
RUL	<i>Remaining Useful Life</i> (Vida Útil Remanescente)
DI <sub>s</sub>	<i>Damage Index</i> (Índice de Dano)
CBM	<i>Condition Based Maintenance</i> (Manutenção Baseada na Condição)
PLEM	<i>Pipeline End Manifold</i>
ANM	Árvore de Natal Molhada
LDA	Lâmina d'água
SY	<i>Scotch-Yoke</i> (Garfo-Escocês)
DPE	Duplo Pistão Efeito
SPE	Simple Pistão Efeito
PTFE	Politetrafluoretileno
RPTFE	Reforçado Politetrafluoretileno
ABNT	Associação Brasileira de Normas Técnicas
ISO	Organização Internacional de Normalização
MEF	Método dos Elementos Finitos
LSTM	<i>Long Short Term Memory</i>
NDT	Técnicas não destrutivas
AE	Emissão Acústica
PCA	<i>Principal Component Analysis</i> (Análise das Componentes Principais)
ANN	<i>Artificial Neural Network</i> (Redes Neurais Artificiais)
RNN	<i>Recurrent Neural Network</i> (Redes Neurais Recorrentes)
PHM	<i>Prognostic Health Management</i> (Gerenciamento do Prognóstico de Saúde)
HI <sub>s</sub>	<i>Health Index</i> (Índice de Saúde)
MC	Monte Carlo
kNN	<i>k-Nearest Neighbour</i> (k-vizinho mais próximo)
LR	<i>Logistic Regression</i> (Regressão Logística)
GB	<i>Gradient Boosting</i>
MSE	<i>Mean Squared Error</i> (Erro Médio Quadrático)
AUC	<i>Area Under Curve</i> (Área sob a curva)

# SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	20
<b>1.1</b>	<b>Estrutura do trabalho</b>	20
<b>1.2</b>	<b>Introdução ao tema</b>	20
<b>1.3</b>	<b>Justificativa</b>	25
<b>1.4</b>	<b>Temas e objetivos</b>	26
<b>1.5</b>	<b>Contribuição</b>	27
<b>1.6</b>	<b>Limitações</b>	27
<b>2</b>	<b>REVISÃO BIBLIOGRÁFICA</b>	29
<b>2.1</b>	<b>Pesquisas e trabalhos correlatos</b>	29
<b>2.2</b>	<b>Válvulas de bloqueio e suas aplicações</b>	32
2.2.1	Sistemas de atuação	36
2.2.1.1	Atuador hidráulico	36
2.2.1.2	<i>Scotch-Yoke</i> simétrico e não-simétrico ( <i>Canted</i> )	37
2.2.2	Válvulas	39
2.2.2.1	Vedações do tipo SPE, DPE	43
2.2.2.2	Sedes poliméricas em PTFE e RPTFE	45
<b>2.3</b>	<b>Principais danos em válvulas de bloqueio</b>	46
<b>2.4</b>	<b>Normas para ensaios e qualificações em válvulas</b>	49
<b>2.5</b>	<b>Técnicas de monitoramento em válvulas de bloqueio</b>	51
2.5.1	Assinaturas	51
2.5.2	Pontos notáveis	53
<b>2.6</b>	<b>Estado da arte no monitoramento das válvulas de bloqueio</b>	56
2.6.1	Modelos matemáticos	59
<b>2.7</b>	<b>Processamento de sinais no monitoramento de válvulas</b>	61
2.7.1	Processamento por algoritmos de aprendizado de máquina	61
2.7.2	Algoritmos de classificação	63
2.7.3	Algoritmos de regressão linear	64
2.7.4	Algoritmos de agrupamento	65
2.7.5	Redução de dimensionalidade	66
2.7.6	Redes neurais artificiais	68
2.7.7	KAN - <i>Kolgomorov Arlond Network</i>	71
2.7.8	Series temporais	72
2.7.8.1	Long Short Term Memory - LSTM	73
2.7.9	Métricas aplicadas em algoritmos	74
2.7.9.1	MSE e MAE para Regressão	74
2.7.9.2	Curva ROC e <i>AUC Score</i> para classificação	75
2.7.9.3	Matriz de confusão para classificação dos algoritmos	76
2.7.10	Fluxograma para aplicação dos algoritmos de monitoramento	77
<b>2.8</b>	<b>Índices de Dano (<i>Damage Index</i>) - DIs</b>	79
<b>2.9</b>	<b>Vida útil remanescente - RUL</b>	80

<b>3</b>	<b>MATERIAIS E MÉTODOS</b>	84
<b>3.1</b>	<b>Testes vedações da válvula - estática</b>	84
<b>3.2</b>	<b>Testes cíclicos</b>	84
<b>3.3</b>	<b>Sinais gerados</b>	88
<b>3.4</b>	<b>Labels</b>	90
<b>3.5</b>	<b>Curva piecewise</b>	90
<b>3.6</b>	<b>DIs - <i>Damage Index</i></b>	91
<b>3.7</b>	<b>Monte Carlo para gerar os dados sintéticos</b>	93
3.7.1	Primeiro e segundo momento estatístico.	93
3.7.2	Medias móveis e diferenciação de ordem 1 (Lag 1)	93
3.7.3	Criação dos sinais sintéticos	94
<b>3.8</b>	<b>Algoritmos de monitoramento</b>	95
3.8.1	Arquitetura e otimização da LSTM - RUL	95
3.8.2	Arquitetura e otimização do kNN - LR - GB	95
<b>3.9</b>	<b>Fluxograma proposto — Entrada dos dados até a regressão e previsão do RUL</b>	96
<b>4</b>	<b>RESULTADOS E DISCUSSÕES</b>	98
<b>4.1</b>	<b>Análise da falha pela inspeção visual</b>	98
<b>4.2</b>	<b>Análise da falha pela inspeção dos dados</b>	101
4.2.1	Labels para a classificação e regressão (RUL)	101
4.2.1.1	KPs	103
4.2.1.2	DIs	104
4.2.1.3	RUL	106
4.2.2	Monte Carlo para dados sintéticos	106
4.2.3	Regressão para os KPs	110
4.2.4	Classificação de dano usando dados reais e sintéticos	112
4.2.4.1	Classificação pelo <i>Key Point</i>	112
4.2.4.2	Classificação pelos <i>Damage Index</i>	113
4.2.4.3	Classificação pelas assinaturas de pressão	117
4.2.5	Calculo da vida útil remanescente - RUL	119
<b>5</b>	<b>CONCLUSÕES</b>	122
<b>6</b>	<b>SUGESTÕES PARA TRABALHOS FUTUROS</b>	124
	<b>REFERÊNCIAS</b>	125
<b>APÊNDICE A</b>	<b>PROCEDIMENTO PARA VERIFICAR VAZAMENTOS</b>	137
<b>APÊNDICE B</b>	<b>ETAPAS PARA GERAR OS CICLOS</b>	138
<b>APÊNDICE C</b>	<b>DESMONTAGEM E MEDIÇÃO DOS COMPONENTES</b>	140
<b>APÊNDICE D</b>	<b>LOSS DA LSTM</b>	141
<b>APÊNDICE E</b>	<b>DISPOSIÇÃO TEMPORAL DAS REGRESSÕES</b>	142
<b>APÊNDICE F</b>	<b>BOXPLOT DAS FAMILIAS DE DIS - SINTÉTICO X REAL</b>	143

# 1 INTRODUÇÃO

Este capítulo se propõe a mostrar a estrutura do estudo, apresentando uma introdução breve sobre o tema, a justificativa para este trabalho, os objetivos a serem alcançados, a contribuição proposta pelo estudo e por fim, as limitações desta tese.

## 1.1 Estrutura do trabalho

Esta tese foi desenvolvida conforme a seguinte estrutura: após a introdução do tema e a apresentação dos objetivos deste trabalho, é trazida a revisão bibliográfica, onde será fornecido toda a base de conhecimento cobrindo os assuntos abordados neste trabalho, como os detalhes sobre as válvulas de segurança, suas aplicações e os principais danos, bem como o estado da arte no monitoramento destes ativos. Também serão apresentados tópicos relacionados ao uso potencial de algoritmos de processamento de sinais quanto ao monitoramento de válvulas de bloqueio e a limitação imposta pelo banco de dados no uso de tais algoritmos. As métricas utilizadas para avaliar os algoritmos que serão implementados aos dados das válvulas serão explicadas. Por fim, na revisão bibliográfica, será explanado o conceito de Vida Útil Remanescente juntamente com o conceito de Índice de Danos.

Após esta etapa, será mostrado os materiais e métodos utilizados para desenvolver os testes cíclicos, o processamento dos dados, a criação de sinais sintéticos e os parâmetros de cada algoritmo.

A etapa posterior é caracterizada pela seção de Resultados e Discussões, onde será exibido os resultados dos algoritmos de classificação e regressão, juntamente com o cálculo de vida útil remanescente por redes neurais.

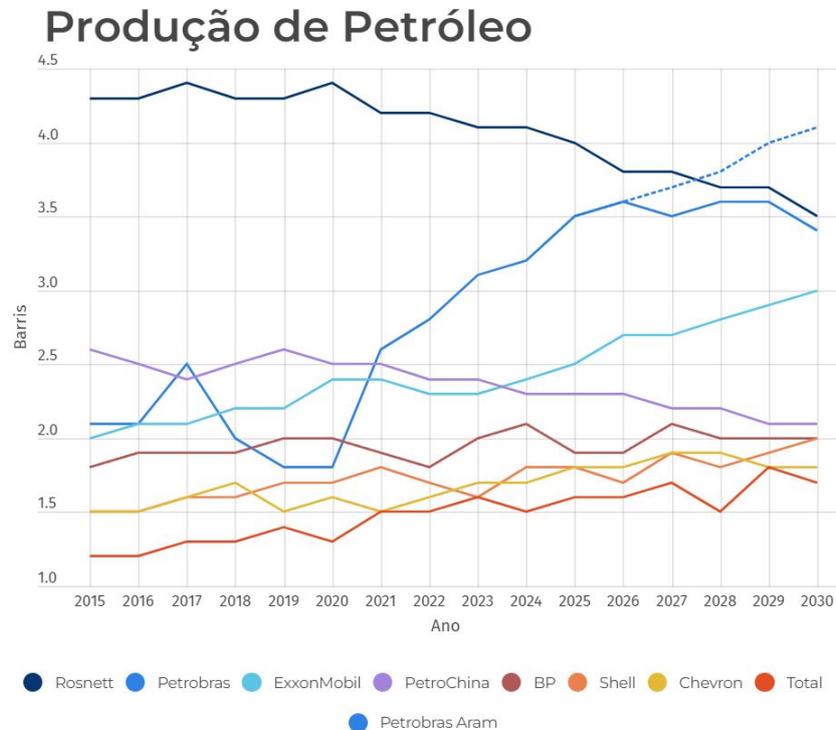
Por fim, segue-se com as conclusões resultantes deste estudo seguidas das sugestões para os trabalhos futuros.

## 1.2 Introdução ao tema

Conforme apontado pela Agência Internacional de Energia, a demanda global por energia está prevista para aumentar em seis por cento no período entre 2022 e 2028, chegando a alcançar 105,7 milhões de barris diários. Além disso, um estudo realizado pela *Rystad Energy* analisou as projeções de produção das principais empresas de extração de petróleo até 2030, onde é indicado um aumento no setor (Energy, 2023). É notável que todas as empresas estudadas, com exceção da PetroChina, preveem um aumento na produção diária de barris até 2030, como demonstrado na Fig. 1. A empresa brasileira Petrobras, ocupa a segunda posição, ficando apenas atrás da empresa *Rosnett*. Entretanto, o mesmo estudo sugere que após as descobertas no campo de Aram, a Petrobras poderá superar a *Rosnett* e assumir a liderança global até 2030 conforme a linha pontilhada na Fig. 1. Este aumento de

produção exigirá melhorias em toda a cadeia de produção e gestão de ativos que envolve as operações *offshore* e *onshore* da indústria brasileira (Petersohn, 2019).

Figura 1: Projeção de barris de petróleo até 2030 para as maiores produtoras do mundo.



Fonte: Adaptada de (Energy, 2023).

Para a gestão de ativos, uma das abordagens mais utilizadas pelas companhias é a chamada manutenção corretiva, que ocorre após o ativo apresentar a falha e a equipe de manutenção intervir para a correção. Este tipo de manutenção é inviável, uma vez que ocasiona paradas de produção, resultando na inoperância dos equipamentos até a finalização do serviço, levando, por fim, a custos financeiros elevados. Uma solução é aplicar a manutenção preditiva, onde sensores instalados em locais estratégicos do ativo, capturam informações referentes a sua operação. Após os processamentos e prognósticos dos dados, métricas e limites podem ser definidos para identificar um comportamento que poderá levar a falha do ativo (Prajapati et al., 2012).

Uma das técnicas utilizadas para realizar o prognóstico de falha de um ativo, é o cálculo de vida restante do equipamento, a chamada Vida Útil Remanescente (*Remaining Useful Life - RUL*) (Si et al., 2011). Este conceito está dentro da chamada Manutenção Baseada na Condição (em inglês *Condition-Based Maintenance - CBM*). A aplicação do RUL através da CBM, resultará em um tempo de planejamento maior para a equipe de manutenção, diminuindo, então, o tempo de execução, não impactando significativamente a cadeia de produção quando um componente se aproxima da falha (Prajapati et al., 2012; Ferreira and Gonçalves, 2022).

Dentro desta cadeia, o transporte dos fluidos do local de produção até as instalações de processamento e distribuição, são realizados pelas tubulações. Para garantir a integridade desse

sistema, especialmente em casos de ruptura ou falha na linha de tubulação, são instaladas válvulas de bloqueio, conhecidas também como válvulas de fechamento de emergência. No ambiente submarino, estas válvulas são conhecidas como *Emergency Shutdown Valve*, ou ESDVs.

Tais válvulas representam componentes essenciais em várias indústrias, incluindo Petróleo e Gás, *subsea*, química, petroquímica e nuclear. Esses ativos são compostos por um atuador e uma válvula, sendo que o atuador desempenha a função de controlar os movimentos de abertura e fechamento. Normalmente, esse controle é realizado por meio de sistemas hidráulicos, embora também possam utilizar sistemas pneumáticos ou elétricos. Quanto à válvula, esta pode assumir diferentes configurações, como válvulas do tipo esfera, gaveta ou borboleta (Teles, 2020; Gouveia, 2018).

Destacando sua importância, as válvulas de bloqueio têm aplicação notável no contexto *subsea*, especialmente na exploração de petróleo em águas profundas. Nessas operações, as reservas de petróleo estão localizadas em depósitos abaixo da superfície marinha. Para viabilizar a extração, uma série de equipamentos são empregados, incluindo umbilicais, sistemas PLEM (Pipeline End Manifold), *manifolds* e a Árvore de Natal Molhada (ANM), como mencionado por Bai em seu estudo (Bai and Bai, 2018).

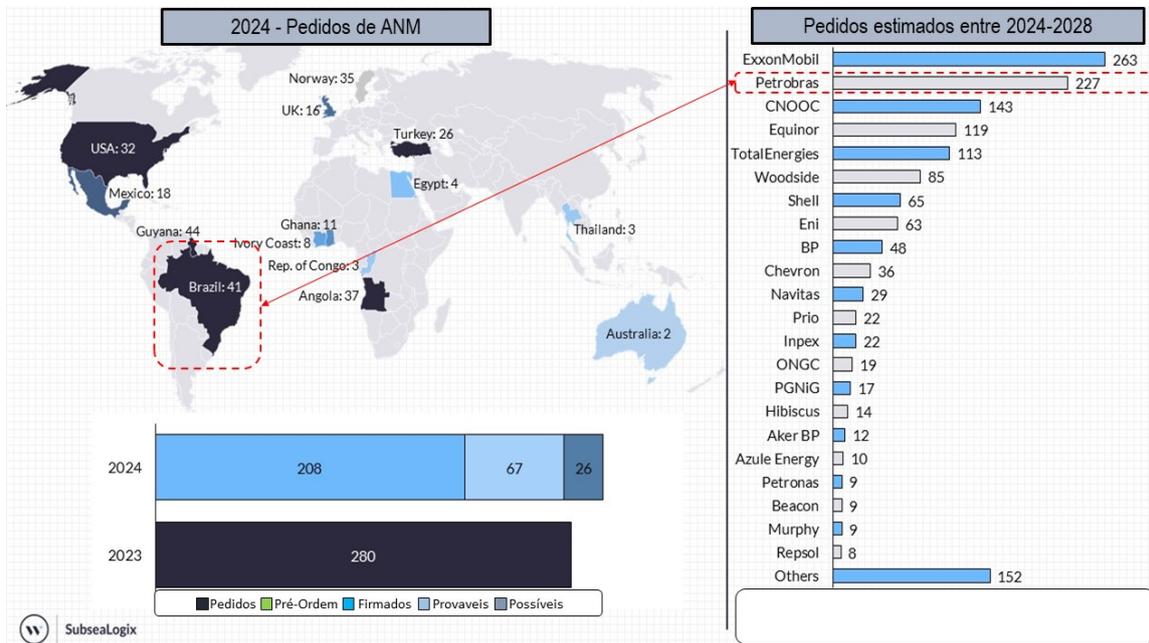
As ANMs, localizadas na cabeça do poço submarino, desempenham um papel crucial em toda a vida útil do poço, sendo que, dentre suas funções, pode-se destacar o controle da produção de petróleo e gás, regular a pressão dos poços submarinos, isolar o poço em caso de emergência, permitir a instalação e remoção de equipamentos submarinos e direcionar e controlar o fluxo de hidrocarbonetos em direção à superfície, através das válvulas que também realizam a introdução de CO<sub>2</sub> e água no poço. Esse controle é executado por meio de várias ESDVs estrategicamente posicionadas na sua estrutura (Bai and Bai, 2018).

Além de sua função primordial de direcionamento de fluxo, as válvulas de bloqueio desempenham um papel crítico em emergências, sendo responsáveis por interromper o fluxo de derivados de petróleo em caso de incidentes, assim como o fazem nas tubulações, também exercem este papel nos ambientes *subsea*, principalmente ligadas aos usos das ANMs. Para cada ANM, existirão algumas válvulas de segurança instaladas na sua estrutura, elevando o número destes equipamentos em uso e também, demandando metodologias que elevem a confiabilidade associada ao monitoramento de tais ativos (Cai et al., 2021; Bai and Bai, 2018; ?).

No contexto *subsea*, um levantamento realizado pelo *Westwood Global Energy Group* prevê que a Petrobras encomendará aproximadamente 227 novas ANMs entre 2024 e 2028 para instalação em seus campos submarinos, como evidenciado na Fig. 2 (Westwood, 2023). Esse dado destaca a relevância contínua das válvulas em operações *subsea* e a demanda crescente por esses dispositivos em ambientes desafiadores de exploração de petróleo em alto mar.

Porém, as válvulas são aplicadas em vários setores das indústrias, não ficando ligada somente ao ambiente *subsea*, como, por exemplo, as refinarias. A Fig. 3 ilustra dois cenários distintos nos quais estes equipamentos desempenham um papel fundamental, um em ambiente *onshore*, onde o equipamento está posicionado entre as tubulações e servem como barreira de contenção em casos

Figura 2: Estimativa de novas ANM novas entre 2024 e 2028. Cada ANM contém algumas válvulas de bloqueio para garantirem a operação segura que envolve a extração e transporte dos fluidos advindos dos poços submarinos.



Fonte: Adaptada de (Westwood, 2023).

emergenciais visto na Fig.3a. A outra aplicação está ilustrada na Fig. 3b, onde é mostrada o equipamento em ambiente *offshore*, onde a válvula de bloqueio (ESDV) está montada em uma ANM. Em ambos os casos, as válvulas são vitais para controlar e impedir o fluxo de hidrocarbonetos inflamáveis.

Com o uso contínuo das válvulas de fechamento de emergência pelas indústrias, a confiabilidade e disponibilidade destes equipamentos durante sua operação são de suma importância. Por isso, é imperativo desenvolver estratégias de monitoramento e acompanhamento para garantir seu desempenho ideal, seja em ambiente *onshore* ou *offshore*.

No entanto, estes equipamentos são compostos por uma série de subcomponentes, incluindo pistão, molas, mecanismos do tipo "Scotch-Yoke", compensadores de pressão, hastes, vedações, o-rings, porta-sedes e obturadores. Cada um destes elementos está sujeito a falhas que podem levar à indisponibilidade do equipamento quando mais necessário. Compreender como esses subcomponentes degradam e afetam o funcionamento das válvulas representa um desafio significativo. Porém, pode-se desenvolver metodologias que acompanham a integridade do equipamento na totalidade, criando métricas e métodos de operações aceitáveis.

Portanto, o desenvolvimento destes métodos e técnicas de análise torna-se essencial para identificar a possível causa das falhas e permitir a antecipação e programação de paradas para manutenção preventiva, evitando assim perdas financeiras decorrentes de manutenções corretivas.

Uma abordagem eficaz seria o monitoramento da válvula durante sua operação e acompanhando

Figura 3: Dois exemplos distintos do uso de ESDV, onde uma se encontra instalada em uma planta *onshore* e a outra em um ambiente *offshore*.

(a) Válvula instalada em uma tubulação.



(b) Válvula (ESDV) instalada em uma ANM.



Fonte: Adaptada de (InstrumentationTools) e (HartEnergy).

a sua desmontagem para correlacionar os sinais e as degradações físicas, porém isto nem sempre é possível. Portanto, existe a possibilidade somente de utilizar os sinais gerados durante suas operações de abertura e fechamento. Aproveitando o movimento natural do equipamento, é possível adquirir esses sinais e desenvolver conclusões sobre o seu funcionamento. Sensores de pressão instalados no atuador, juntamente com transdutores de torque e sensores de posições de ângulos nas válvulas, podem ser utilizados para capturar os sinais, que podem ser posteriormente processados (Teles et al., 2020; de Gouveia et al., 2024).

Além disto, sensores de pressão na montante e jusante da válvula, também podem extrair padrões de funcionamento que poderão revelar falhas através do processamento dos sinais gerados (Teles, 2020).

Um destes processamentos resulta na extração de assinaturas, as quais são sinais de pressão e torque que resumem todo o esforço necessário para vencer os atritos estáticos e dinâmicos no equipamento, promovendo então seu movimento e operação.

As assinaturas retornam informações relevantes das válvulas, onde são obtidas e utilizadas qualitativamente e quantitativamente para determinar o grau de desgaste desses equipamentos. Além do método pela assinatura, existem ainda processamento baseado nos Pontos Notáveis (em inglês *Key Points* KPs) que podem ser aplicados nas válvulas de bloqueio (Euthymiou, 2002).

Porém, esta aplicação, requer um profissional altamente treinado para reconhecer, manualmente, cada um destes KPs na assinatura, além de demandar um tempo considerável quando vários eventos da válvula se acumulam ao longo do tempo. Outra opção seria a aplicação de técnicas de monitoramento, oriundas de outras áreas do conhecimento, como, por exemplo, os Índices de Dano (*Damage Index* (DIs)) extensamente aplicados na saúde estrutural de ativos (em *Structural Health Monitoring*

(SHM)) (Silva, 2021; Lizé, 2018).

Estes DIs possuem um potencial para serem aplicados aos sinais das ESDVs a fim de extrair o comportamento do equipamento, e ilustrá-los por um valor escalar.

Além de todas as metodologias, citadas, pode-se ainda fazer o uso e obter a vantagem dos algoritmos de *Machine Learning* (ML) para se automatizar as análises, visto que seu uso aumenta em todas as áreas do conhecimento (Atif Qureshi et al., 2018; El Naqa and Murphy, 2015; Yazdi et al., 2022; Zhang et al., 2017)

Porém, muitas destas aplicações, demandam um extenso banco de dados, com sinais de operação de várias válvulas, com diversos modos de falhas, o que pode levar a dificuldade de aplicar os pressupostos acima citados nestes equipamentos. Isto se dá, pois a aplicação de soluções em ML envolvem um banco de dados com poder de generalizar outras válvulas, apresentando ainda certas características como *Independent and Identically Distributed* (discutida na Sec. 2.7.1 ), trazendo desafios extras em proporcionar soluções neste campo do conhecimento (El Naqa and Murphy, 2015).

Com isto, outra oportunidade surge, com relação ao desenvolvimento de sinais chamados de “sintéticos”.

Tal abordagem, pode capturar características estatísticas dos dados originais e utilizar estes dados como entrada para se obter sinais novos, que mantenham o padrão estatístico anterior. O resultado disto, é o potencial aumento do banco de dados, sendo muitas vezes escassos, permitindo a implementação eventualmente das técnicas mencionadas, embora limitadas, pois o modo de falha ainda continuara o mesmo, sendo que somente a quantidade de ciclos ou eventos serão ampliadas.

É importante observar que os poucos estudos publicados até o momento sobre a análise de sinais de válvulas de bloqueio com fechamento de emergência, sejam pela técnica dos KPs ou pela assinatura de pressão, foram conduzidos manualmente, sem a aplicação de técnicas de automatização, exigindo a intervenção de operadores altamente treinados e especializados na área. No entanto, com os avanços dos algoritmos de processamento de sinais, há uma crescente demanda por análises automáticas que podem trazer vantagens significativas para o monitoramento desses ativos, dando mais assertividade aos diagnósticos e precisão no reconhecimento de evento relacionado a danos nas válvulas de bloqueio.

### 1.3 Justificativa

A justificativa deste trabalho se dá pela possibilidade de utilizar técnicas com alto poder de abstração e reconhecimento de padrões (falhas) nas válvulas de bloqueio, pois usualmente, as análises atuais se desenvolvem de maneira manual, sendo totalmente dependentes de um operador. Logo a implementação de tais técnicas, como os algoritmos de processamento de sinais, podem automatizar o reconhecimento destes padrões, auxiliando no monitoramento de válvulas de emergências e diminuindo o impacto do operador além do tempo de resposta na identificação de falhas através dos sinais coletados.

Somado a isto, existe a possibilidade de identificação de danos, bem como na localização

automática dos *Key Points* pelos algoritmos, que novamente irão melhorar o monitoramento das válvulas. Além disto, a estimativa da vida útil remanescente do ativo usando as redes neurais para se antever o início da falha se torna um campo promissor para ser analisado. Existe ainda a possibilidade de substituir o monitoramento através dos KPs pelos *Damage Index* (DIs) fornecendo uma técnica que demanda menos do operador humano. E por fim, a criação de sinais sintéticos, através do método estocástico de Monte Carlo, poderá expandir o banco de dados que, para este tipo de equipamento, é escasso e limitado, possibilitando a aplicação de técnicas de monitoramento.

## 1.4 Temas e objetivos

Este trabalho irá abordar o monitoramento através da análise de dados gerados por uma válvula de bloqueio do tipo esfera *trunnion*, usadas em indústrias de petróleo e gás, durante testes cíclicos. O processamento dos sinais será um dos temas, além da aplicação de algoritmos de monitoramento para realizar a classificação e regressão dos danos. Também será aplicado técnicas estatísticas, mais precisamente, de Monte Carlo, para gerar sinais sintéticos. Por fim, o cálculo de vida útil remanescente será abordado. Como objetivos, pode-se separá-los em 2 grupos: gerais e específicos.

- Avaliar o monitoramento da integridade de uma válvula de bloqueio, comparando as técnicas de:
  - *Key Points* (KPs)
  - *Damage Index* (DIs)
  - Assinatura de pressão
- Gerar sinais sintéticos, através do método de Monte Carlo, para expandir o banco de dados;
- Estimar o *Remaining Useful Life* (RUL) por algoritmos de redes neurais.

Com os objetivos específicos de:

- Verificar se os DIs podem substituir os KPs como estimador da condição da válvula de bloqueio;
- \*\* Avaliar o potencial de aplicação de três algoritmos na detecção de dano ocorrido na válvula de bloqueio;
- Aplicar as técnicas de regressão para automatizar a localização dos KPs;
- Avaliar a aplicação de redes neurais, LSTM, no cálculo do RUL;
- Verificar se os dados sintéticos, possuem informações suficientes para treinarem um algoritmo de classificação de dano;

\*\*A aplicação dos algoritmos de detecção de dano para monitorar a integridade da válvula, será desenvolvida através dos algoritmos da área do conhecimento denominada *Machine Learning*, porém, o autor destacará as limitações imposta pelo banco de dados desta tese no uso de soluções puramente de *Machine Learning* (Ver Sec. 2.7.1). Portanto, a aplicação também está relacionado ao potencial do uso de tais algoritmos aos sinais gerados durante testes cíclicos de uma válvula de segurança.

## 1.5 Contribuição

No campo do monitoramento de válvulas de bloqueio, a utilização atual dos *Key Points* (KPs) é realizada de forma totalmente manual e depende de um operador altamente especializado. O estudo sobre a aplicação de algoritmos de processamento de sinais para automatizar a localização dos KPs pode melhorar o monitoramento e aumentar a assertividade na identificação de eventos críticos associados a defeitos nas válvulas.

A utilização de *Damage Index* como estimador da condição operacional do equipamento também será analisada, podendo resultar em uma alternativa ao uso convencional dos KPs. Além disso, a tarefa de classificação de danos pode auxiliar na localização de degradações nas válvulas. Outro ponto de contribuição será a avaliação da criação de sinais sintéticos, visando expandir o banco de dados de uma válvula de emergência, para então verificar se os algoritmos podem ser treinados exclusivamente com esses sinais sintéticos.

Também será avaliado o uso de algoritmos de redes neurais para estimar a vida útil remanescente poderá definir o tempo de operação do ativo de maneira mais precisa, reduzindo custos e intervenções. Por fim, o uso de algoritmos ligados a *Machine Learning* em válvulas de bloqueio, embora limitado pelo banco de dados, poderá ser avaliado de maneira mais profunda em estudos posteriores a partir da implementação inicial aplicada nesta tese.

## 1.6 Limitações

Esta tese possui algumas limitações em relação ao uso de alguns termos, também com relação ao banco de dados e ao uso dos algoritmos de redes neurais.

Em relação ao termo válvula de bloqueio, em aplicações *subsea*, tal válvula recebe a nomenclatura de (*Emergency Shutdown Valve* - ESDV). Porém, a válvula de bloqueio utilizada nesta tese, apesar de ser construída conforme uma ESDV, principalmente com relação ao funcionamento do atuador hidráulico (retorno por mola - *Fail Safe Close, Scotch-Yoke*), se difere em alguns aspectos, como, por exemplo, as ESDV possuem vedações das sedes do tipo *Double Piston Effect*, a desta tese possui vedações tipo *Single Piston Effect*, as ESDV normalmente utilizam materiais nobres como Inconel 625 e 718, a desta tese usou aço carbono (WCB) para o corpo da válvula e aço inoxidável martensítico 13Cr (CA15) para os componentes internos. Nas ESDVs os materiais das sedes costumam ser metal x metal, na válvula desta tese se utilizou PTFE com carga de reforço com carbono e grafite. Além disto, as normas e padrões construtivos são diferentes.

Portanto, a válvula de bloqueio utilizada nesta tese é voltada para aplicações *onshore* (refinarias e plataformas) e o sistema de atuação, com configurações semelhantes a uma ESDV, para aplicações *offshore*. Para as técnicas de monitoramento utilizadas nesta tese, elas podem ser aplicadas em ambos os cenários, *offshore* ou *onshore*, pois o processamento de sinais se concentra nos níveis de pressão gerados na câmara do atuador, que está presente em ambos os cenários.

Quanto ao termo utilizado para descrever o conjunto válvula e atuador hidráulico, esta tese utilizará o termo válvula de bloqueio, por vezes realizando a intercambialidade entre os termos válvula de segurança, válvula de emergência e ESDV como sinônimos para melhorar a leitura da tese, porém, com a ressalva mencionada anteriormente sobre as diferenças entre a válvula *offshore* ou *onshore*.

Com relação ao termo algoritmos de processamento de sinais, este termo será utilizado para descrever a aplicação dos códigos matemáticos utilizados para abstrair e reconhecer os padrões de falhas na válvula de bloqueio. Embora, tais códigos estejam ligados ao campo de aprendizado de máquina, (*Machine Learning* - ML), o banco de dados utilizado nesta tese não preenche os requisitos para os algoritmos apresentarem resultados de aprendizado de máquina (ver Sec. 2.7.1).

Isto se deve ao fato que o banco de dados proveniente dos ensaios não possui a capacidade de generalizar o comportamento de diversas válvulas de bloqueio, o que só seria possível caso várias válvulas de diferentes fabricantes fossem testadas conjuntamente, obtendo-se, assim, diversos modos de falha de diferentes naturezas.

Com a impossibilidade de realizar tais ensaios, seja pela falta de fabricantes dispostos a disponibilizar válvulas de emergências para este estudo, seja pela impossibilidade de simular e obter uma ampla gama de modos de falha, o presente trabalho poderá utilizar o termo *Machine Learning* no decorrer desta tese, mas não como uma resolução de problema propriamente dentro do campo de ML.

O uso de tais algoritmos de ML nesta tese se dará de maneira eventual, porém, sem a possibilidade de validação concreta, sendo este, um estudo preliminar. Portanto, estas análises serão uma avaliação inicial sobre o potencial destes algoritmos no monitoramento de válvulas de bloqueio. Caso, o banco de dados seja ampliando de modo a possuir características que permitam o uso total destes algoritmos, poder-se-ia aplicar esta mesma metodologia e analisar os resultados no domínio de ML.

Por fim, o uso dos algoritmos de redes neurais, mais precisamente as do tipo *Long Short Term Memory* (LSTM), será aplicado para realizar os cálculos de vida útil remanescente das válvulas de bloqueio. Neste trabalho, as LSTM serão mais direcionadas ao campo de problemas de regressão, visando implementar o estado da arte no cálculo da vida útil remanescente.

## 2 REVISÃO BIBLIOGRÁFICA

As próximas seções deste trabalho serão dedicadas a elucidar os conceitos fundamentais necessários para uma compreensão abrangente dos termos e princípios empregados nesta pesquisa. Desse modo, abordaremos detalhadamente as válvulas de bloqueio com fechamento de emergência e seu funcionamento, as normas relevantes que regem esses dispositivos, as técnicas de monitoramento em uso atualmente e, por fim, examinaremos o estado da arte na aplicação de técnicas de monitoramento às válvulas. Isso nos permitirá desenvolver uma visão abrangente e atualizada das práticas e tecnologias relacionadas a esses componentes críticos da indústria.

### 2.1 Pesquisas e trabalhos correlatos

Trabalhos sobre válvulas de bloqueio, também chamadas de válvulas de fechamento de emergência, sempre foram objetos de estudos, tanto da indústria como da academia. Portanto, uma breve descrição, em ordem cronológica, será apresentada a seguir, elucidando as principais publicações e alguns resultados alcançados neste tema.

Eriksen et al. (1992) apresentou o conceito, filosofia de *design*, testes e instalação de uma *Emergency Shutdown Valve* que foi alocada entre o campo de *Osenberg* e a plataforma *Oseberg C*, na Noruega, no ano de 1991. O estudo concluiu que a ESDV instalada próxima à plataforma *Oseberg C* poderia diminuir danos a plataforma em situações onde um *riser* pudesse se romper ocasionado princípios de incêndios.

Em 1993, Ouchet (1993) revelou que o entendimento dos mecanismos de falhas de válvulas na indústria de petróleo, era escasso. Além disto, o autor afirmou que dados históricos eram inadequados para estudos. Com isto, o autor propôs uma metodologia para modelar a confiabilidade de válvulas. Foi definido um modelo matemático de uma válvula de emergência do tipo gaveta, a qual o autor alimentou com curvas estatísticas para criar uma curva de probabilidade de falha.

Uma simulação numérica foi conduzida por Mahgerefteh et al. (1997) para analisar e simular a resposta dinâmica de uma ESDV durante o rompimento total de uma linha de gás pressurizada. O estudo analisou a eficácia da válvula de bloqueio ao conter metano em uma linha de 145 quilômetros, pressurizados em 133 bar.

Euthymíou (2001), publicou os resultados do seu estudo sobre uma metodologia para testes funcionais em válvulas submarinas. Neste trabalho, o autor desenvolveu a metodologia que irá realizar a coleta de dados durante os testes de homologação de projeto (PVT) e dos testes de aceitação em fábrica nos produtos (FAT). O autor utilizou ferramentas estatísticas para extrair a confiabilidade dos produtos. Ainda foram atingidos objetivos secundários, como o desenvolvimento dos critérios para aceitação nos testes atmosféricos e hiperbáricos.

Em 2002, foi apresentado o conceito de *Key Points*, ou Pontos Notáveis, presentes nos

sinais gerados durante os testes PVT e FAT. O monitoramento destes índices poderiam resumir o comportamento das válvulas submarinas (Euthymiou, 2002).

Carvalho (2007), apresentou uma metodologia que comparasse o desempenho das válvulas submetidas ao FAT com os valores encontrados no PVT. O autor utilizou uma análise estatística, conhecida como "análise da variância"(ANOVA), para determinar se uma válvula-produto é estatisticamente similar a outra válvula-produto dentro de um intervalo de confiança de 95%.

Já em 2011, Mashiba (2011), aprimorou os modelos matemáticos com o intuito de simular o comportamento estático de uma válvula gaveta de emergência, usada em ambiente *subsea*. O autor modelou a dinâmica do atuador, da válvula, da mola e do umbilical a fim de reproduzir os sinais gerados durante os testes de PVT e FAT. Neste estudo foram analisados a influência que parâmetros construtivos do equipamento exercem sobre o sinal conhecido como "assinatura de pressão". Além disto, o autor forneceu um diagrama com as principais falhas que ocorrem em válvulas submarinas de emergência, permitindo um mapeamento mais completo do conjunto válvula-atuador.

Em 2013, outro modelo matemático foi desenvolvido para estimar a evolução da probabilidade de falha em válvulas gavetas. Os parâmetros construtivos da válvula foram obtidos preferencialmente a partir da homologação do projeto com testes em protótipo, ou secundariamente, por testes tribológicos padronizados. O método de Monte Carlo foi então aplicado a fim de estimar a probabilidade de falha ao longo da vida do componente. Por fim, o trabalho consegue traçar uma curva com esta probabilidade de falha (Euthymiou, 2013).

Mnif et al. (2013) aplicou testes de abertura e fechamento em uma válvula esfera para determinar a mudança no coeficiente de atrito. O autor impôs 1200 ciclos ao equipamento, porém, não foram detalhados os sinais obtidos nem um processamento da evolução do coeficiente de atrito em função dos ciclos.

Gasparetto (2014), a fim de substituir as ligas metálicas de matérias nobres de alto custo, o autor analisou a substituição por carbono revestido nos componentes internos da válvula. De modo a validar a proposta, foram conduzidos testes de ciclagem e desempenho, impondo a válvula 1000 ciclos de abertura e fechamento, sendo o valor de torque continuamente monitorado. Ao fim dos testes, o autor confirmou apenas um desgaste uniforme nas vedações e superfície de vedação da esfera, o que não comprometeu a vedação das válvulas.

Teles (2015), desenvolveu e validou um projeto de válvula de bloqueio do tipo esfera para baixas emissões. Os testes foram realizados durante os ciclos de abertura e fechamento do equipamento, aplicando a máxima pressão de trabalho usando o gás hélio como fluido de teste. Além disto, o autor realizou a aquisição de sinais de torque durante os acionamentos da válvula.

Em 2016, Rossetto (2016), avaliou a integridade estrutural de uma válvula esfera, do tipo *trunnion*, através do método dos elementos finitos. Um dos objetivos analisados pelo autor, é o modo de falha por vazamento entre sede e esfera. Também é analisado a influência que as forças fluidos-dinâmicas, geradas pelo escoamento no interior da válvula, tem sobre os valores de torque, ocorrendo na abertura do obturador o valor máximo de torque.

Para melhorar o desempenho de válvula, a partir de melhorias no funcionamento mecânico das

válvulas *subsea*, T. (2018) avaliou conceitualmente a proposta de uma válvula *Gás Lift* utilizando ligas de memória de forma nas molas dos atuadores.

Um estudo sobre o torque de acionamento, foi conduzido por Argüello (2018), onde o autor conduziu testes de funcionamento de uma válvula esfera flutuante de bloqueio para aquisição da assinatura de torque. O autor desenvolveu um modelo em elementos finitos o qual foi calibrado com as assinaturas coletadas. Posteriormente, foram geradas mudanças na geometria modelada com o intuito de simular falhas no obturador e nas sedes. As respostas do torque obtidas pelo MEF, foram desenvolvidas para compor um banco de dados de sinais com falhas.

Em 2018, um trabalho aplicando técnicas de *Machine Learning* foi apresentado, onde os autores utilizaram os métodos supervisionados e os não-supervisionados aos dados de válvulas submarinas. A tentativa de descrever os estados saudáveis e não-saudáveis, no âmbito supervisionado, foi realizada através dos dados no domínio da frequência e do tempo, derivados do sinal bruto. No âmbito não-supervisionado, os autores aplicaram métricas como DTW (*Dynamic Time Warping*) para analisar o sinal bruto e verificar detecção de mudanças abruptas relacionados a falhas no equipamento (Atif Qureshi et al., 2018).

No trabalho de Romanik et al. (2019), o autor submeteu uma válvula a ciclos de abertura e fechamento, totalizando 1000 eventos, a fim de caracterizar 3 geometrias de vedações. A análise foi desenvolvida analisando os valores de torque necessários para promover a abertura e fechamento da válvula durante o desgaste do contato sede e obturador.

Em Teles (2020), submeteu uma válvula esfera de bloqueio a testes cíclicos em diferentes temperaturas. O autor impôs a válvula o máximo diferencial de pressão entre montante e jusante. Os dados coletados, foram os sinais de pressão e torque, sendo desenvolvidos, por fim, ambas as assinaturas. As análises usando o método dos Pontos Notáveis mostrou degradações nas válvulas durante os testes cíclicos, sendo o momento conhecido como *crack-open*, a região onde ocorrem as maiores deformações nas sedes poliméricas. O autor também detectou o momento onde a válvula perdeu sua capacidade de vedação, ao analisar o evento onde o diferencial de pressão montante x jusante, apresentou valor de zero. Além disto, foram conduzidas análises visuais do estado final das sedes poliméricas.

Na otimização das válvulas de bloqueio, existem trabalhos onde os autores estão buscando a eletrificação do atuador, a fim de diminuir o impacto de vazamento e aumentar a confiabilidade do sistema, principalmente quando tais ativos estão sendo operados em ambientes submarinos, onde qualquer intervenção é onerosa (Orth et al., 2021).

Com o avanço nos métodos computacionais, como a aplicação de algoritmos de aprendizado de máquinas, permitindo a análise de uma grande base de dados, aliado ao reconhecimento de padrões de comportamento associado a falhas, algumas publicações para detectar vazamento em válvulas através da técnica de emissão acústica também estão sendo publicadas (Liu et al., 2022, 2023).

Outro ponto que a indústria está buscando se aprimorar, no que diz respeito a otimização de funcionamento deste tipo de equipamento, é com relação ao desgaste entre as superfícies deslizantes do obturador e sede. Em uma válvula gaveta *subsea*, Teles et al. (2023), testou dois pares de contato

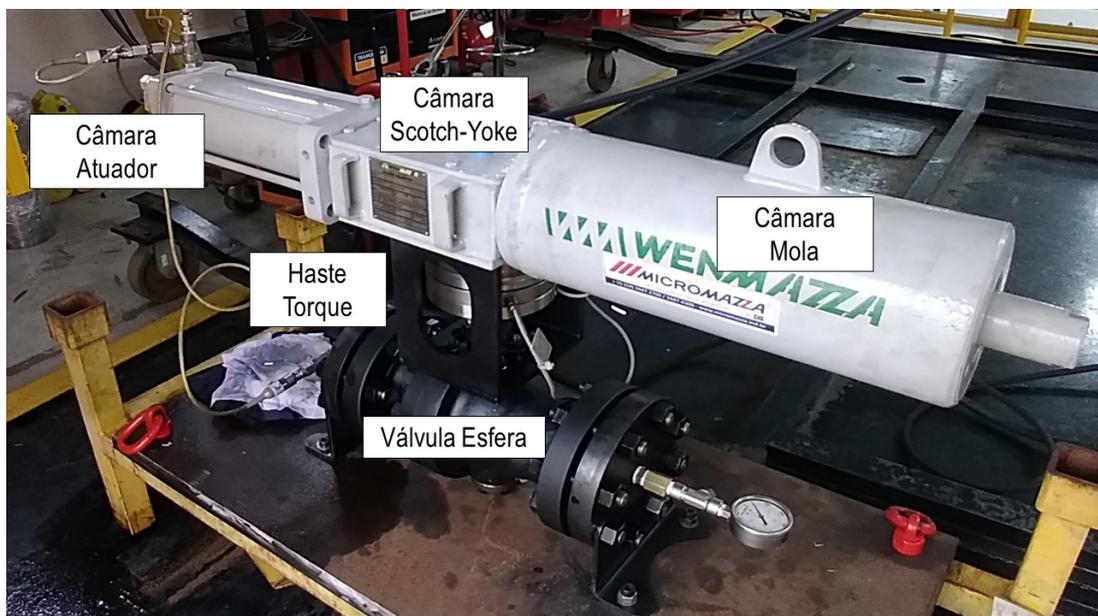
variando o processo de endurecimento superficial para verificar o desempenho de ambos.

## 2.2 Válvulas de bloqueio e suas aplicações

As válvulas de bloqueio desempenham um papel crucial em diversas indústrias, incluindo o setor de petróleo & gás, química, petroquímica e nuclear, independentemente de operarem em ambientes *on-shore* ou *off-shore*, como evidenciado em pesquisa anterior (Unnikrishnan et al., 2015).

A principal função desses dispositivos é interromper ou direcionar o fluxo de fluidos pressurizados em situações de emergências. O acionamento das válvulas de emergência pode ser realizado localmente ou remotamente, comumente por meio de sistemas hidráulicos. Um componente essencial deste conjunto de equipamento é o atuador, que pode operar por fonte elétrica, além da operação a base de fluidos pressurizados. Esse fluido fornece energia à face do pistão do atuador, que, por sua vez, transfere essa energia para a haste do atuador movendo-se de maneira linear. Ao passar pelo mecanismo "*Scotch-Yoke*" essa energia é convertida no torque necessário para acionar a válvula. Estes equipamentos podem apresentar variações em sua configuração, incluindo o tipo de válvula ou atuador empregado (Souza, 2019; Teles, 2020). A Fig. 4 exibe uma ESDV, bem como a localização dos mecanismos citados.

Figura 4: Exemplo de uma válvula de bloqueio com: acionamento por pistão (hidráulico) e retorno por mola (*Fail Safe Close*), sistema de *Scotch-Yoke* e válvula esfera (*Trunnion*).



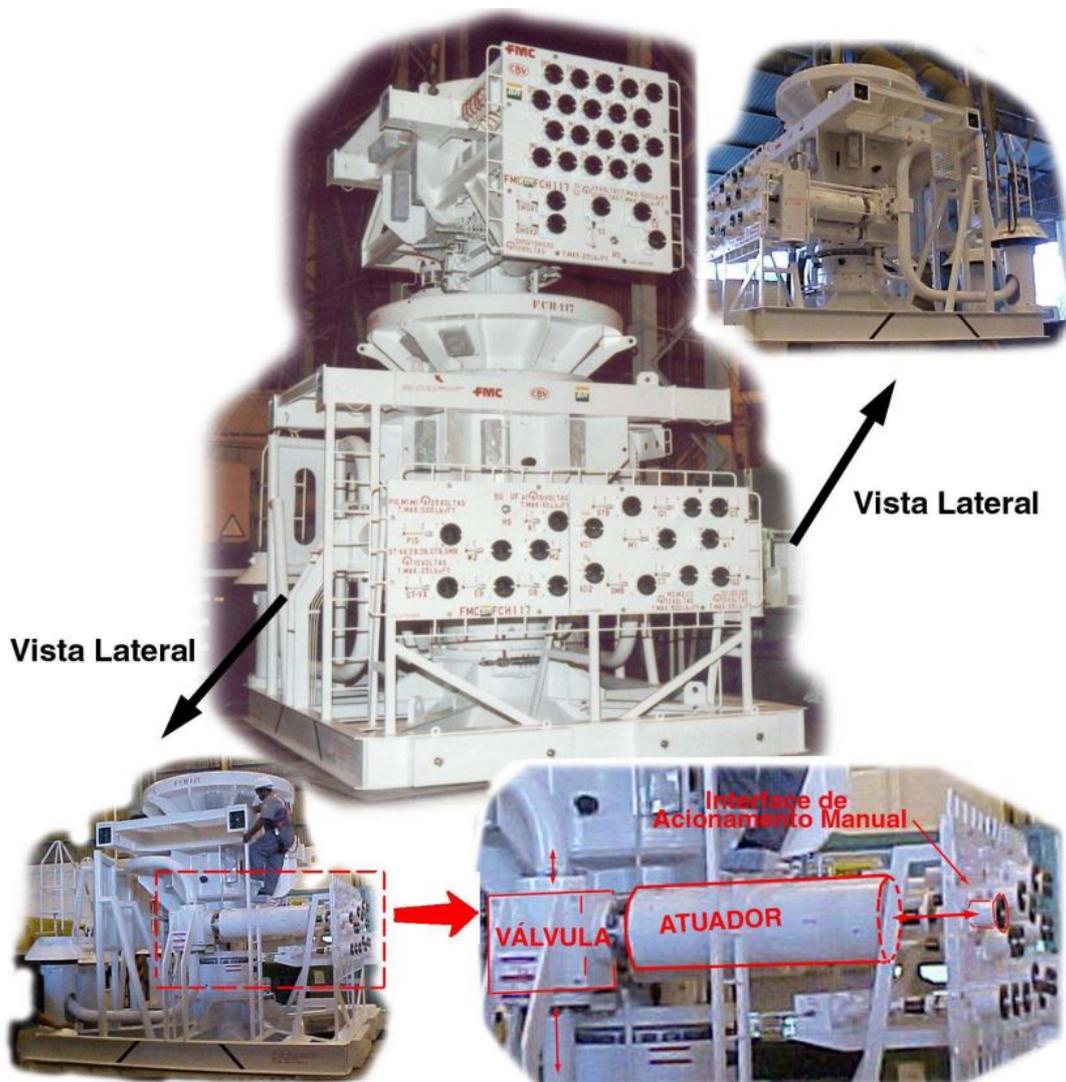
Fonte: Próprio Autor.

Nas aplicações de emergência, as válvulas gavetas também são amplamente utilizadas devido ao seu histórico estabelecido na indústria de petróleo. Essas válvulas são reconhecidas por sua confiabilidade, o que as torna dispositivos altamente confiáveis para o controle de fluxo em situações críticas. No entanto, as válvulas esfera têm ganhado destaque recentemente, especialmente

em operações subsea de águas profundas, conforme Fig. 5 mostra a válvula posicionada. Esse reconhecimento se deve principalmente à sua confiabilidade, impulsionada por avanços em vedações e revestimentos metálicos, como mencionado por Souza (Souza, 2019).

Esses desenvolvimentos têm contribuído para a crescente adoção das válvulas esfera em ambientes desafiadores de exploração de petróleo em águas profundas. Além disto, tais equipamentos, são aplicados em grande escala nas Árvores de Natal Molhada (ANM), que controlam e direcionam o escoamento do fluido resultante da exploração de petróleo em alto mar. As ESDVs podem assumir as funções que controlam a tubulação principal, a secundária, o anular e o *cross-over* nas ANMs (Bai and Bai, 2018).

Figura 5: Uma Árvore de Natal Molhada e a localização de uma válvula do tipo ESDV posicionada na estrutura.



Fonte: Adaptado de Euthymiou (2013).

No cenário mundial, o uso de ESDVs ganhou destaque a partir do ano de 1988, em decorrência do desastre ocorrido na plataforma *Piper Alpha*, conforme ilustrado na Fig. 6, localizada no Mar

do Norte (Paté-Cornell, 1993). Este trágico evento envolveu o bombeamento contínuo de fluidos pressurizados e inflamáveis para uma plataforma já em chamas.

Nesta situação, não havia dispositivos de segurança adequados para interromper o fornecimento desses fluidos. Essa falta de contenção resultou em um agravamento significativo do desastre e, lamentavelmente, na perda de 167 vidas de operadores que estavam na plataforma naquele dia (Paté-Cornell, 1993; Cullen, 1993).

Antes desse incidente, como observou McIntyre (1991), apenas sete válvulas de isolamento do tipo ESDV haviam sido instaladas nas fases de construção das plataformas *offshore*.

Contudo, após a tragédia, o Parlamento Britânico realizou uma investigação abrangente para identificar as causas do desastre e propor medidas para prevenir eventos semelhantes no futuro. O chefe dessa investigação foi o Lord Cullen, que, em 1993, publicou os resultados de sua apuração (Cullen, 1993).

O inquérito de Lord Cullen resultou em uma série de recomendações e medidas de segurança, destacando-se as chamadas “Safety Cases”. Esses casos de segurança propuseram a implementação de sistemas autônomos capazes de interromper o fornecimento e transporte de derivados inflamáveis do petróleo em situações de emergência.

Nesse contexto, as válvulas, com sua capacidade de fechamento automático por mola, emergiram como uma solução eficaz para interromper o fluxo de fluidos inflamáveis, especialmente em cenários semelhantes aos ocorridos na plataforma “*Piper Alpha*”.

Essa trágica lição resultou em mudanças significativas nas regulamentações de segurança e práticas industriais, levando a uma ampla adoção das ESDVs como um componente essencial para a prevenção de desastres em ambientes industriais que lidam com substâncias inflamáveis.

No entanto, é importante destacar que as válvulas de emergência com fechamento automático não estão restritas apenas as instalações offshore em alto mar. Elas também são amplamente utilizadas em áreas urbanas e densamente povoadas, especialmente em grandes centros urbanos.

Com estes usos é fundamental monitorar e prevenir desastres relacionados a rupturas de tubulações que podem resultar no vazamento de hidrocarbonetos presentes nos fluidos, causando incêndios, explosões e, lamentavelmente, perdas de vidas humanas e danos sociais significativos. A Tab. 1 apresenta alguns exemplos de desastres ocorridos a partir de 2010, destacando seus impactos. Esses incidentes reforçam a importância crítica das válvulas de bloqueio não apenas em ambientes *offshore*, mas também em contextos urbanos, onde sua função de interromper o fluxo de fluidos inflamáveis em situações de emergência, desempenham um papel fundamental na segurança pública e na proteção do meio ambiente. O monitoramento e a manutenção adequados dessas válvulas são essenciais para mitigar os riscos associados a tais desastres e garantir a segurança das comunidades circundantes (Yu et al., 2022).

É notável que a ocorrência desses acidentes ocorre raramente sem perdas de vidas humanas, e em alguns casos, como no México e na Nigéria, as perdas humanas foram particularmente significativas. Além das tragédias pessoais, esses eventos também resultam em perdas sociais, com pessoas perdendo suas moradias, e em prejuízos financeiros substanciais. Por exemplo, o desastre na Califórnia, em

Figura 6: Plataforma *Piper Alpha*, em 1988, em chamas. Mais tarde, o inquérito do Lord Cullen, apontaria que, dentre outras medidas, as ESDVs poderiam mitigar as consequências catastróficas deste desastre interrompendo o escoamento dos fluidos inflamáveis.



Fonte: Adaptado de Technology (2019).

Tabela 1: Acidentes envolvendo a liberação de hidrocarbonetos em tubulações na última década.

Data	Localização	Morte	Feridos	Outros
21/08/2020	Texas, USA	4	6	50 casas destruídas, 276.000 pessoas desabrigadas
15/03/2020	Lagos, Nigéria	23	25	-
01/08/2019	Kentucky, USA	1	5	-
18/01/2019	Hidalgo, México	137	10	-
13/09/2018	Massachusetts, USA	1	21	-
07/09/2018	Marshall County, USA	-	-	Liberação de \$437.250 de gás natural
25/05/2017	Colorado, USA	1	3	-
09/09/2010	Califórnia, USA	8	51	\$220 milhões em danos a propriedades

Fonte: Adaptado de Yu et al. (2022).

2010, resultou não apenas em oito mortes, mas também em prejuízos financeiros estimados em R\$220.000.000 devido ao vazamento de fluidos para a atmosfera.

Portanto, a presença de equipamentos capazes de interromper o fluxo de fluidos em situações de desastre é de importância fundamental para garantir a segurança tanto das pessoas quanto das operações em curso. Isso é válido tanto em ambientes altamente industriais, como o caso de uma plataforma em alto mar, como a "*Piper Alpha*" quanto em locais onde vidas humanas circulam diariamente (Yu et al., 2022).

Para alcançar esse objetivo, é essencial compreender os principais componentes que compõem as válvulas de bloqueio e como eles funcionam. Nas seções a seguir, serão apresentados esses componentes e seu funcionamento.

## 2.2.1 Sistemas de atuação

### 2.2.1.1 Atuador hidráulico

O sistema de atuação desempenha um papel fundamental na operação das válvulas de fechamento de emergência, por ser responsável por promover os movimentos necessários para abrir e fechar a válvula. Esse processo ocorre devido ao movimento de um pistão localizado no atuador. O movimento do pistão é linear, e dependendo do tipo de válvula em uso, pode ser convertido em movimento angular por meio de um sistema conhecido como *Scotch-Yoke* ou um sistema de pinhão e cremalheira.

A atuação do atuador pode ocorrer por meio de um fluido pressurizado, que exerce força sobre a área do pistão, deslocando-o. Além disso, a atuação também pode ser pneumática ou elétrica, dependendo das especificações da aplicação (Leon et al., 2023).

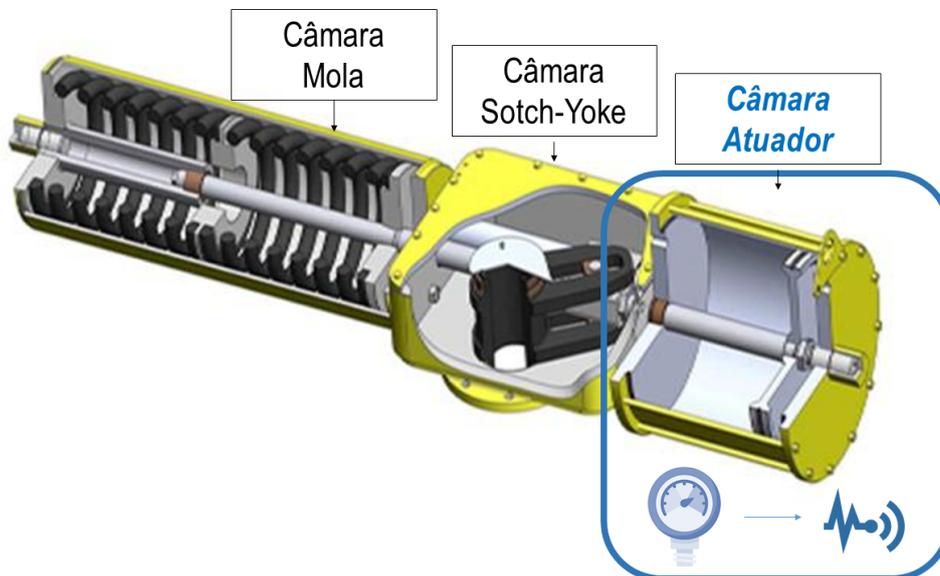
A Fig. 7 exibe um atuador em corte, dando ênfase nos mecanismos mais comuns encontrados nos atuadores do tipo hidráulico, aplicados em válvulas de segurança. A câmara do atuador, que está destacada em azul, é realizada a instrumentação, por meio de sensores, para realizar a aquisição dos valores de pressões necessários para promover a abertura e o fechamento da válvula. Como o atuador deve vencer a força que a mola exerce no sentido contrário e também a pressão que a montante exerce nas sedes do obturador, toda a pressão que o fluido hidráulico impõe na face do pistão, pode ser monitorada a fim de verificar a condição do equipamento, pois cada aumento de atrito, resultante de desgastes ou falhas, irá demandar um fornecimento maior de pressão ao equipamento.

Logo, a grandeza física relacionada a pressão na câmara do atuador, pode ser monitorada para verificar se estes aumentos ou diminuições estão correlacionadas com os mecanismos de desgastes que estão presentes em uma válvula de bloqueio do tipo esfera.

Nas aplicações offshore, especialmente nas aplicações *subsea*, a confiabilidade associada à atuação hidráulica torna os atuadores hidráulicos amplamente preferidos. A extremidade do atuador está conectada à câmara da mola, sendo comprimida quando energia é fornecida ao fluido na câmara do atuador. Essa compressão da mola é mantida apenas quando a energia é continuamente fornecida ao sistema. No entanto, se o fornecimento de energia for interrompido, a mola liberará a energia potencial elástica armazenada. Portanto, em cenários como o desastre na plataforma *Piper Alpha*, se uma ESDV com retorno por mola estivesse instalada nas tubulações conectadas à plataforma em chamas, o impacto do desastre poderia ter sido mitigado (Mashiba, 2011; Cullen, 1993).

No entanto, é importante observar que nem todas as aplicações requerem o fechamento da válvula em situações de emergência. Em alguns casos, é necessário liberar o fluido para evitar desastres. Nesses cenários, a lógica de montagem do atuador é invertida. A mola é comprimida para fechar a válvula, e quando o fornecimento de pressão para o atuador é cortado, a mola se expande, abrindo a válvula. Esse comportamento é conhecido como "Falha Segura" ou "*Fail Safe*." Todos os movimentos, sejam de abertura ou fechamento, são realizados por um mecanismo chamado *Scotch-Yoke*, responsável por converter o movimento linear da haste do pistão em movimentos de rotação que acionam o obturador, especialmente no caso de válvulas esféricas.

Figura 7: Apresentação de um atuador utilizado na abertura e fechamento de uma válvula de bloqueio. Na região em azul, o monitoramento do equipamento é realizado utilizando-se um sensor de pressão localizado na câmara do atuador.



Fonte: Adaptado de Mahmoodi and Bandpy (2018).

### 2.2.1.2 Scotch-Yoke *simétrico e não-simétrico (Canted)*

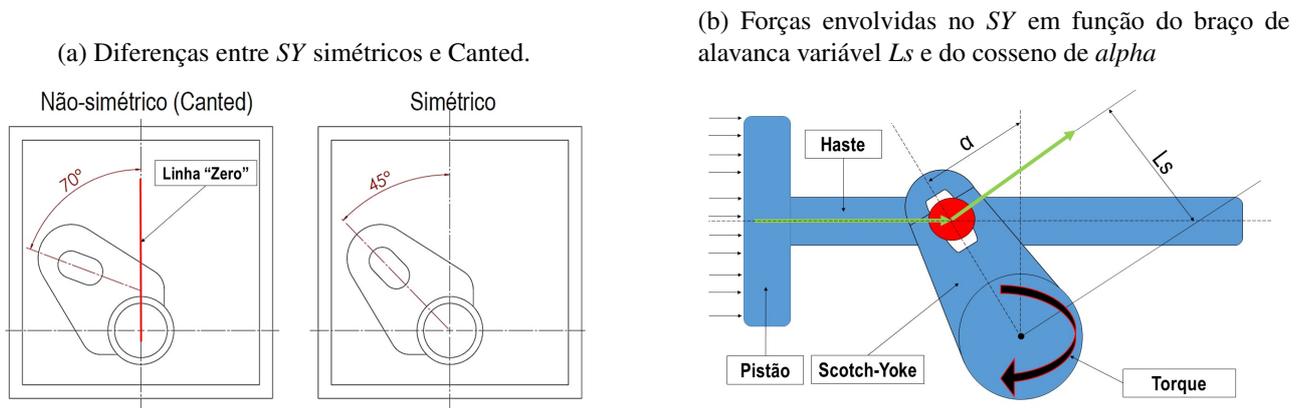
Um componente essencial para converter o movimento linear do pistão em movimento angular, a fim de abrir e fechar uma válvula de esfera, é o mecanismo conhecido como "Scotch-Yoke" (SY) (Bergonzoni et al., 2018a; Arakelian et al., 2016). O SY possui um curso de 90 graus, o que é suficiente para realizar a operação de abertura e fechamento de uma válvula esfera. Esse mecanismo é montado entre a câmara do atuador e a câmara da mola em relação ao sistema de atuação, enquanto em relação à válvula, ele é posicionado na haste da mesma. É no SY que a força exercida pelo fluido sobre o pistão é transferida para a haste e convertida em torque, possibilitando a abertura da válvula (Pugi et al., 2016; Bergonzoni et al., 2018b).

A configuração e o projeto do SY são cruciais para garantir que a abertura e o fechamento da válvula ocorram efetivamente sob condições de máximo diferencial de pressão. Portanto, o braço de alavanca do SY deve ter o comprimento adequado para gerar o torque necessário nessas situações de pressão diferencial máxima. O SY pode ser montado em duas configurações principais. A primeira é chamada de configuração "simétrica" onde são alocados 45 graus de giro para cada lado. Nessa configuração, o valor de torque é distribuído de maneira simétrica em relação ao eixo central do SY.

A outra opção é a montagem não-simétrica, conhecida como *Canted*, onde o ângulo inicial não é de 45 graus, como ilustrado na Fig. 8. Isso permite que o SY inicie com um valor de torque mais elevado em comparação à configuração simétrica, o que pode ser útil em algumas aplicações específicas (Pugi et al., 2016).

Essa variação na configuração do mecanismo *Scotch-Yoke* (SY) ocorre porque o braço  $L_s$ , conforme ilustrado na Figura 8b, é um braço variável. Isso significa que o comprimento total do

Figura 8: Representação da diferença entre o *Scotch-Yoke* simétrico e não simétrico.



Fonte: Próprio Autor.

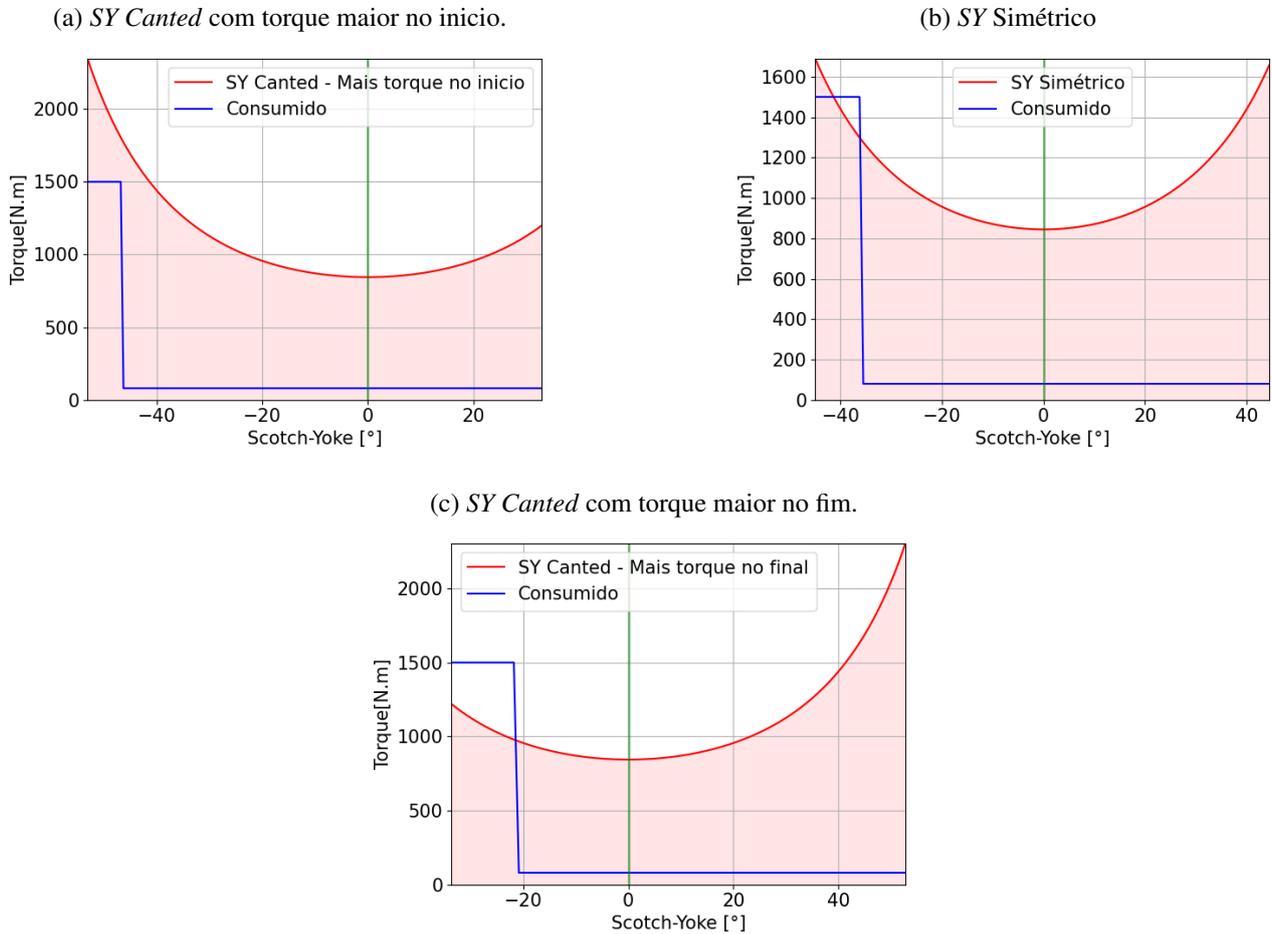
braço  $L_s$  muda à medida que a haste do pistão avança. Como a fórmula que calcula o torque depende do comprimento do braço de alavanca, qualquer alteração em seu comprimento afetará diretamente o valor final do torque gerado conforme equações.

Portanto, a configuração do sistema “*Canted*” oferece a vantagem de proporcionar um valor de torque mais elevado para a válvula, seja no início ou no final do movimento, como ilustrado na Fig. 9a. Este valor mais elevado de torque é obtido com o mesmo valor de força, ou pressão vezes a área, apenas em função da mudança do tamanho do braço variável.

Esta flexibilidade é particularmente útil em válvulas que apresentam atrito significativo, especialmente quando há um grande diferencial de pressão entre a montante e a jusante. Em tais casos, é importante fornecer um torque mais elevado no início do movimento, quando o atrito é maior, até que a pressão entre os dois lados da válvula se equilibre, resultando na redução do torque necessário para operar a válvula.

Em contrapartida, se o atrito for maior no final do movimento, é essencial fornecer um torque mais alto no final do giro, como exemplificado na Fig. 9c. Há ainda as aplicações onde o *SY* é montado de maneira simétrica, resultando em um valor de torque igualmente distribuído, como ilustra a Fig. 9. Esse ajuste permite uma operação mais eficiente e suave da válvula sob diferentes condições e requisitos operacionais (Gouveia, 2018; Pugi et al., 2016).

Figura 9: Influência da montagem do SY em função do torque fornecido. A linha em vermelho representa o torque fornecido pelo *Scotch-Yoke*, já a linha azul representa o valor de torque que a válvula demanda para mover o obturador. Estes exemplos consideram o máximo diferencial de pressão entre montante e jusante.



Fonte: Próprio Autor.

### 2.2.2 Válvulas

As válvulas são dispositivos mecânicos utilizados para controlar, direcionar e regular o fluxo de fluidos, sejam líquidos, gases ou vapores, em sistemas industriais. Um componente fundamental deste tipo de equipamento é chamado de obturador.

Tal componente possui a função de bloquear ou permitir o escoamento do fluido entre a montante e jusante da válvula. A depender do tipo de válvula, como, por exemplo, esfera, alívio, gaveta ou borboleta, o obturador pode assumir diferentes formas, como uma esfera ou uma cunha. As válvulas são projetadas e desenvolvidas para atender a uma variedade de critérios operacionais, incluindo pressão, tipo de fluido, temperatura de trabalho e confiabilidade ao longo de sua vida útil.

A seleção, o tipo e o dimensionamento são aspectos cruciais na sua escolha. Os principais fatores a serem considerados para a especificação incluem: perda de carga, pressão e temperatura do fluido, tipo de fluido, capacidade de vazão, tipos de acionamento, espaço disponível para instalação, materiais

de construção e tipo de conexões (Mathias, 2014).

A Tab. 2 apresenta diversos tipos de válvulas para diferentes aplicações.

Tabela 2: Tipos de válvulas para diferentes aplicações. Adaptado de Gasparetto (2014); Mathias (2014).

Válvula	Bloqueio fluxo	Controle Fluxo	Aciona Rápido	Aciona Frequente	Passagem plena	Prevenção Refluxo	Alto Diferencial Pressão	Alívio Pressão	Fluido Viscoso
Gaveta	•					•			•
Globo		•		•			•		
Retenção						•			
Guilhotina	•		•		•				•
Diafragma		•		•					
Mangote		•							•
Esfera	•		•	•	•				
Borboleta	•		•	•	•				
Macho	•		•	•	•				
Segurança								•	
Controle		•		•					

Fonte: Adaptado de Gasparetto (2014); Mathias (2014).

Elas são encontradas em diversos ramos da indústria e desempenham um papel crucial em diversos setores, incluindo refinarias de petróleo, fábricas petroquímicas, siderúrgicas, usinas termoeletricas, indústrias químicas, farmacêuticas e alimentícias.

Existem vários tipos de válvulas disponíveis, mas os tipos mais comuns e amplamente aplicados em válvulas de bloqueio em situações de emergência (com fechamento automático) são as válvulas de esfera e as válvulas de gaveta. A Fig. 10 exibe estas duas válvulas mais utilizadas, além de ilustrar como o obturador promove o bloqueio dos fluidos (Euthymíou, 2013; Mashiba, 2011)

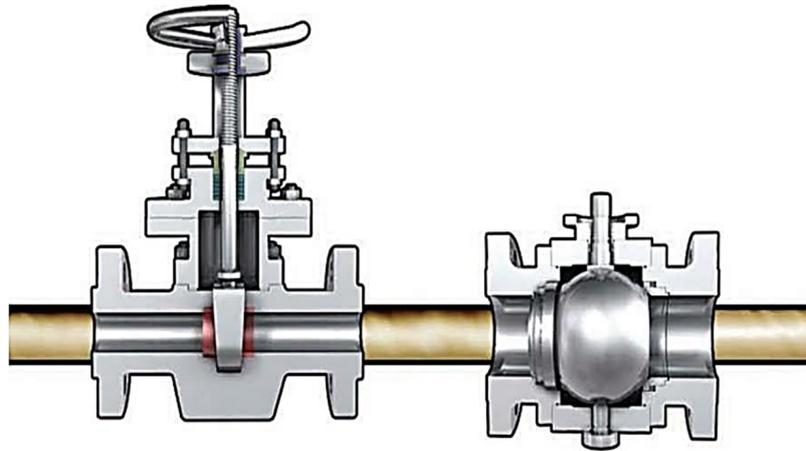
Para fins deste trabalho, será abordada especificamente nas válvulas de obturador de esfera, as chamadas válvulas de esfera, explorando seus princípios de funcionamento e sua aplicação nas ESDVs.

As válvulas de esfera são compostas por diversos elementos, incluindo um obturador esférico, tampa, corpo da válvula, haste, vedações, o' rings e sedes. No mercado brasileiro, os testes realizados para avaliar o desempenho dessas válvulas estão sujeitos à regulamentação da norma ABNT 15827 (Teles, 2020). Esta norma estabelece diretrizes rigorosas que devem ser seguidas para garantir que uma válvula industrial seja capaz de operar com segurança dentro de sua faixa de pressão designada. Os testes incluem avaliações cíclicas e de desempenho em diferentes temperaturas (Teles et al., 2020).

A Fig. 11 ilustra a relação entre a pressão máxima de trabalho de válvulas de esfera e a temperatura de operação, considerando o material de construção das sedes das válvulas. Essas informações são essenciais para garantir o funcionamento adequado das válvulas em condições diversas de pressão e temperatura (Micromazza, 2023).

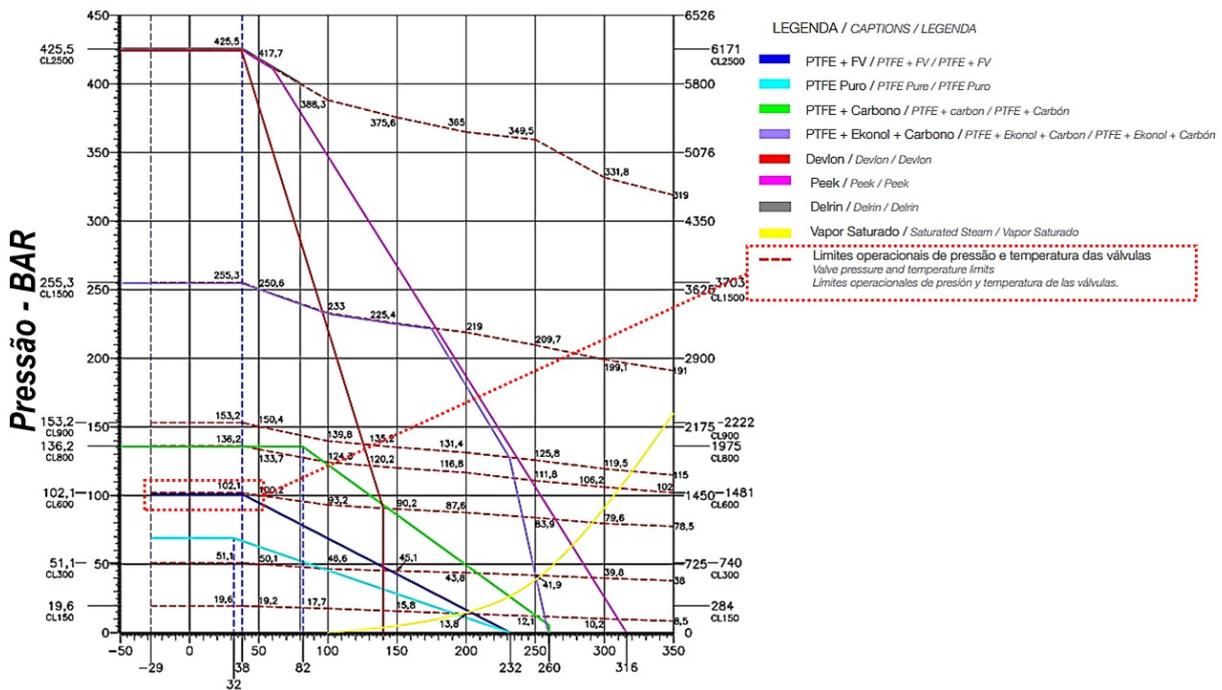
Todos esses requisitos são essenciais devido à importância da confiabilidade associada às válvulas. Em instalações de acesso remoto, onde as inspeções visuais regulares são impraticáveis, é fundamental que os equipamentos operem de maneira confiável ao longo de sua vida útil, em

Figura 10: Válvula gaveta (esquerda) e esfera (direita). As mais utilizadas em sistemas de emergências. Notar que a gaveta possui um obturador em forma de “cunha”, que se move paralelo à haste. Para a esfera, o obturador é esférico e seu movimento é angular em relação ao eixo da haste.



Fonte: Adaptado de Xie (2017).

Figura 11: Relação pressão máxima e temperatura para diversas classes de válvulas esferas.



Fonte: Adaptado de Micromazza (2023).

um intervalo de confiança, sem apresentar defeitos ou degradações. Isso é crucial para garantir a segurança da operação. Na Seção 2.4, serão apresentados detalhes mais profundos sobre esses testes cíclicos.

No que diz respeito ao funcionamento da válvula de esfera, há o componente conhecido como "esfera," que possui um orifício passante. Quando esse orifício está alinhado com a tubulação, permite

a passagem do fluido. Existem duas principais variações na montagem da esfera: flutuante e *trunnion*.

Nas válvulas flutuantes, a esfera está conectada a uma haste em sua parte superior, mas na extremidade inferior, a esfera está em balanço. Essa configuração permite uma certa flutuação da esfera quando o fluido pressurizado exerce uma força sobre sua área exposta. Essa flexão faz com que a esfera se desloque contra as sedes de vedação localizadas do lado oposto da área em contato com o fluido, ou seja, no lado a jusante da válvula. Esse contato cria uma força de vedação entre a esfera e a sede, impedindo assim que o fluido escoe para o lado jusante da válvula.

Logo, devido a esta flexão da haste, o uso de válvulas esferas flutuantes estão limitadas ao uso conforme explica a Tab. 3 (Sotoodeh, 2021a).

Tabela 3: Tamanhos máximos, em polegadas, para válvulas de esfera flutuante por classe.

Classe #	Tamanho Máximo (pol)
150	8
300	6
600	4
900 e 1500	2
2500	1 ½

Fonte: Adaptado de Sotoodeh (2021a)

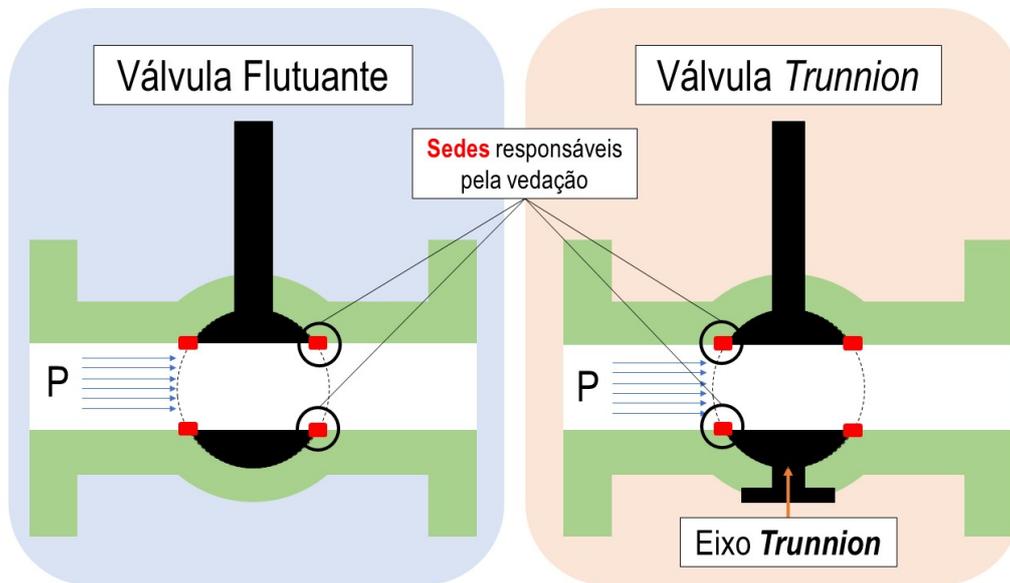
No caso das válvulas *trunnion*, existe um eixo localizada na parte inferior do corpo da válvula, que restringe o deslocamento da esfera e, conseqüentemente, sua flexão. Isso resulta em uma operação mais controlada da esfera, minimizando as variações na força de vedação e garantindo um melhor controle do fluxo de fluido.

Geralmente, as válvulas *trunnion* são utilizadas em operações em que estão sujeitas a maiores pressões e diâmetros maiores, quando comparadas as válvulas flutuantes. Estes conceitos, estão ilustrados na Fig. 12, a qual mostra quais as sedes, sejam do lado montante ou jusante, realizam as vedações quando existe um diferencial de pressão na válvula, partindo da pressurização pelo lado montante.

Com relação ao deslocamento das sedes nas válvulas de esfera, ocorre o oposto em comparação ao movimento da esfera. Ou seja, quando uma válvula é do tipo flutuante, as sedes são fixas, enquanto em uma válvula de esfera do tipo *trunnion*, as sedes são móveis. Essa distinção leva a mais uma configuração que está relacionada ao funcionamento das válvulas: sedes do tipo Duplo Pistão Efeito (DPE) e Simples Pistão Efeito (SPE).

Essas diferentes configurações de sedes afetam o desempenho e a capacidade de vedação das válvulas de esfera em diferentes cenários operacionais.

Figura 12: Diferença entre válvulas esferas flutuantes e *trunnion* e quais sedes executam a vedação quando, em ambos os casos, a pressão na tubulação, está localizada a montante da válvula, ao lado esquerdo da Figura.



Fonte: Adaptado de (Mathias, 2014; Sotoodeh, 2021a).

### 2.2.2.1 Vedações do tipo SPE, DPE

As configurações de vedação SPE (Simple Pistão Efeito) e DPE (Duplo Pistão Efeito) são empregadas para controlar a pressão na cavidade de válvulas esféricas quando estas estão em posição de fechamento. Nessas circunstâncias, pode ocorrer a retenção de um volume de fluido na cavidade da válvula. Caso a válvula seja exposta a um aumento significativo de temperatura, o fluido retido pode se expandir, resultando em um aumento da pressão interna. Para prevenir danos aos componentes da sede da válvula devido ao incremento de pressão, é essencial permitir a liberação do fluido retido. Essa liberação só é viável se o design da válvula permitir que o fluido na cavidade desloque o porta-sede, conforme ilustrado no balanço de áreas nas Fig. 13 e Fig. 14.

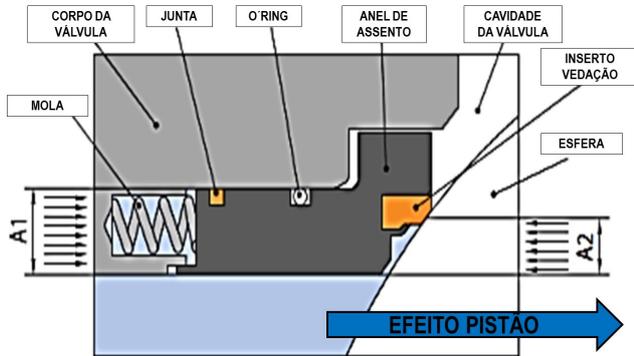
Tais considerações são fundamentais para assegurar o funcionamento seguro das válvulas esféricas sob diversas condições operacionais, especialmente em cenários de variações significativas de temperatura (Sotoodeh, 2021b; Piping-World, 2023).

Para uma sede com configuração do tipo SPE (Simple Pistão Efeito), quando a pressão na montante da válvula é predominantemente maior, a área  $A_1$ , gerada pela pressão do fluido, é superior à área  $A_2$ , resultando em uma força que desloca o porta-sede em direção ao obturador. Esse deslocamento cria uma pressão de contato entre a sede e o obturador, assegurando a vedação da válvula, conforme ilustrado na Fig. 13a.

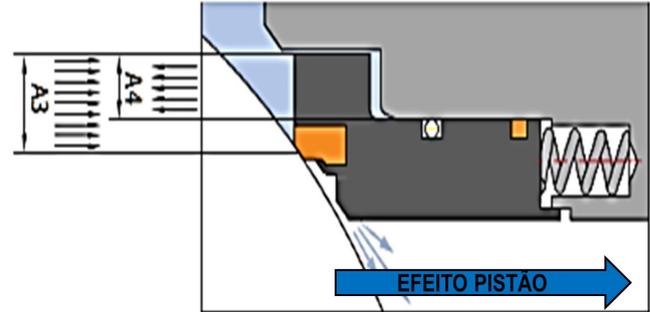
Quando a válvula está na posição fechada, pode haver uma retenção de pressão na cavidade da válvula. Se a pressão retida na cavidade aumentar, por exemplo, devido à expansão térmica do fluido, é essencial aliviar essa pressão para prevenir danos aos componentes internos da válvula. Nesse contexto, a área  $A_3$  é projetada para ser maior que a área  $A_4$ . Essa diferença de áreas resulta em uma

Figura 13: Configuração Simples Pistão Efeito (SPE) nas sedes de uma válvula.

(a) Balanço de áreas na sede SPE, quando a pressão se localiza na montante da válvula.



(b) Balanço de áreas na sede SPE, quando a pressão se localiza na cavidade da válvula.



Fonte: Adaptado de Piping-World (2023).

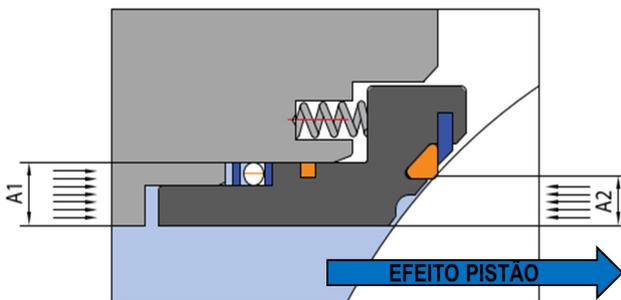
força que desloca o porta-sede na direção da jusante, permitindo o alívio da pressão acumulada na cavidade da válvula, conforme demonstrado na Fig. 13b.

Essa funcionalidade é crucial para manter a integridade e o desempenho seguro da válvula sob condições operacionais variáveis, incluindo mudanças significativas de temperatura (Souza, 2019).

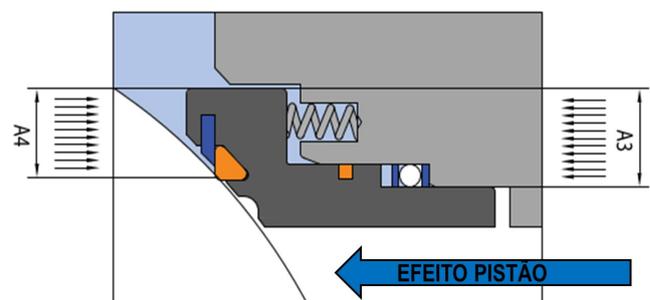
Quando o fluido exerce pressão pelo lado montante, a configuração DPE opera de maneira semelhante à configuração SPE. Nessa situação, a pressão na montante da válvula é maior e a área  $A1$ , gerada pela pressão do fluido, é superior à área  $A2$ . Isso resulta em uma força que move o porta-sede em direção ao obturador, criando uma tensão de contato entre a sede e o obturador para vedar a válvula, como mostrado na Fig. 14a.

Figura 14: Configuração Duplo Pistão Efeito (DPE) nas sedes de uma válvula.

(a) Balanço de áreas na sede DPE, quando a pressão se localiza na montante da válvula.



(b) Balanço de áreas na sede DPE, quando a pressão se localiza na cavidade da válvula.



Fonte: Adaptado de Piping-World (2023).

De maneira semelhante quanto ao movimento, a Fig. 14b, mostra a válvula ao encontrar com um fluido pressurizado na cavidade da válvula, pela característica DPE possuir este duplo efeito pistão, a sede é capaz de se deslocar, no sentido ao encontro do obturador, não permitindo o escoamento do

fluido, no sentido cavidade-jusante. Tal função é crucial quando o objetivo do projeto é de impedir qualquer nível de escoamento do fluido para o lado oposto.

Essa dualidade de operação, torna a configuração DPE altamente eficaz e versátil, garantindo a vedação adequada e a segurança do sistema em várias condições operacionais.

Existem ainda as configurações DBB e DIB, que embora utilizadas em válvulas de bloqueio, não será abordada neste trabalho, para uma compreensão mais clara destes conceitos pode-se analisar trabalhos acadêmicos já publicados (Sotoodeh, 2021b,d).

#### 2.2.2.2 *Sedes poliméricas em PTFE e RPTFE*

O PTFE (politetraflúoretileno), é caracterizado como um termoplástico semicristalino, amplamente utilizado nas mais diversas aplicações de engenharia, como encanamentos, registros, próteses e válvulas. Esta aplicação decorrentes da a sua alta estabilidade térmica, boa resistência a solventes e um coeficiente de atrito baixo. A relação de atrito baixo, resulta pela maneira que suas cadeias de moléculas de ligam, sendo que para o PTFE, elas apresentam a estrutura linear, que formam filmes de baixa resistência ao cisalhamento na superfície do contra corpo durante o contato e movimentos cisalhantes. Porém, o PTFE possui algumas limitações, como uma baixa resistência mecânica e uma baixa resistência abrasiva, levando a desgastes, muitas vezes, prematuros. (Silva, 2016; Silva, 2008).

A maior causa de tais desgastes, são ocasionadas pelos movimentos entre duas superfícies em contato, o atrito. No estudo entre os pares de contato, a tribologia, uma série de desgastes podem ser associados ao material, desgaste adesivo, abrasivo, desgaste por fadiga e desgaste por fusão (Silva, 2016).

Para promover uma melhora da resistência, seja mecânica ou ao desgaste, pode-se utilizar elementos de carga. Tais materiais estão dispostos na Tab. 4, onde se nota que a adição de carbono e grafite, resultam em um aumento da resistência a compressão, resistência ao desgaste e uma diminuição do coeficiente de atrito (Silva, 2016).

Dentre as melhoras se destacam o aumento ao desgaste, visto que a aplicação voltada a válvula da indústria de petróleo e gás, estão constantes submetidas a aberturas e fechamentos, tal melhora poderá prolongar a vida útil da sede de RPTFE, responsável por promover o bloqueio quanto ao escoamento dos fluidos.

Além disto, a diminuição do coeficiente de atrito, entre PTFE e o obturador, resultara em valores de torque, e conseqüentemente, de pressão de acionamento, menores, facilitando a atuação do equipamento durante sua vida operacional (Silva, 2016; ?; Silva, 2008).

Tabela 4: Propriedades melhoradas do PTFE obtidas por diferentes cargas.

<b>Cargas</b>	<b>Propriedades Obtidas</b>
Fibra de Vidro	Resistência à compressão Resistência ao desgaste Ótima resistência química
Carbono	Resistência à compressão Resistência ao desgaste Boa condutibilidade térmica
Grafite	Boa condutibilidade térmica Boas produtividades de deslizamento Baixo coeficiente de atrito
Bronze	Resistência à compressão Resistência ao desgaste Baixo escoamento a frio Ótima resistência química

Fonte: Adaptado de Silva (2016).

### 2.3 Principais danos em válvulas de bloqueio

De acordo com estudos conduzidos por Teles (2020), as válvulas foram projetadas há algumas décadas, mas a constante revisão de normas e padrões internacionais cada vez mais rigorosos tem contribuído para melhorar a qualidade desses equipamentos, reduzindo a ocorrência de falhas. No entanto, o mesmo autor observa que uma das questões recorrentes em termos de falhas continua relacionada às sedes das válvulas.

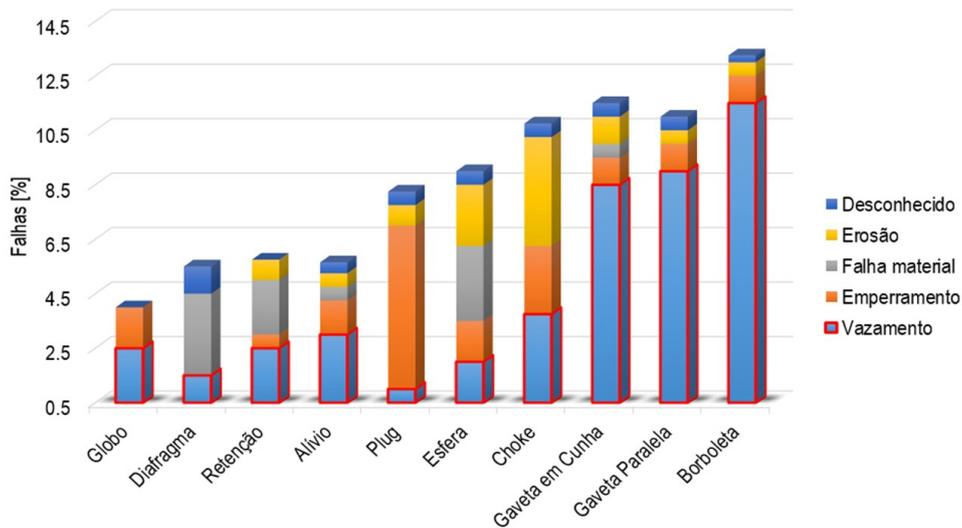
Em um estudo realizado por Peters (Glasgow, UK, 2003), as ESDVs foram responsáveis pela maioria dos incidentes, representando 69% do total, e foram a segunda maior causa de tempo perdido na produção, com 37% do tempo total de parada.

A Fig. 15 ilustra que, em uma amostra de 10 tipos diferentes de válvulas, a maioria delas apresentou vazamentos como a principal causa de falhas. No caso das válvulas esféricas, as falhas ocorreram em aproximadamente 10% das válvulas analisadas, como indicado na Figura 15.

Quando nos concentramos nas válvulas de bloqueio, observamos que as falhas relacionadas às sedes e vedações representam aproximadamente três quartos de todas as falhas registradas. Essas falhas podem estar associadas a ciclos repetitivos, fadiga ou pressões máximas. Em segundo lugar, com uma fração de apenas nove por cento, estão as falhas por corrosão, que estão mais relacionadas à escolha do material e à especificação adequada da válvula para o fluido de trabalho do que às condições de operação (Teles, 2020; Souza, 2019).

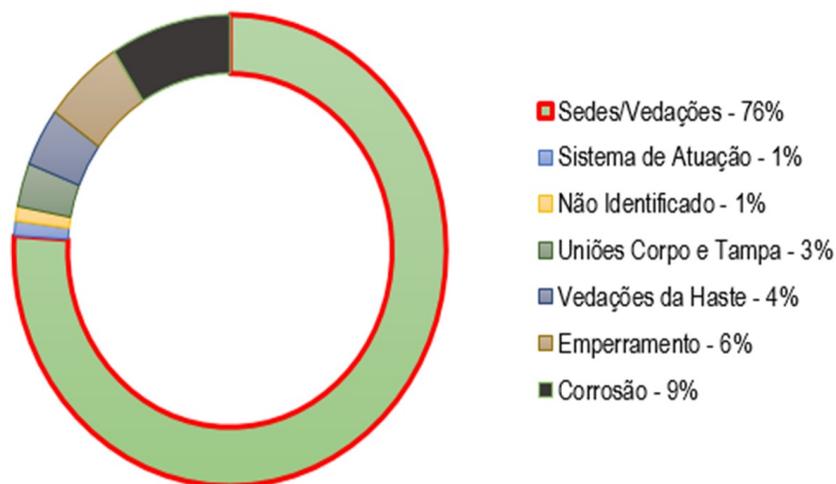
Os defeitos mais comuns em sedes resilientes, feitas de material polimérico à base de politetrafluoretileno (PTFE) e reforçadas com adição de cargas, como o RPTFE, são diversos. Em primeiro lugar, a presença de sólidos em suspensão ou partículas abrasivas no fluido pode causar sulcos nas sedes, ou mesmo se alojar no material polimérico, levando a danos na esfera e, conseqüentemente, vazamentos. Além disso, em aplicações em altas temperaturas, a resistência

Figura 15: Distribuição do tipo de falha ocorrida em um estudo em uma população de 250.000 válvulas, destaque para as falhas do tipo vazamento.



Fonte: Adaptado de Teles (2020); Euthymíou (2013).

Figura 16: Detalhamento das falhas em válvulas de bloqueio, sendo que, as falhas em sedes correspondem por 76% de todas as falhas ocorridas no equipamento.



Fonte: Adaptado de Teles (2020).

mecânica da vedação pode diminuir, resultando em deformações plásticas anormais e vazamentos.

Também é comum observar danos na sede, especialmente onde se inicia a abertura da válvula, bem como na região onde ocorre a descarga do fluido em alta velocidade durante a abertura, causando erosão e deformação permanente na banda de vedação da sede.

A Figura 17 exemplifica esses defeitos, que podem ser sólidos em suspensão ou partículas abrasivas, resultando em sulcos nas sedes e danos na sede, gerando por fim, vazamentos. Outro ponto que pode levar a defeitos, são aplicações em elevadas temperaturas, pois a resistência mecânica da vedação diminuirá, levando a deformações plásticas anormais, o que também resultara no vazamento

do fluido.

A erosão também pode ocorrer, pois durante a abertura da válvula, o ponto de descarga do fluido em alta velocidade no instante onde ocorre a despressurização da montante consequente, equalização da pressão montante x jusante, podem ocorrer estas erosões somadas a deformações permanentes, que além de elevar as pressões necessárias para promover a abertura da válvula pelo atuador hidráulico, resulta em vazamentos (Teles, 2020).

Figura 17: Defeitos em sedes poliméricas.



Fonte: Adaptado de Teles (2020).

Em Yanjie Jia (2022), danos em válvulas de bloqueio foram analisadas. Estes danos estão exemplificados conforme Fig. 18.

Figura 18: Defeitos em sedes utilizadas em válvulas de bloqueio.



Fonte: Adaptado de Yanjie Jia (2022).

## 2.4 Normas para ensaios e qualificações em válvulas

Na definição de ensaios envolvendo válvulas, a indústria brasileira conta com a norma regulamentadora NBR 15827 (ABNT NBR 15827, 2022). Para a construção das válvulas, as normas que regem a definição dos materiais são as internacionais (ASME B16.34, 2020; API 6D, 2022; API 6DX, 2023) conforme Fig. 19 (Teles et al., 2023, 2024).

- API 6D: apresenta especificações de materiais, requerimentos de testes, composições químicas. Sua abrangência cobre válvulas de 1/2" até 60". Nas classes de pressão 150, 300, 600, 900, 1500 e 2500.
- ASME 16.34: exhibe grupos de materiais, definições de classes de pressões, indicações de padrões para testes e inspeções.
- ASME Divisão 2 e ASME Seção 2 Parte D: mostra o critério para analisar a tensão admissível e propriedades dos materiais utilizados nos componentes das válvulas.
- API 598: apresenta informações e requerimentos para o teste de aceitação em fábrica (*Factory Acceptance Testing - FAT*). Também indica o tipo de fluido para testes hidrostáticos, por exemplo.
- ABNT NBR 15827: descreve a seleção de materiais para válvulas esferas conforme o processo de manufatura. Também apresenta a especificação de material para a manufatura de um protótipo da válvula para homologação do produto.

Além disso, existe a especificação técnica da empresa brasileira Petrobras, que define os requisitos mínimos para a homologação de projetos e a fabricação de válvulas submarinas para lâminas d'água de até 2000 metros.

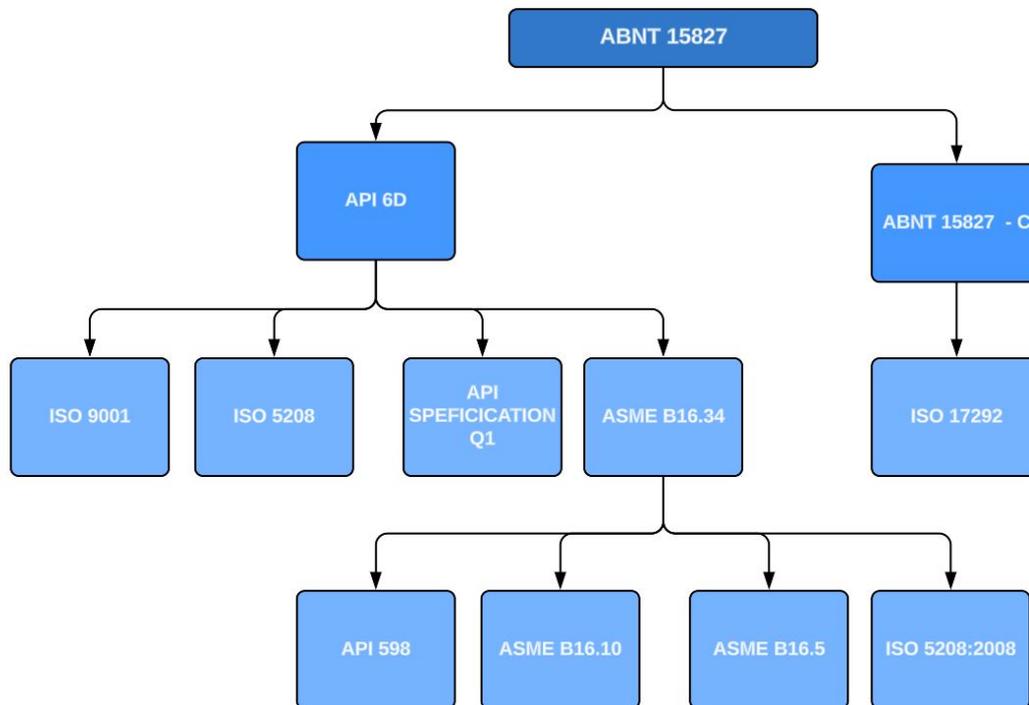
Para a homologação dessas válvulas, juntamente com os atuadores hidráulicos em aplicações em águas rasas, profundas e ultra-profundas, são estabelecidas diretrizes específicas conforme a norma ET-3500.00-1510-224-PPC-002 (Rossetto, 2016; Euthymíou, 2013).

Esta especificação técnica detalha os critérios de desempenho, materiais e procedimentos de teste necessários para garantir a confiabilidade e a segurança das válvulas submarinas sob condições extremas. A norma abrange aspectos como resistência à corrosão, pressão de operação, temperatura, e a compatibilidade dos materiais com os fluidos processados. Além disso, a especificação inclui diretrizes para a inspeção e manutenção das válvulas, assegurando que elas continuem a operar eficazmente ao longo de sua vida útil.

A homologação de projetos de válvulas submarinas seguindo a norma ET-3500.00-1510-224-PPC-002 é um processo rigoroso que envolve testes extensivos em condições simuladas de operação (Rossetto, 2016; Euthymíou, 2013).

A norma brasileira se baseia nesta ET e também em algumas especificações e exigências internacionais para determinar alguns dos requisitos de funcionamento e capacidade das válvulas.

Figura 19: Normas aplicadas em válvulas do tipo esfera em relação a ABNT 15827.



Fonte: Adaptado de Teles (2020).

No entanto, entre todas as normas internacionais, a ABNT 15827 é a única que prevê ensaios cíclicos de homologação em temperaturas extremas, tanto altas quanto baixas, além da temperatura ambiente (Teles, 2020).

De acordo com Teles (2020), as normas relacionadas ao desempenho desses equipamentos não detalham as pressões e temperaturas relacionadas às sedes das válvulas, mas sim ao material do corpo. Portanto, as normas internacionais que estabelecem as diretrizes para os testes de homologação não abrangem a degradação do par sede-esfera simulando as condições de campo, deixando a interação pressão x temperatura fora do escopo de testes.

No entanto, apenas a ISO 17292 (ISO 17292, 2024), ver Fig. 19, menciona o uso de sedes poliméricas em válvulas, estabelecendo limites de pressão e temperatura, mas não fornece detalhes sobre a realização dos testes e não especifica a quantidade mínima de testes exigidos para esse tipo de válvula com sedes poliméricas.

Para aplicações submarinas, onde o equipamento estará sujeito as pressões hidrostáticas da coluna d'água, testes adicionais são requeridos das ESDVs. Dentre os requisitos, estão as operações de abertura e fechamento, com o máximo diferencial de pressão entre montante e jusante, submetida a pressão ambiente da coluna d'água (Sotoodeh, 2021c).

Tais testes são realizados em vasos de pressão, com espessura suficiente para simularem as pressões encontradas no ambiente submerso. Estes vasos são conhecidos como "Câmara Hiperbárica", e os ensaios são referidos como ensaios hiperbáricos.

A Fig. 20 mostra a câmara juntamente com uma ESDV sendo posicionada para os testes. Além de

impor a ESDVs, uma condição real, o ensaio exige quantidades determinadas de ciclos de aberturas e fechamentos que posteriormente são associados a confiabilidade final da ESDV. Isto se faz necessário, pois uma vez instalada no ambiente submerso, manutenções e intervenções nestes equipamentos, se tornam onerosas. Portanto, o equipamento deve ter uma taxa de confiabilidade elevada, para operar sem intervenções por 20 ou 30 anos, tempo este que abrange a vida útil de tal equipamento (Praveen et al., 2018; Sotoodeh, 2021c).

Figura 20: Teste hiperbárico aplicado em ESDVs.



Fonte: Sotoodeh (2021c).

## 2.5 Técnicas de monitoramento em válvulas de bloqueio

Devido ao papel que ESDVs desempenham, monitorar seus sinais é de grande importância para a indústria, portanto, esta seção irá se dedicar a apresentar os trabalhos encontrados na literatura com relação ao monitoramento.

### 2.5.1 Assinaturas

Uma estratégia eficaz para monitorar o funcionamento do conjunto válvula e atuador envolve o acompanhamento da fonte de energia utilizada para acioná-las, que pode ser hidráulica, pneumática ou elétrica. Esse monitoramento visa correlacionar possíveis variações nos valores dessa energia com a condição operacional do equipamento. Para sistemas de acionamento hidráulico, é possível posicionar um sensor de pressão nas proximidades do atuador e configurá-lo em um sistema de aquisição de

dados.

Esse sensor de pressão pode efetuar a leitura e o armazenamento dos sinais de pressão. Quando colocado tanto no lado montante quanto na jusante da válvula, fornece informações sobre a pressão na tubulação. Além disso, ao combinar esses dados de pressão com a posição angular do obturador da válvula esfera, obtida via um sensor de posição, como um potenciômetro, é possível determinar a posição da esfera. O sistema de acionamento baseado no mecanismo *Scotch-Yoke* garante um movimento de noventa graus, simplificando a obtenção das informações de ângulo. Com esses dados em mãos, a aplicação de técnicas de processamento de sinais permite identificar eventos relacionados à abertura e ao fechamento da válvula. Isso resulta na criação de um gráfico temporal conhecido como “Assinatura de Pressão”, no qual as pressões são representadas no eixo vertical (y) e o ângulo da esfera é disposto no eixo horizontal (x). Esse gráfico oferece uma compreensão sobre como variações na pressão estão relacionadas à posição angular da esfera ao longo do tempo. Esse método de monitoramento fornece informações valiosas para avaliar o desempenho das válvulas de bloqueio e identificar qualquer comportamento anormal que indique a necessidade de manutenção ou intervenção (Teles, 2020; Euthymíou, 2013; Mashiba, 2011).

Essas assinaturas podem representar o comportamento normal e sem defeitos da válvula em condições ideais. Quando a válvula é instalada em um ambiente de operação real, é possível adquirir sinais semelhantes, ou seja, uma nova assinatura, durante seu funcionamento em campo. Comparando a assinatura obtida durante os testes com a assinatura da válvula em operação em campo, pode-se estabelecer uma forma inicial e simples de monitoramento das válvulas por meio da análise de sinais. Isto somente será possível, caso os testes em laboratórios simulem de maneira fiel às condições enfrentadas em campo, como pressão e temperatura. No caso de falta de sinais provenientes de testes, pode-se adquirir sinais diretamente do campo, onde as primeiras assinaturas serão definidas como o padrão sem defeito do equipamento. Essa nova assinatura se torna o padrão de funcionamento esperado do equipamento em condições normais de operação. Esse método de monitoramento baseado na comparação de assinaturas permite identificar desvios no comportamento da válvula em campo em relação ao seu desempenho esperado, o que pode indicar problemas ou necessidade de manutenção (Bencomo, 2012)

Além disso, outro conjunto de sinais que pode ser adquirido e utilizado para criar outra forma de assinatura é o conjunto de valores de torque. No trabalho de Teles (2020), os dois conjuntos de sinais, tanto pressão como torque, foram analisados a fim de detectar defeitos ocorridos em testes cíclicos de uma válvula a partir dos eventos de abertura e fechamento.

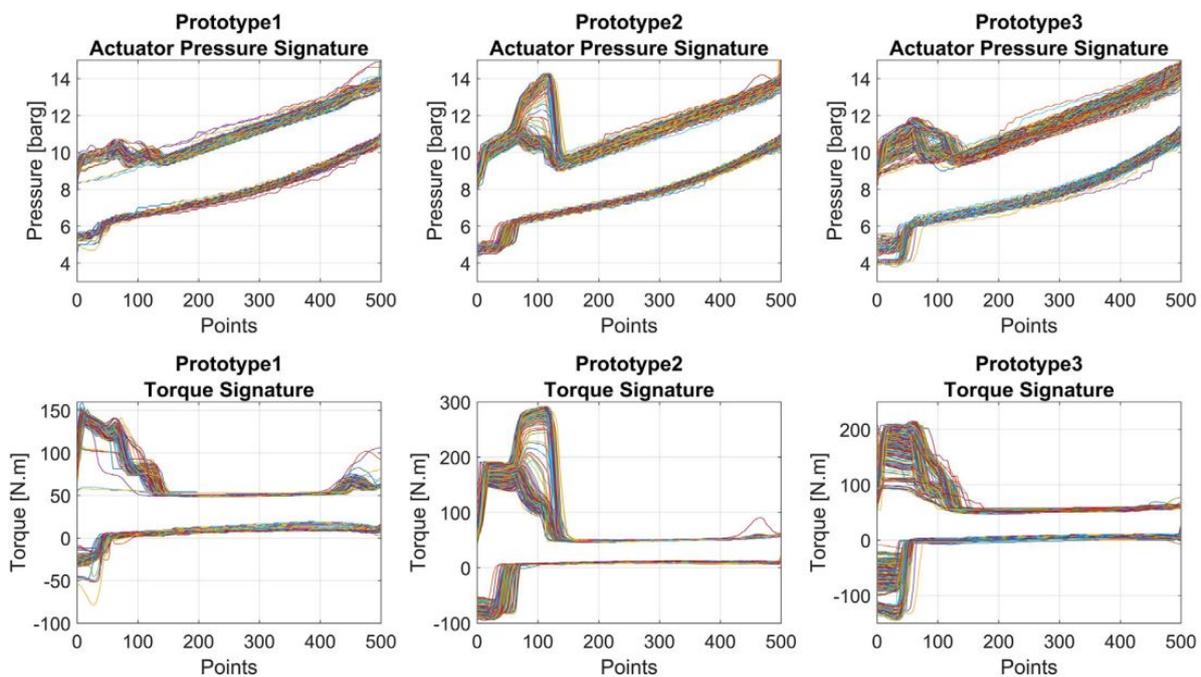
Conforme mencionado na Seção 2.2.1.2, o mecanismo *Scotch-Yoke* é responsável por gerar o torque necessário para abrir e fechar a válvula. Esse torque é transmitido por torção através da haste da válvula. Utilizando o mesmo princípio do gráfico de pressão, mas agora com os valores de torque no eixo y, é possível construir a assinatura de torque da válvula de bloqueio.

Com os sinais de pressão, torque e posição angular em mãos, possibilita-se resumir o comportamento da válvula por meio de gráficos temporais (Souza, 2019). No entanto, a análise manual desses gráficos, que envolve a comparação entre diferentes assinaturas, pode ser uma tarefa

desafiadora que requer a experiência de um operador altamente treinado. Além disso, em uma planta industrial com centenas de válvulas de fechamento de emergência instaladas, a análise manual por comparação pode se tornar impraticável. A Fig. 21 ilustra várias assinaturas sobrepostas e demonstra a complexidade dessa tarefa de análise.

Nesse cenário, surge a necessidade de introduzir o conceito de Pontos Notáveis ou *Key Points*, que será abordado na Seção 2.5.2. Esse conceito visa simplificar a análise das assinaturas e fornecer uma opção mais eficiente para monitorar o desempenho das válvulas em ambientes industriais complexos (Euthymiou, 2013; Mashiba, 2011; Teles, 2020).

Figura 21: Assinaturas de pressão e torque.



Fonte: Adaptado de Teles et al. (2020).

### 2.5.2 Pontos notáveis

Os pontos notáveis estão intrinsecamente ligados às assinaturas de pressão e torque das válvulas esfera e representam momentos específicos em seu movimento. Esses pontos desempenham um papel fundamental na análise do comportamento das válvulas (Teles, 2020). A seguir, serão explicados esses momentos cruciais:

1. Ponto A1 (Avanço 1): Este ponto ocorre quando a válvula está inicialmente fechada, e há um diferencial de pressão entre o lado montante e jusante. Quando a pressão é fornecida ao atuador e começa a vencer todos os atritos de inércia do sistema, ocorre um aumento de pressão sem movimento angular da esfera (Euthymiou, 2002; Mashiba, 2011; Teles, 2020)

2. Ponto A2 (Avanço 2): Ocorre quando a válvula começa a girar nos primeiros graus após sair da inércia. Neste momento, apesar da rotação, o fluido ainda não flui do lado montante para a jusante,

pois nenhuma passagem foi criada. A pressão na câmara do atuador continua a subir.

3. Ponto A3 (Avanço 3): Quando a primeira passagem é criada pelo obturador, ocorre uma pressão máxima no atuador antes de ocorrer uma queda. Este é o ponto onde a pressão no atuador atinge seu valor máximo.

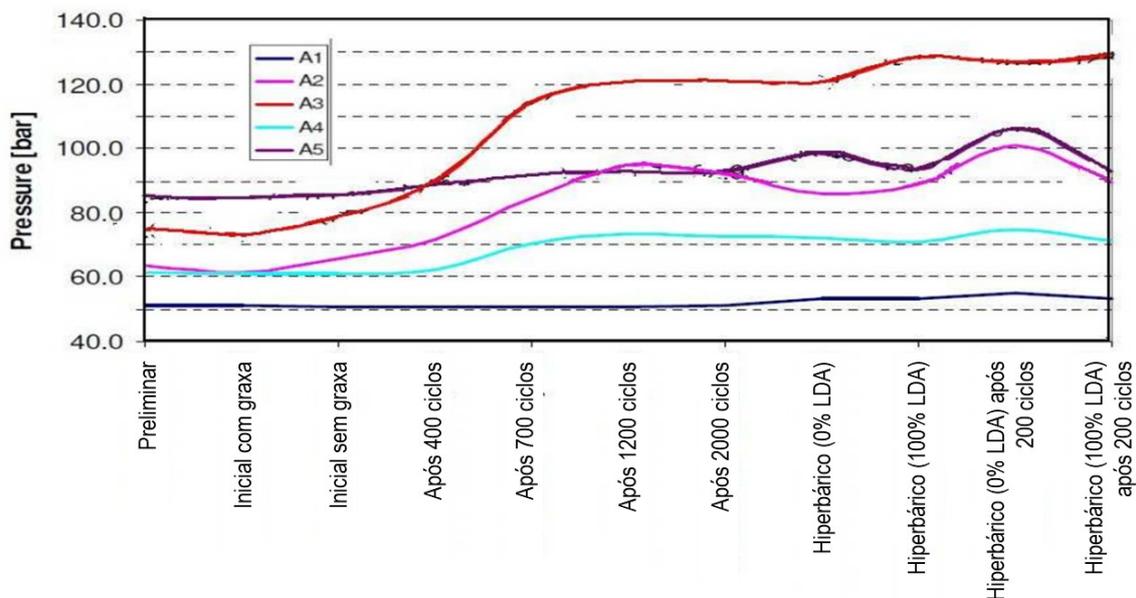
4. Ponto A4 (Avanço 4): Este ponto marca a queda abrupta de pressão na válvula quando o fluido pressurizado é forçado a passar para o lado jusante. Isso ocorre devido ao volume que precisa ser preenchido na tubulação.

5. Ponto A5 (Avanço 5): No final da abertura, quando a mola está quase totalmente comprimida, ocorre um aumento abrupto de pressão até atingir o valor fornecido pelo sistema de alimentação hidráulico. Esse ponto marca a transição do comportamento linear para o aumento repentino de pressão.

É importante observar que os pontos A1 a A5 referem-se ao avanço da válvula, ou seja, à sua abertura. Para o fechamento da válvula, os pontos correspondentes são denominados R1 a R5, onde “R” representa o “Retorno” (Euthymiou, 2002; Mashiba, 2011; Teles, 2020).

Ao adquirir esses pontos notáveis, é possível representá-los em função das assinaturas obtidas. Por exemplo, se forem obtidas 10 assinaturas, teremos 10 conjuntos de pontos A1, A2, A3, A4 e A5, dispostos lado a lado. Essa disposição fornece um resumo do comportamento da ESDV de maneira mais concisa do que as assinaturas completas. A Figura apresentada a seguir ilustra a tendência dos pontos notáveis(Souza, 2019).

Figura 22: Tendência dos pontos notáveis após testes de qualificação e o seu potencial em resumir o comportamento da ESDV ao longo do tempo.



Fonte: Adaptado de Euthymiou (2013).

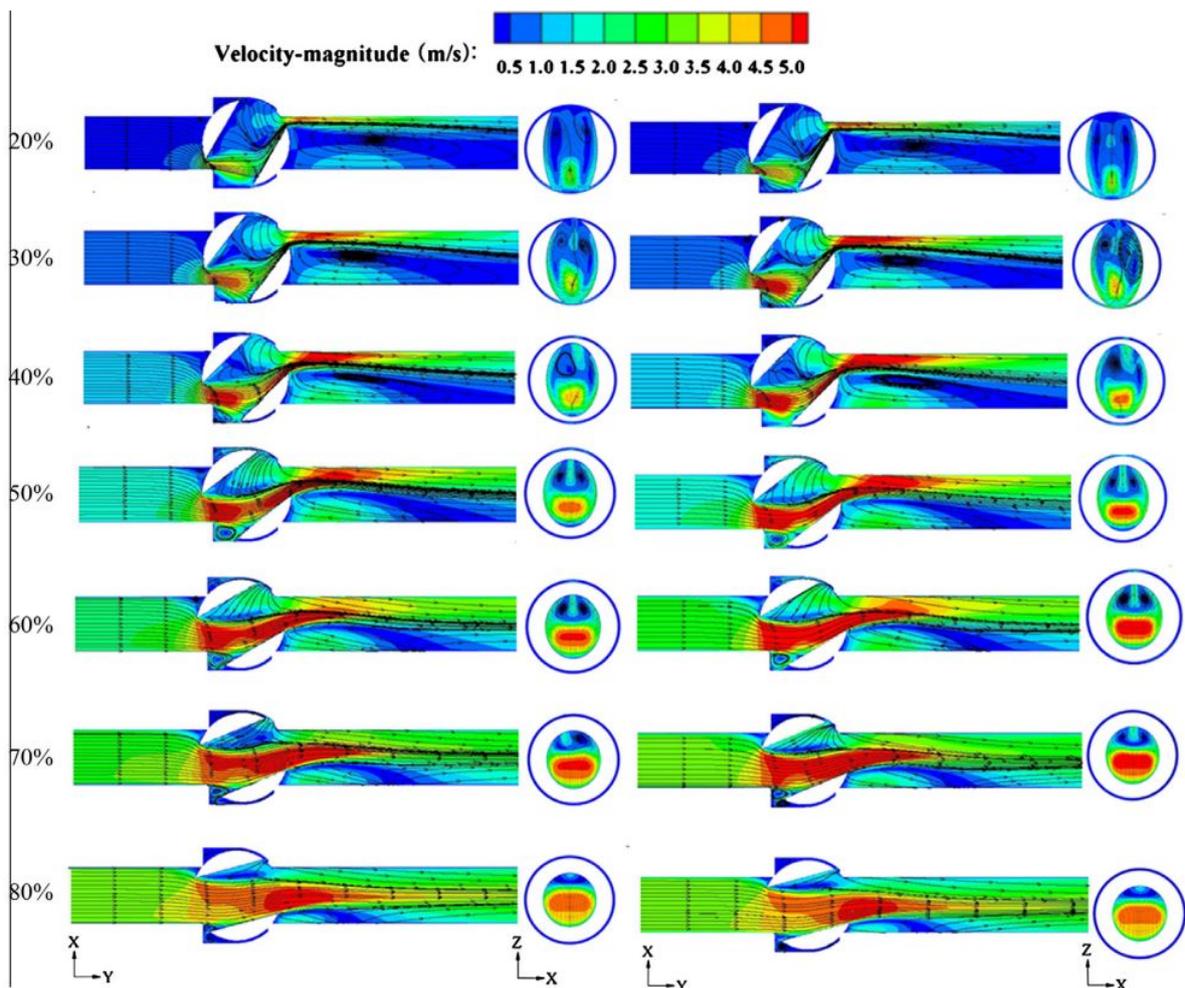
Na existência de um diferencial de pressão entre a montante e jusante da válvula, ou seja, pressão

de trabalho no lado montante e zero, ou atmosférico no lado jusante, existira um momento, onde ao iniciar a rotação da esfera/obturador, uma mínima passagem será criada. Esta mínima passagem, irá permitir que o fluido de trabalho, flua para o lado de menor pressão (Mashiba, 2011; Teles, 2020).

Com isso, o escoamento poderá atingir velocidade maiores e devido à equação de Bernoulli, como a pressão de um fluido, é inversamente, proporcional à sua velocidade, teremos uma queda de pressão, no momento em que esta passagem é criada. Com relação ao KPs, este momento, onde a primeira área da seção transversal da esfera, permite que o fluido escoe, recebe o nome de *crack-open*.

É neste ponto que o fluido pode apresentar comportamentos resultantes do processo conhecido por cavitação (Teles, 2020; Teles et al., 2020). Levando a uma degradação acelerada em um ponto específico da sede da esfera. Conforme trabalhos publicados, a Fig. 23 mostra a relação entre a velocidade de escoamento em uma válvula esfera em função do ângulo de abertura do obturador.

Figura 23: Relação da pressão e velocidade em função da abertura da esfera. Notar quando a mínima passagem é criada (*crack-open*), na posição de 20%, a velocidade aumenta, se concentrando em uma região específica, resultando na diminuição da pressão, sendo esta, o momento propenso a existência de cavitação.

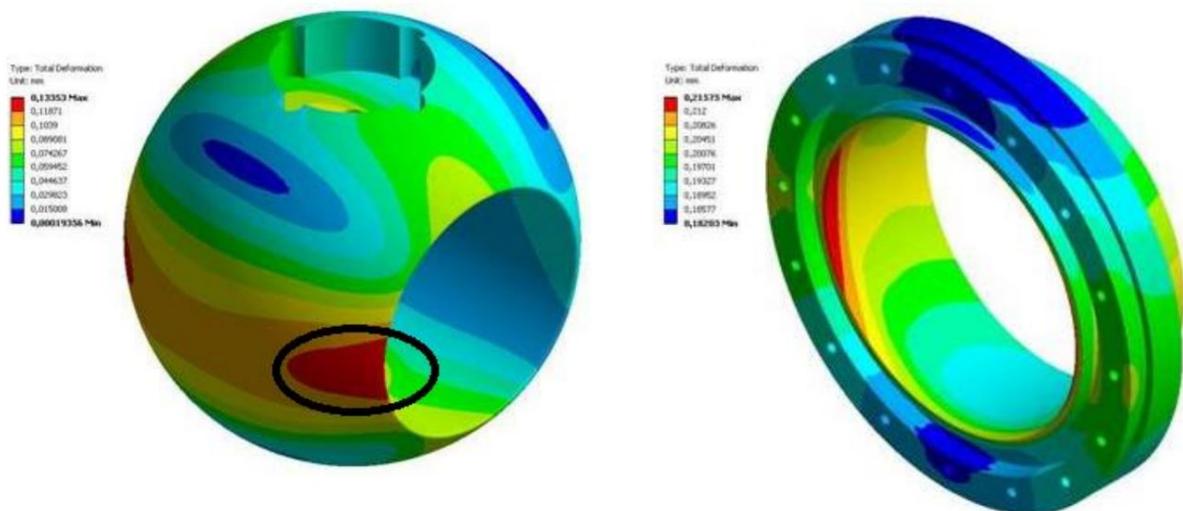


Fonte: Adaptado de Cui et al. (2017).

Outros trabalhos foram conduzidos, analisando a integridade estrutural de válvulas esferas, através do Método dos Elementos Finitos (MEF) (Rossetto, 2016). O autor, mostra que existe a região denominada “boca da esfera”, conforme ilustrada pela Fig. 24. Tal região apresentou a maior deformação em um caso estudado pelo autor. Agrupando a informação fornecida pela Fig. 23 juntamente com a Fig. 24, percebe-se que a região chamada de boca da esfera, nada mais é que a *crack-open*.

Isto implica em uma região crítica para os projetos de válvulas esferas, pois esta região é sensível, tanto, a cargas estruturais como em testes cíclicos, sendo um dos pontos de atenção durante o projeto destes equipamentos.

Figura 24: Região de maior deformação na esfera, conduzida por uma análise estrutural por MEF de uma válvula esfera. Considerar a região apresentada pelo círculo preto, onde existe a maior deformação na esfera.



Fonte: Adaptado de Rossetto (2016).

## 2.6 Estado da arte no monitoramento das válvulas de bloqueio

Alguns estudos relevantes foram publicados, abordando algumas facetas das válvulas industriais. Estes estudos se concentraram no acionamento cíclico das válvulas e suas respostas em relação aos sinais, que podem ser pressão ou torque, além de avaliar o desgaste de cada componente ao final dos testes (Teles et al., 2020; Teles, 2020; Asim et al., 2019).

Outra área de pesquisa se concentrou na importância dos testes cíclicos em ambiente hiperbárico, que simulam as condições de pressões submarinas, especialmente quando as ESDVs são instaladas abaixo da superfície do mar. Esses estudos enfatizaram a necessidade de garantir o desempenho confiável dessas válvulas em ambientes marinhos desafiadores (Praveen et al., 2018).

Além disso, alguns estudos investigaram a evolução do coeficiente de atrito e seu impacto no torque durante os ensaios cíclicos. Essas pesquisas ajudaram a entender como o desgaste e o atrito

afetam o desempenho das válvulas ao longo do tempo (Mnif et al., 2013).

Em termos mais recentes, o estudo da vida útil remanescente aplicado em válvulas começou a ser publicados pela comunidade acadêmica. Como o trabalho apresentado por Angadi and Jackson (2022) focado na revisão de RUL em válvulas solenoides, além do trabalho de Loukopoulos et al. (2019), para falhas em válvula de compressores.

Estudos em classificações e previsões do RUL em válvulas também tem sido estudadas, usando técnicas de *LSTM* em conjunto com as regressões de séries temporais do tipo ARIMA (Nie et al., 2022).

Outros estudos mais direcionados as válvulas de emergências, também tem sido publicado, onde a aplicação de algoritmos de *Machine Learning*, mais precisamente *LSTM* e algoritmos convolucionais, tem sido aplicados a dados de Emissão Acústicas para determinar, vazamentos e degradações das válvulas (Wang et al., 2021, 2020).

Analisando outros trabalhos que abordam o estudo de previsão de RUL, nota-se que existe uma tendência direcionada para a aplicação de algoritmos de *Deep Learning* para se determinar a vida remanescente destes equipamentos (Dong et al., 2023; Ma and Mao, 2020; Wang et al., 2022; Elsheikh et al., 2019).

Isto deve a natureza destes algoritmos, capazes de evidenciar e capturar os comportamentos não-lineares das falhas e conseqüentemente, da degradação que resultará na diminuição do RUL dos ativos.

O uso de técnicas de ensaios não destrutivas (END) para monitorar vazamentos tem se mostrado uma área de pesquisa em crescimento. Uma das técnicas já mencionadas, usadas para estimar o RUL, é a Emissão Acústica (AE), explorada em estudos recentes (Lee et al., 2006; Yan et al., 2015).

A técnica de AE envolve o uso de sensores sensíveis a variações na pressão sonora na forma de ondas. Esses sensores são fixados na superfície da válvula, e os sinais captados são submetidos a um processo que inclui amplificação, filtragem e digitalização para posterior análise.

Quando uma válvula não apresenta vazamento, espera-se que o sinal seja mais estável. No entanto, quando ocorrem vazamentos na válvula, as variações na resposta geram ruídos captados pelos sensores (Matthews, 1983; Kemp et al., 1986).

Ademais, observa-se um aumento no uso de AE em combinação com algoritmos de *Machine Learning* (ML). Na Seção sobre *Machine Learning* (Sec. 3.8), exploraremos em detalhes os conceitos e o funcionamento desses algoritmos. Vários autores têm utilizado algoritmos de ML para quantificar os níveis de vazamento e classificar a gravidade dos vazamentos com base nos sinais gerados pela AE (Zhu et al., 2018; Zhao et al., 2020; Ullah et al., 2023).

Essa abordagem combina a sensibilidade da AE na detecção de vazamentos com a capacidade do ML de processar grandes volumes de dados e identificar padrões, tornando-a uma ferramenta promissora para a análise e monitoramento de vazamentos em válvulas industriais.

Outros pesquisadores têm empregado algoritmos de ML para classificar o comportamento de válvulas industriais com base em seus sinais e operação. Por exemplo, alguns estudos se concentraram em utilizar o ML para determinar se um sinal proveniente de uma válvula apresenta níveis anormais

de atrito ou se está operando conforme o esperado durante aberturas e fechamentos (Yazdi et al., 2022; Kamaruddin et al., 2020).

Além disso, há trabalhos que exploram o uso de imagens para avaliar se uma válvula está total ou parcialmente fechada. Essas imagens são analisadas por algoritmos de ML especializados em processamento de imagens, como as Redes Neurais Convolucionais (Convolutional Neural Networks - CNN) (Hayward and Portugal, 2019).

Essa abordagem visual permite uma avaliação rápida e precisa do estado da válvula com base em informações visuais, complementando outras técnicas de monitoramento.

Existem ainda os trabalhos concentrados na análise dos sinais gerados pelas ESDVs, como o estudo de Atif Qureshi et al. (2018). Nesse trabalho, os sinais gerados pela ESDV foram minuciosamente analisados no domínio do tempo e da frequência para classificar as operações como normais ou indicativas de danos, ou problemas.

Outras pesquisas abordam a importância do uso de Indicadores-Chave de Desempenho (Key Performance Indicators - KPIs) para avaliar o desempenho das ESDVs (Zhu et al., 2020). Nesses estudos, são apresentadas métricas relacionadas aos valores de torque gerados durante o funcionamento das válvulas.

Esses valores de torque ocorrem em momentos específicos da curva característica do equipamento (Gokilakrishnan et al., 2014).

Portanto, monitorar esses KPIs, conforme o autor, proporcionaria uma compreensão adicional na detecção e análise de falhas ou degradações prematuras (Zhu et al., 2020).

A indústria também continua a demonstrar interesse significativo em compreender como o atrito entre vários pares de materiais influenciam o desgaste das superfícies em contato nas válvulas, como as sedes metálicas e o obturador. Nesse contexto, um estudo recente investigou o desempenho de diferentes materiais para otimizar a combinação do obturador e das sedes metálicas em uma válvula gaveta de aplicação *onshore* (Teles et al., 2023, 2024).

Com a análise dos trabalhos mencionados, fica evidente que várias soluções estão sendo propostas e, em alguns casos, desenvolvidas para monitorar e avaliar o desempenho das válvulas. No entanto, também existem propostas comerciais que oferecem soluções de monitoramento de ESDVs no nível empresarial, embora muitas delas não detalhem completamente como funcionam devido a considerações de segredo industrial relacionadas aos seus softwares. A seguir, serão apresentados alguns desses softwares, sem entrar em detalhes, uma vez que não é o foco deste trabalho, mas é importante destacar que existem soluções disponíveis para a indústria. É relevante mencionar que a grande maioria dessas soluções não explica de forma transparente o funcionamento de suas metodologias.

Usando o conceito de assinaturas de pressão, existem softwares como o V-Map, Valcontrols e Imtex, conforme mostrado na Figura 25. Embora esses softwares não forneçam muitos detalhes publicamente, os sinais disponíveis em seus sites contêm curvas características que podem ser associadas às assinaturas, tanto de pressão quanto de torque. Portanto, pode-se concluir que esses softwares utilizam métodos de comparação de assinaturas para detectar mudanças na operação da

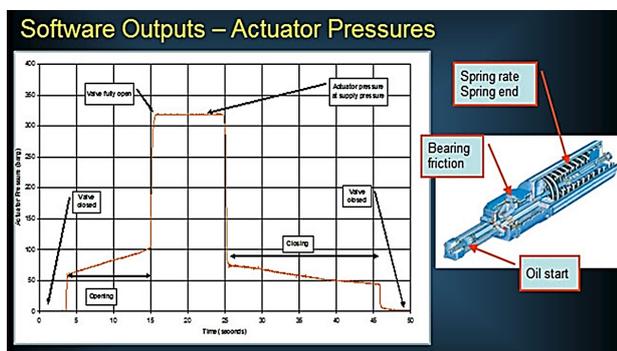
válvula.

Essas abordagens de comparação de assinaturas podem ser observadas em trabalhos como o de Bencomo em 2012 (Bencomo, 2012).

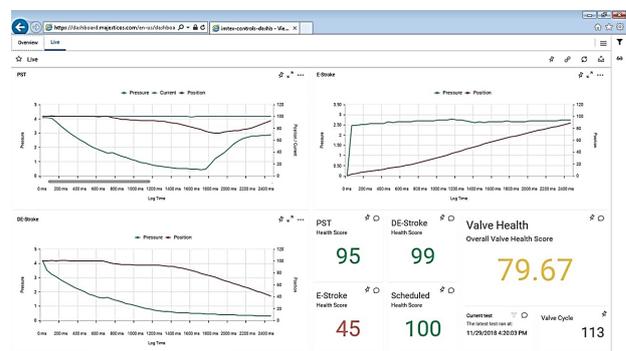
Essas soluções comerciais oferecem uma alternativa para as indústrias que buscam monitorar suas válvulas de bloqueio, mas muitas vezes, os detalhes técnicos específicos são protegidos como propriedade intelectual das empresas desenvolvedoras. Portanto, a escolha entre soluções comerciais e abordagens acadêmicas ou internas depende das necessidades e recursos de cada empresa.

Figura 25: Softwares comerciais direcionados ao monitoramento de ESDV utilizando as assinaturas de pressão e emissão acústica como formas de monitoramento no âmbito industrial.

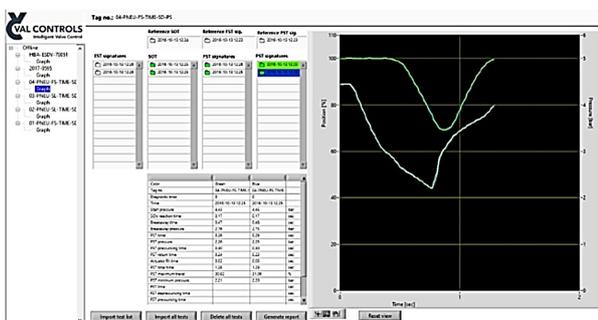
(a) Software V-Map.



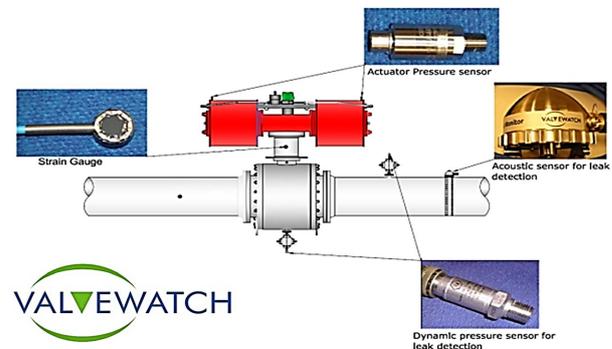
(b) Software IMtex



(c) Software ValControls.



(d) Software ValveWatch.



Fonte: Próprio Autor.

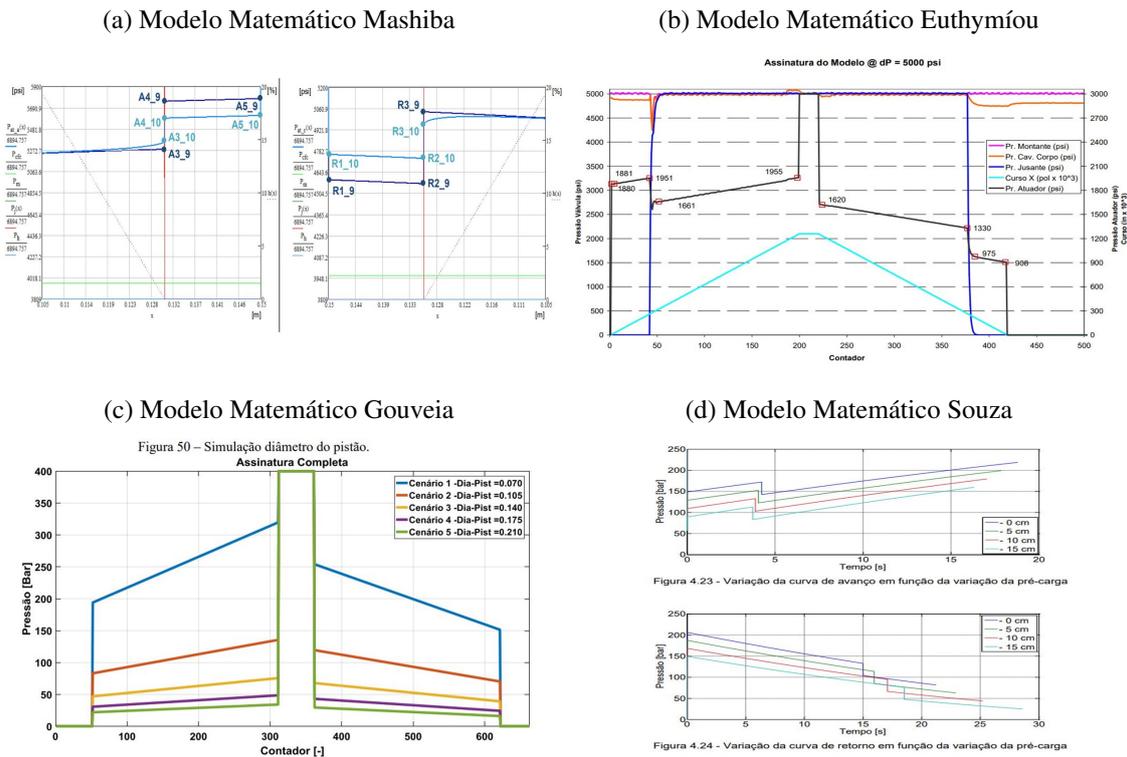
## 2.6.1 Modelos matemáticos

Para o monitoramento desses equipamentos, também é encontrada na literatura uma abordagem baseada em modelos matemáticos. Nesses estudos, equações que descrevem o funcionamento das válvulas de bloqueio e também as ESDVs, são desenvolvidas para gerar as assinaturas de pressão como saída. Esses modelos utilizam os dados construtivos de uma válvula de bloqueio para estimar sua assinatura de pressão. Esses parâmetros englobam uma variedade de características, desde o coeficiente de rigidez da mola elástica até os níveis de atrito do O'ring contra o êmbolo do pistão localizado na câmara do atuador, além do comprimento do umbilical que alimenta o sistema.

As assinaturas de pressão, modeladas por essas equações, fornecem informações valiosas sobre

o funcionamento e o desempenho da válvula. Essas informações podem ser utilizadas para monitorar o estado da válvula, identificar possíveis falhas ou anomalias e tomar decisões proativas de manutenção. A Fig. 26 ilustra visualmente as assinaturas de pressão geradas pelos modelos matemáticos desenvolvidos para esse fim. Essa abordagem oferece uma ferramenta poderosa para o monitoramento contínuo da integridade e eficiência das válvulas submarinas em operações críticas.

Figura 26: Modelos matemáticos, sejam estáticos ou dinâmicos, estão apresentados através da assinatura de pressão por diferentes autores e evidenciam o potencial de simulação de comportamentos associado a falhas nas ESDVs.



Fonte: Adaptado de Mashiba (2011); Euthymíou (2013); Gouveia (2018); Souza (2019).

Em 2011, Mashiba (2011), desenvolveu um modelo estático do funcionamento de uma ESDV utilizando uma válvula gaveta submarina. Euthymíou (2013), expandiu a metodologia e aplicou modelos matemáticos a uma ESDV gaveta, porém, inserindo simulações de desgastes aos componentes da gaveta. Estas simulações foram realizadas pelo método de Monte Carlo baseado em distribuições estatísticas resultantes do conhecimento do autor e de conversas com os fabricantes das ESDVs que descrevam a probabilidade de falha em função do número de ciclos.

Gouveia (2018), modelou uma ESDV, porém, do tipo esfera. O modelo era estático e o autor abordou as mudanças de parâmetros construtivos e simulações de degradações da ESDV, as saídas foram, assim como os trabalhos anteriores, as assinaturas de pressão.

Souza (2019), ampliou todos os trabalhos anteriores, desenvolvendo um modelo dinâmico, e analisando a influência do tempo de acionamento em uma ESDV com válvula esfera, inserindo a

influência com comprimento do umbilical em operações *subsea*, além da influência da lâmina d'água e mudanças dos parâmetros construtivos. O modelo também resultou nas assinaturas de pressão, mas em função do tempo de acionamento, como descreve a Fig. 26.

Teles (2020), contribuiu modelando os valores de torque para uma válvula esfera também utilizando os parâmetros construtivos de uma válvula esfera *trunnion*. Esta análise pode ser ampliada e adicionada aos modelos anteriores descritos, resultando em modelos matemáticos mais robustos e condizentes com a realidade.

Estes trabalhos mostram uma tendência da indústria na busca de modelar o comportamento de tais equipamentos, a fim de se entender seu comportamento relacionado, principalmente, as falhas. Com isto, as simulações das assinaturas, buscam fornecer uma compreensão do impacto das falhas, na assinatura, somando-se o conhecimento obtido nestes modelos, que embora digitais, podem contribuir para os operadores destes equipamentos a identificar e reconhecer modos de falhas quando ocorridos em campo, uma vez que instrumentação das ESDVs, sejam aplicados.

Com a evolução dos métodos de *Machine Learning*, abre-se ainda, a possibilidade de explorar e mesclar os modelos matemáticos com os chamados “gêmeos digitais” (em inglês, *Digital Twin*), que buscam simular os sinais e comportamentos de ativos e equipamentos através do modelamento matemático, ou mesmo mediante o uso de técnicas de *Data-Driven*.

## 2.7 Processamento de sinais no monitoramento de válvulas

Esta seção irá expor o funcionamento dos algoritmos de processamento de sinais, utilizando alguns conceitos de aprendizado de máquina. Porém, como já abordado na Sec. 1.6, a aplicação deste conceito somente se dá, caso o banco de dados utilizado consiga generalizar o funcionamento de todas as válvulas, bem como de todos os modos de falhas em uma válvula de bloqueio, além disto, deve apresentar a condição IID (ver Sec. 2.7.1).

### 2.7.1 Processamento por algoritmos de aprendizado de máquina

Antes de abordar os algoritmos é importante destacar o banco de dados que os alimenta, pois este deve possuir variáveis independentes e igualmente distribuídas (*Independent and Identically Distributed* - IID). Esta é uma suposição estatística que descreve a natureza dos dados utilizados em um modelo. Essa suposição é fundamental para a aplicação de muitos algoritmos de aprendizado de máquina, ao permitir que sejam feitas inferências estatísticas precisas a partir dos dados. O termo *Independent* afirma que as distribuições não estão relacionadas entre si, ou seja, a observação de uma ocorrência, não influencia na outra, como, por exemplo, ao jogar uma moeda para o alto esperando obter cara ou coroa.

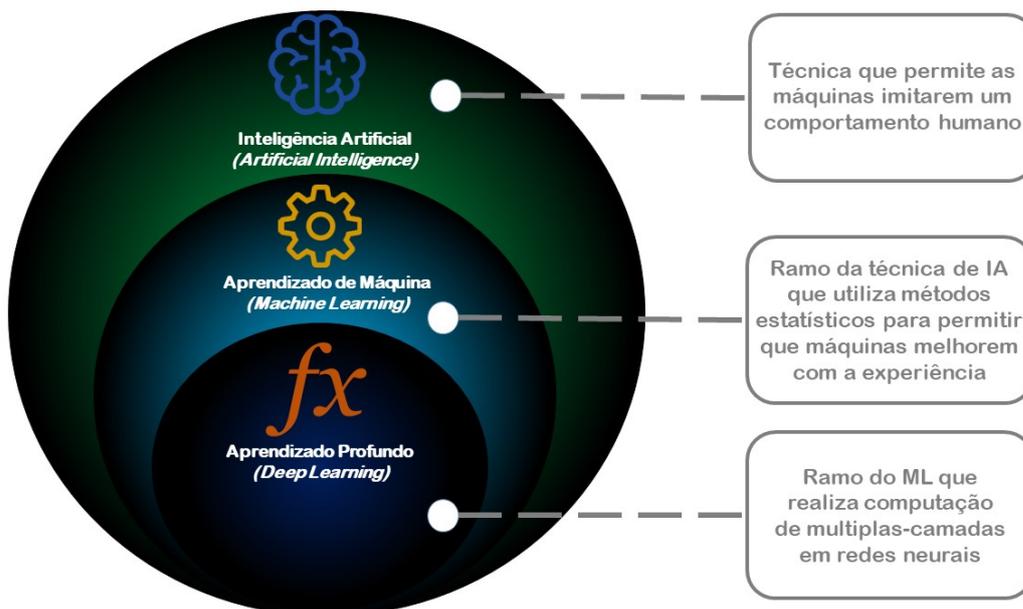
O termo *Identically Distributed* implica que todas as observações são resultados da mesma distribuição de probabilidade. A partir destas duas premissas, inferências dos algoritmos de aprendizado de máquina podem ser aplicados. Outro ponto é que uma solução em aprendizado de máquina demandaria um banco de dados com válvulas de segurança de diferentes fabricantes,

resultando, por sua vez, em diferentes modos de falhas. Com estas ressalvas, o conceito de aprendizado de máquina será abordado com relação aos algoritmos utilizados nesta tese (El Naqa and Murphy, 2015; Zhou, 2021; Mahesh, 2020).

Os algoritmos de aprendizado de máquina são métodos matemáticos orientados aos dados que mesclam técnicas estatísticas, da computação, probabilidade e otimizações para realizarem decisões otimizadas baseadas em exemplos de aprendizagem.

Estes métodos matemáticos podem ser designados como algoritmos. Ele está em um domínio maior, chamado de Inteligência Artificial, como mostra a Fig. 27. Este é um amplo ramo do conhecimento relacionado a capacidade de uma máquina, no caso, algoritmos matemáticos, realizar uma tarefa de forma autônoma e contínua, com o mínimo de intervenção humana. Porém, um consenso sobre o que, de fato, define uma Inteligência Artificial (IA), não há. Porém, de maneira geral, uma máquina utilizando um método que a permita refletir as mesmas decisões e conclusões que um agente de inteligência, pode definir uma IA. Logo o intuito de uma IA é reproduzir os mesmos resultados que uma inteligência humana, melhorando a assertividade e a confiabilidade das decisões (El Naqa and Murphy, 2015; Zhou, 2021).

Figura 27: Domínio da Inteligência Artificial, Aprendizado de Máquina e Aprendizado Profundo.



Fonte: Adaptado de Edureka! (2024).

Para a aplicação dos algoritmos de aprendizado de máquina, existem 2 grandes grupos onde os algoritmos são divididos, os algoritmos supervisionado e os não supervisionados. Além de existir um terceiro grupo, chamado de aprendizado por reforço, o autor não irá abordar este conceito, visto que foge ao tema proposto neste trabalho.

No aprendizado supervisionado, são dispostos exemplos e casos que descrevem as características do problema a serem resolvidas. Estas características podem ser numéricas ou alfanumérica.

Associado ao problema, devemos ter uma saída que corresponde às características. Estas saídas serão o alvo último que o algoritmo deve aprender a reproduzir a partir das características fornecidas. Como nesse grupo, dos supervisionados, sempre existirá uma saída sendo “mostrada” ao algoritmo, ele estará sempre sob-supervisão. O grupo dos não-supervisionados, não recebem a saída, somente as características, logo, são aplicados algoritmos que buscam agrupar problemas com comportamentos semelhantes (Goodfellow et al., 2016).

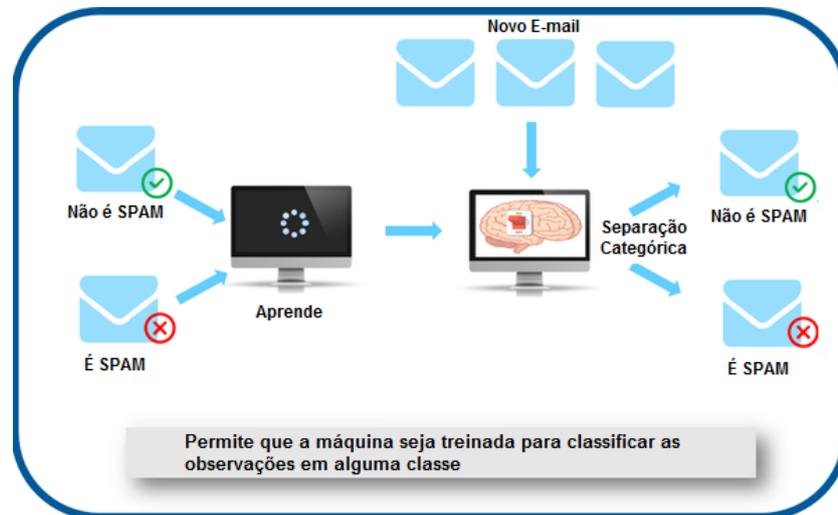
Porém, as classes de algoritmos não param nestes dois grupos e se ramificam ainda em outros tipos de soluções a depender do problema que se tem em vista solucionar. Eles serão tratados nas seções seguintes.

### 2.7.2 Algoritmos de classificação

O processo de classificação está relacionada com a tarefa de atribuir um rótulo, o qual é a saída, a um conjunto de características, ou *features*. De maneira geral, a saída pode ser o clássico "Sim" ou "não". Como a saída contém somente duas possibilidades, este exemplo é caracterizado como problema "Binário". Mas existem classificações multi-classes, onde os rótulos (saídas) podem apresentar mais de duas saídas, como, por exemplo; "sim", "não" e "talvez". Para simplificar, imagine que o algoritmo deve descobrir se um e-mail é *spam* ou não (binário). Para isso, ele buscará descobrir certas características de um típico e-mail de *spam* que o identifiquem como tal. Após o processo de treino, onde o algoritmo definiu as características que mais contribuem para identificar um *spam*, como, por exemplo, palavras como "Compre" e "Promoção", ele irá atribuir o rótulo, ou saída, em: "sim é spam" ou "não é spam". Poderíamos ainda treinar o algoritmo para reconhecer um e-mail de trabalho, de entrevista ou de uma oportunidade, dando exemplos na fase de treinamento. Este tipo de abordagem, onde se espera um rótulo e não um número contínuo, é chamado de "Classificação" (Goodfellow et al., 2016; El Naqa and Murphy, 2015; Programaria, 2020).

Em problemas de engenharia, existem inúmeras oportunidades de aplicação de algoritmos de classificação, desde reconhecimento de imagens relacionadas a defeitos em produtos em linhas de produção, até a identificação de um objeto em um via pública por um carro de direção autônoma.

Figura 28: Típico exemplo de problemas de classificação utilizando a decisão "é spam" ou "não é spam" associado aos e-mails recebidos.



Fonte: Programaria (2020).

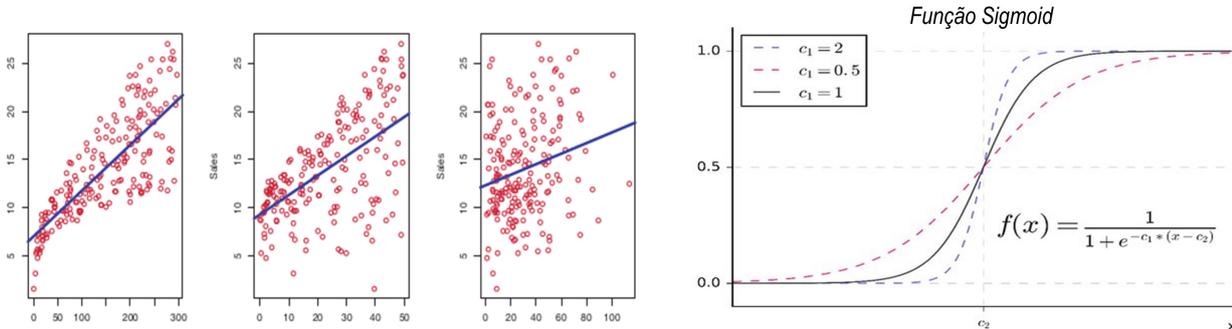
### 2.7.3 Algoritmos de regressão linear

Os algoritmos baseados na regressão linear são usados para mapear problemas e também usam características específicas do problema como entrada, assim como ocorre na classificação. A grande diferença, no entanto, está no tipo de saída que esses algoritmos produzem. Enquanto na classificação a saída é tipicamente binária (sim ou não), na regressão, as saídas são valores numéricos, embora também possam lidar com números discretos.

Apesar do nome "linear", que pode sugerir uma relação linear entre uma entrada  $x$  e uma saída  $y$ , isso não é necessariamente verdade para os algoritmos de regressão. Devido à natureza não linear dos modelos matemáticos usados nesse grupo de algoritmos, é possível extrair equações não lineares, dependendo do modelo selecionado. Isso significa que a relação entre as entradas e as saídas pode ser mais complexa e não seguir uma tendência linear, como exemplificado pelo uso da função sigmoide, ilustrada na Fig. 29 (Maulud and Abdulazeez, 2020; Ray, 2019; Pacheco, 2021).

Figura 29: Representações das regressões lineares e não lineares.

(a) Exemplos de regressões lineares de primeira ordem. (b) Exemplos da função *Sigmoid* que pode ser aplicado em Na adaptação aos dados, somente o coeficiente angular é problemas de regressões lineares afim de fornecer soluções alterado mudança a inclinação da reta. não-lineares.



Fonte: (Leibovich-Raveh et al., 2018; Pacheco, 2021).

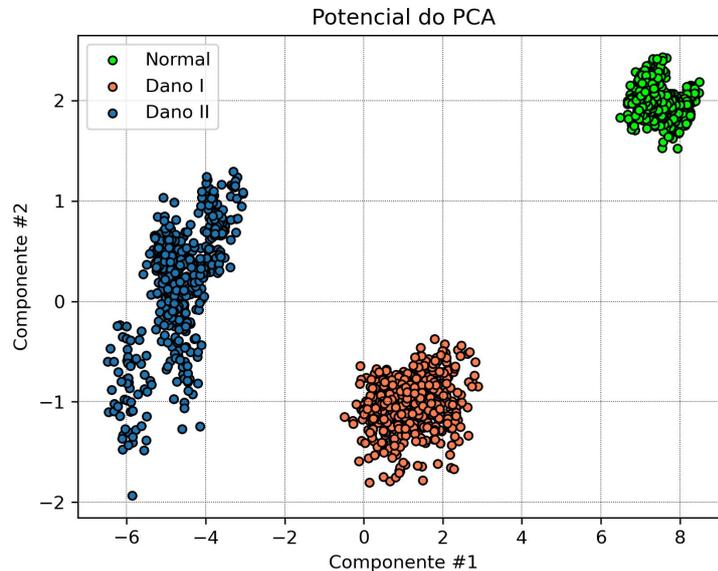
## 2.7.4 Algoritmos de agrupamento

A técnica de agrupamento, também conhecida como clusterização, é uma abordagem que pretende identificar padrões de semelhança entre os dados de entrada, organizando-os em grupos ou *clusters*. A principal diferença entre a técnica de agrupamento e outras abordagens, como a classificação, reside no fato de que na clusterização não são fornecidos rótulos ou categorias predefinidas para os dados. Em outras palavras, o algoritmo não possui informações sobre a que grupo ou categoria cada ponto de dados pertence. Em vez disso, ele analisa os dados com base em suas características intrínsecas e busca agrupá-los com base em semelhanças percebidas (Xu and Wunsch, 2005).

A clusterização é uma técnica não supervisionada, o que significa que o algoritmo realiza todo o processo de agrupamento sem orientação externa. Ele explora as relações e semelhanças nos dados, procurando criar grupos de pontos que sejam mais semelhantes entre si do que com os pontos de outros grupos. Por exemplo, um conjunto de dados que represente consumidores com base em várias características, como idade, renda e preferências de compra. Usando a clusterização, o algoritmo pode identificar automaticamente grupos de consumidores que compartilham características semelhantes, como na Fig. 30, onde dois tipos de falhas foram detectados e estão representados no espaço R2 de maneira distinta, apresentando uma fronteira de comportamento visível.

Esses grupos podem ainda representar diferentes perfis de clientes, como jovens com baixa renda, idosos com alta renda, equipamento com falha, espécies de animais, eventos climáticos, etc. A interpretação dos resultados da clusterização pode ser desafiadora, especialmente quando os dados têm muitas dimensões. Portanto, em muitos casos, é necessário reduzir a dimensionalidade dos dados para facilitar a análise e a compreensão dos agrupamentos identificados (Rodriguez et al., 2019; Xu and Wunsch, 2005).

Figura 30: Agrupamento de sinais aplicado aos dados de uma válvula de bloqueio que apresentou dois tipos de danos.



Fonte: Próprio Autor.

### 2.7.5 Redução de dimensionalidade

Dependendo do tipo de problema em questão, diversos atributos ou características são fornecidos aos modelos de aprendizado de máquina. Essas características podem ter um impacto variável no resultado do modelo.

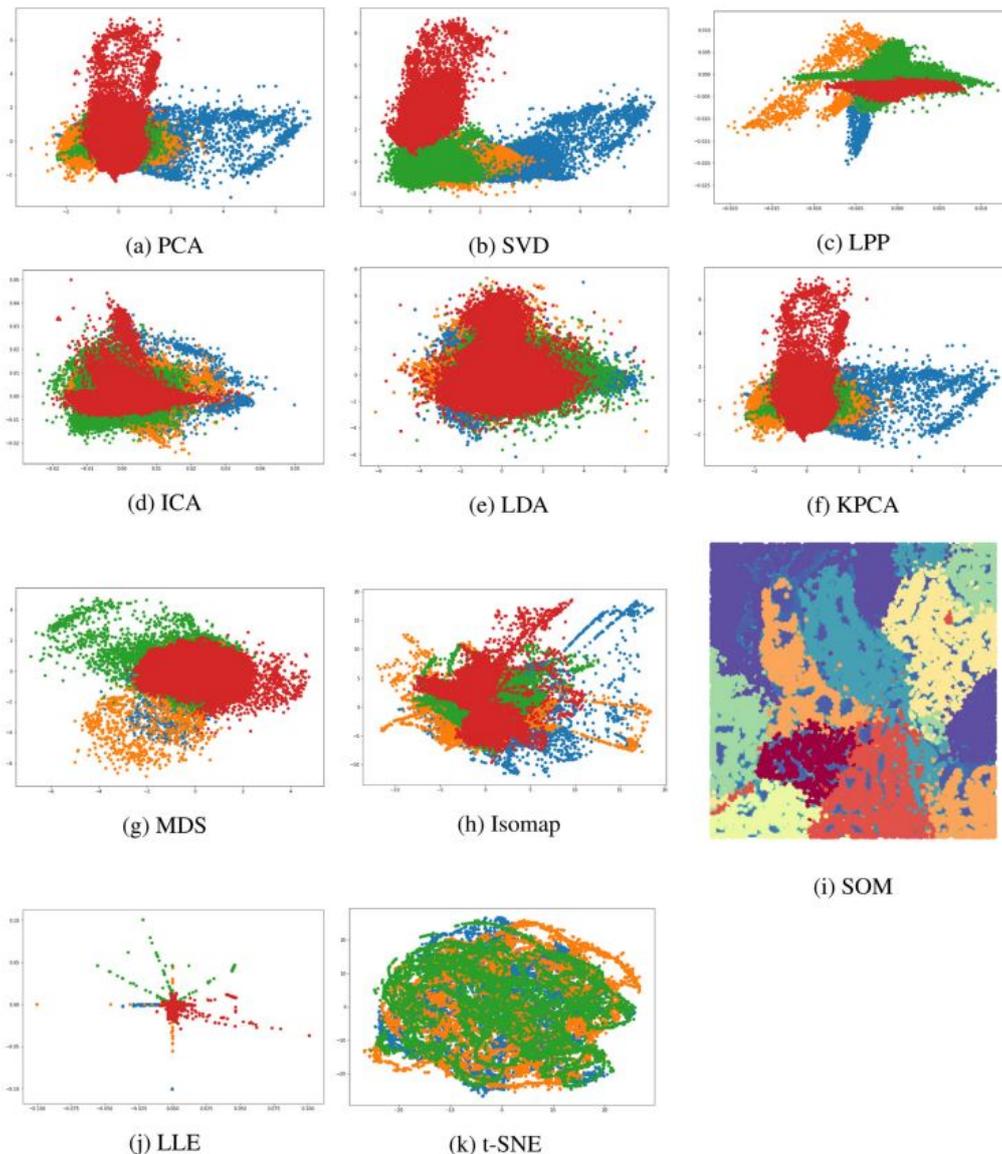
Em situações em que determinadas características não contribuem significativamente para o resultado final, elas acabam consumindo recursos computacionais durante a fase de treinamento, sem proporcionar benefícios substanciais. Outro aspecto relevante a considerar é o número elevado de características. Dentre as opções de algoritmos de redução encontrados na literatura, alguns estão dispostos conforme Fig. 31. Onde algumas características do conjunto de dados são mais evidenciadas que outras a depender da escolha do algoritmo. Como o foco deste trabalho não é realizar uma extensa explicação sobre cada modelo, para mais informação, consultar literaturas que abordem este tema (Ayesha et al., 2020).

Um modelo pode aprender eficazmente a representar a saída de um problema durante a fase de treinamento, mas esse aprendizado excessivo pode resultar em um desempenho inadequado durante a fase de teste. Esse fenômeno é conhecido como *overfitting* (sobreajuste), no qual o modelo se adapta demais aos dados de treinamento específicos, tornando-se menos capaz de generalizar para novos dados.

Em contrapartida, pode ocorrer o *underfitting* (subajuste), no qual o modelo de treinamento é inadequado e não consegue capturar o comportamento geral dos dados de saída (Lee et al., 2007).

A Figura 32 ilustra esses comportamentos, mostrando como o *overfitting* resulta em um modelo

Figura 31: Exemplos de diversos algoritmos de redução da dimensionalidade.



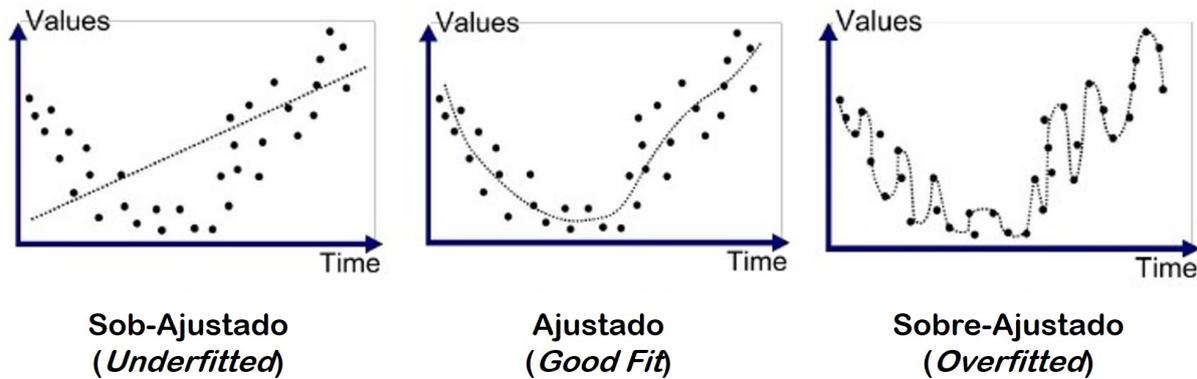
Fonte: Adaptado de Ayesha et al. (2020).

que se ajusta excessivamente aos dados de treinamento, enquanto o *underfitting* leva a um modelo que não consegue representar adequadamente os dados de treinamento.

Esses problemas de *overfitting* e *underfitting* podem ser mitigados por meio de técnicas de seleção e redução de características, como a redução de dimensionalidade, que visa preservar as informações mais relevantes enquanto elimina características redundantes ou menos informativas. Isso ajuda a melhorar a capacidade do modelo de generalizar para novos dados e, conseqüentemente, aprimora seu desempenho.

Este fenômeno de *overfitting* e *underfitting* afeta todos os tipos de modelos de aprendizado de máquina, independentemente de serem supervisionados ou não supervisionados, de agrupamento ou de deep learning. Para mitigar esses problemas, uma abordagem comum é a redução da

Figura 32: Problemas de *Overfitted* e *Underfitted* aos dados, muitas vezes estão associados a quantidade de características (*features*) usadas durante o treino. Logo uma redução na dimensionalidade é aplicada.



Fonte: Adaptado de de Ciências de Dados (2020).

dimensionalidade das características do problema. Esse processo envolve a aplicação de técnicas matemáticas que buscam preservar a maior quantidade possível de informações originais usando um conjunto menor de características (Lee et al., 2007; Ayesha et al., 2020).

Um método amplamente utilizado para redução de dimensionalidade é a Análise da Componente Principal, conhecida como “PCA”, do inglês *Principal Component Analysis*.

O PCA visa identificar os eixos que representam a maior variância nos dados, ordenando-os conforme a variância capturada.

Isso permite determinar quais eixos contêm a maior quantidade de informações. Em alguns casos, usando apenas os primeiros eixos identificados pelo PCA, é possível preservar até 98% das informações originais, mesmo usando apenas duas ou três características. É importante ressaltar que não existe uma regra fixa para a aplicação do PCA, e cada caso deve ser analisado individualmente, pois a eficácia da redução de dimensionalidade pode variar dependendo dos dados e do problema em questão (Ayesha et al., 2020). A Figura 33 ilustra de forma simplificada como o PCA funciona.

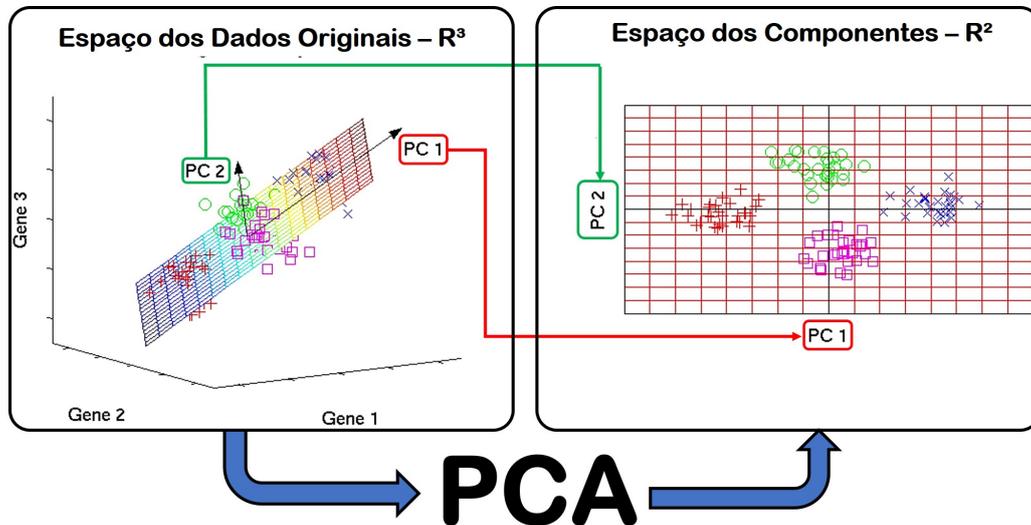
Essas técnicas de redução de dimensionalidade desempenham um papel fundamental no pré-processamento de dados para melhorar a eficácia dos modelos de aprendizado de máquina, tornando-os mais capazes de generalizar para novos dados e evitar problemas como *overfitting* e *underfitting*.

### 2.7.6 Redes neurais artificiais

As Redes Neurais Artificiais (RNA), ou *Artificial Neural Network* (ANN) em inglês, são algoritmos de alto nível projetados para emular o comportamento do cérebro humano e sua capacidade de aprender por meio da experiência. O cérebro humano é um órgão complexo composto por bilhões de neurônios, as unidades fundamentais do sistema nervoso.

Cada neurônio é composto por três partes principais: dendritos, corpo celular e axônio. Os

Figura 33: Ilustração simplificada do funcionamento do PCA (Análise da Componente Principal) na redução da dimensionalidade dos dados. O PCA identifica os eixos que capturam a maior variância nos dados, permitindo uma representação mais compacta das informações originais.

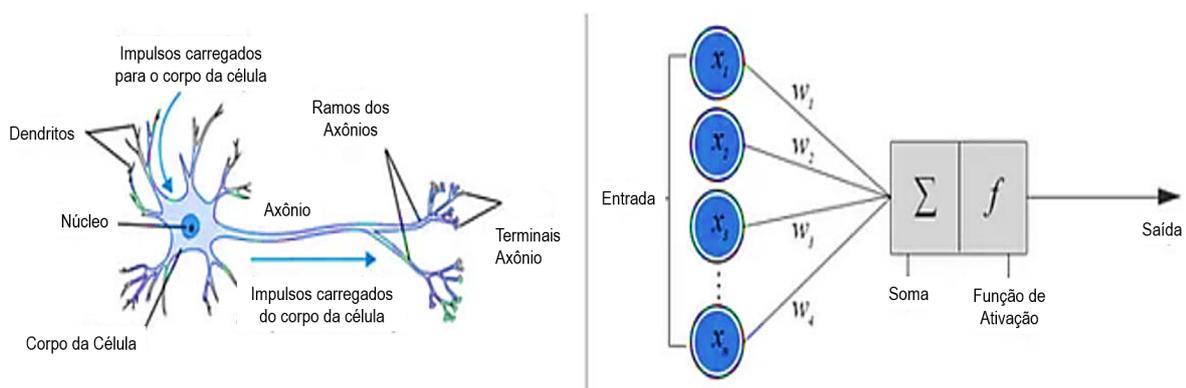


Fonte: Adaptado de AnalyticsVidhya (2016).

dendritos desempenham o papel de portas de entrada para os sinais nervosos, capturando estímulos ao longo de um intervalo de tempo. Esses estímulos são, então, transmitidos para o corpo celular, onde são processados. Quando a acumulação desses estímulos atinge um limite determinado, um novo impulso nervoso é gerado e propagado ao longo do axônio, o qual é uma estrutura semelhante a um fio, transmitindo o impulso para as células vizinhas por meio de sinapses.

Esse processo de transmissão de sinais pode se repetir em várias camadas de neurônios, onde um neurônio alimenta o próximo em uma cascata de processamento de informações (Haykin, 2001). A Figura 34 exibe um neurônio biológico e suas partes fundamentais.

Figura 34: Representação de um neurônio biológico (esquerda) e um artificial (direita).



Fonte: Adaptado de Roell (2017).

As redes neurais artificiais foram inspiradas no funcionamento do cérebro humano e buscam

replicar esse processo de aprendizado por meio de algoritmos matemáticos. Elas são compostas por unidades computacionais chamadas neurônios artificiais, organizados em camadas e conectados por pesos ajustáveis. O treinamento de uma rede neural artificial envolve o ajuste desses pesos com base em um conjunto de dados de treinamento, permitindo que a rede aprenda padrões e realize tarefas específicas, como classificação, regressão, processamento de imagem, entre outras. O cérebro humano pode rearranjar as disposições dos neurônios a depender de um novo conhecimento ou experiência, resultando em alterações estruturais. Isto é realizado através do reforço ou inibição de algumas sinapses que inabilitam o neurônio (Ferneda, 2006; Grossberg, 1988).

Um dos primeiros trabalhos que buscaram reproduzir o comportamento de um neurônio biológico artificialmente, foi o trabalho de Rosenblatt, em 1958 (Rosenblatt, 1958). Neste trabalho foram usados apenas uma camada de neurônio, que recebeu o nome de *Perceptron*. Este modelo artificial é composto por entradas (dendritos), camada (corpo) e saída (axônio) assim como no neurônio biológico. As entradas são as informações numéricas, multiplicadas por um peso e um *viés* aleatório antes de chegarem na camada. Ao chegarem na camada, elas são somadas e comparadas com um "limiar" que irá decidir se informação será passada para a saída ou não.

Este limiar segue funções matemáticas baseada em regras definidas por curvas pré-estabelecidas. Este limiar, é definido como a função de ativação. É esta função que determina se o neurônio carrega informação relevante ou que poderá ser descartada. Caso a informação numérica calcula ative o limiar, ela é direcionada para a saída e poderá alimentar o próximo neurônio. Um esquema que representa este processo pode ser visto na Fig. 34 (Mishra and Srivastava, 2014).

As funções de ativação majoritariamente são as responsáveis por definir se a informação segue adiante ou não, por esta razão, elas recebem uma atenção mais específica. Portanto, existem algumas variações dentre as disponíveis para o uso nas ANN. A Fig. 35 mostra as mais utilizadas e conhecidas (Ramachandran et al., 2017b; Roell, 2017).

Para cada problema, seja de natureza linear ou não-linear, uma função será mais apropriada, logo, não existe uma função que performe de maneira excelente para todas as abordagens. Com isto, autores concluem que a definição da função de ativação que deverá ser utilizada, segue um método *eurístico*, onde tentativas e erros são aplicados aos algoritmos e as métricas são monitoradas a fim de maximizá-las ou minimizá-las (Luus et al., 2015; Hansen et al., 1999).

Para problemas do tipo classificação, as funções de ativação mais indicadas são as do tipo *Sigmoid* e *Tanh* e suas variações. Para as abordagens de regressão linear, utilizando *deep learning*, as funções mais indicadas seriam as do tipo Linear e *ReLU* e *Leaky ReLU* (Zhang et al., 2018).

As funções de ativação desempenham um papel crucial nas redes neurais artificiais (ANN) e são responsáveis por determinar se as informações devem ser transmitidas adiante na rede. Devido a essa importância, uma variedade de funções de ativação está disponível para uso em ANN, cada uma adequada para diferentes tipos de problemas. A Figura 35 mostra algumas das funções de ativação mais comuns e conhecidas (Sharma et al., 2017b)

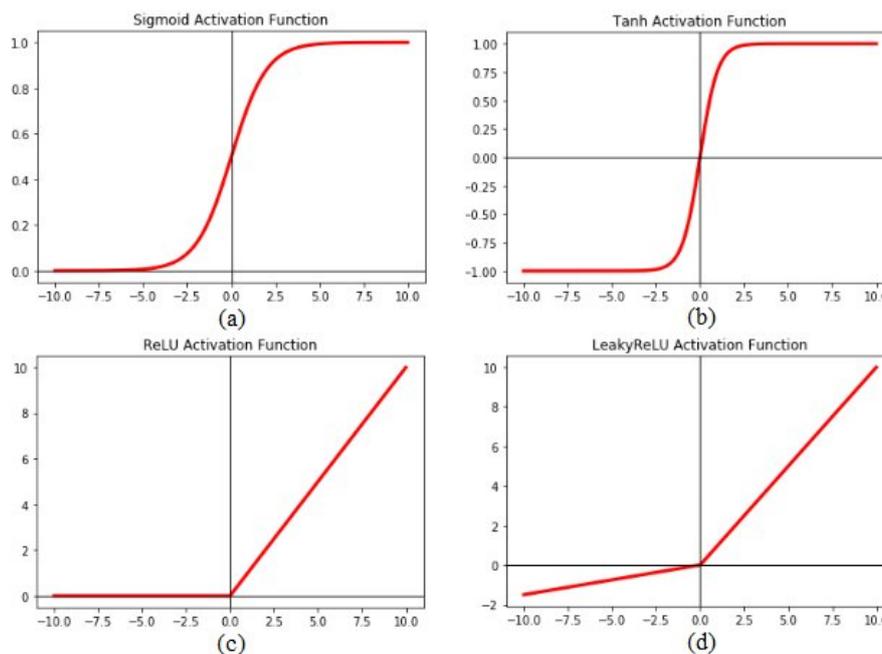
Não existe uma função de ativação universal que funcione de maneira excelente para todos os tipos de problemas. Portanto, a escolha da função de ativação mais apropriada muitas vezes segue

uma abordagem heurística, envolvendo tentativas e erros, monitorando métricas para maximizá-las ou minimizá-las durante o treinamento da rede. Isso significa que a seleção da função de ativação é altamente dependente do problema específico que está sendo abordado. Para problemas de classificação, as funções de ativação mais indicadas costumam ser aquelas do tipo "Sigmoid" e "Tanh", juntamente com suas variações.

Por outro lado, em abordagens de regressão linear utilizando redes neurais profundas, as funções de ativação mais adequadas costumam ser aquelas do tipo Linear, "ReLU" (Unidade Linear Retificada) e "Leaky ReLU" (Unidade Linear Retificada Vazando). Essa variedade de funções de ativação permite que as redes neurais se adaptem a uma ampla gama de problemas, desde tarefas simples até problemas complexos de aprendizado de máquina.

A escolha adequada da função de ativação é uma parte fundamental do projeto e treinamento de uma rede neural para garantir um desempenho ótimo em uma tarefa específica (Sharma et al., 2017a; Ramachandran et al., 2017a; Agatonovic-Kustrin and Beresford, 2000).

Figura 35: Funções de ativação utilizadas em ANNs (*deep learning*).



Fonte: Kandel and Castelli (2020).

### 2.7.7 KAN - *Kolmogorov Arlond Network*

Uma nova rede neural que surgiu recentemente, é a chamada KAN (*Kolmogorov Arlond Network*, onde são utilizadas as mesmas estruturas de uma rede neural, porém, as funções de ativação, em uma rede neural convencional, são fixas nos neurônios, já nas KANs, todo parâmetro de peso é substituído por uma função parametrizada univariada em forma de uma *spline* (Schmidt-Hieber, 2021).

Em testes publicados em estudos, como por Liu et al. (2024), as KAN obtiveram resultados melhores que as redes em tarefas de classificação, utilizando um menor conjunto de dados.

O uso das KANs foge do proposto por este trabalho, porém, sua aplicação pode ser de extremo potencial, devido ao seu poder de abstrair padrões com um número menor de dados, como os dados de válvulas de bloqueio.

### 2.7.8 Series temporais

Os algoritmos de séries temporais são técnicas que procuram prever o próximo valor alvo de um conjunto de números, discretos ou contínuos. Estes valores se referem a uma sequência de observações, ou também medidas, que foram coletadas ao longo do tempo. Uma de suas principais características é que as séries temporais devem ser organizadas de forma cronológica, variando apenas o intervalo, que pode ser regular ou irregular. Vários ramos do conhecimento utilizam as séries temporais, como estudos em finanças, economia, previsão de demanda, dados climáticos, produção industrial, vida útil de equipamento, entre outros. A previsão de valores futuros é baseada somente nos valores anteriores conhecidos (Chatfield, 2000).

O algoritmo visa extrair padrões, comportamentos e perincipalmente, tendências associadas aos dados ao longo do tempo. É uma forma mais especializada de algoritmos de regressão (ver Sec. 2.7.3, que, na literatura, são conhecidos como modelos "Auto-Regressivos" (Hamilton, 2020).

Existem abordagens para se analisar os dados de maneira espectral, onde se aplicando uma transformada de *Fourier* é possível extrair padrões e comportamentos da série no domínio da frequência. Tem-se ainda análises estatísticas, onde as características da série são focadas na sua densidade de probabilidade (PDF) de ocorrer e com isso os momentos estatísticos poderão ser obtidos. Pode-se optar por reconhecer anomalias nos sinais, onde pontos ou valores que possuem um comportamento distante de uma média esperada, onde estes podem indicar mudança de comportamento na série e ser associado a defeitos.

As ANNs são aplicadas também na análise de séries temporais, como dados financeiros, previsões meteorológicas, produção industrial, entre outros. No entanto, ao lidar com séries temporais, as ANN podem se beneficiar de uma arquitetura especializada chamada Redes Neurais Recorrentes (RNN) (Canizo et al., 2019).

A principal diferença entre as ANN tradicionais e as RNN é a capacidade destas últimas de lidar com dados sequenciais ou séries temporais. Em uma RNN, os neurônios são organizados de forma que as saídas de uma camada anterior possam retroalimentar a camada seguinte. Isso cria uma conexão temporal, permitindo que a rede mantenha uma memória interna das informações processadas anteriormente.

Essa capacidade de memória é fundamental para lidar com dados sequenciais, uma vez que permite que a rede aprenda com base em eventos passados em uma sequência. Por exemplo, ao prever o próximo valor em uma série temporal, como o preço das ações, é crucial considerar informações anteriores, como os preços das ações em dias anteriores. Em suma, as Redes Neurais Recorrentes (RNN) são uma variação das redes neurais artificiais (ANN) projetada especificamente para lidar com séries temporais e dados sequenciais, permitindo que a rede mantenha uma memória interna das informações passadas para melhorar suas previsões e análises (Qin et al., 2017; Zhang and Man,

1998).

### 2.7.8.1 Long Short Term Memory - LSTM

As redes neurais recorrentes (RNNs) apresentaram um salto no processamento de dados sequenciais, porém enfrentaram desafios na retenção de informações em longos termos, como na análise de frases ou texto longo e em séries temporais com tamanho maiores. Isto se deu devido ao desaparecimento do gradiente de correção, quando aplicado a regra da cadeia na atualização dos pesos de cada neurônio.

Para solucionar estes problemas, surge então a LSTM (*Long Short-Term Memory*), uma arquitetura especializada em superar as limitações temporais das RNNs. Ao contrário das RNNs tradicionais, as LSTMs foram projetadas para capturar relações temporais em dados sequenciais de maneira mais eficaz. Esse recurso permite a aprendizagem eficaz de padrões temporais em sequências longas. Seu design incorpora unidades de memória, células e portões, permitindo a retenção seletiva de informações por períodos prolongados (Ma and Mao, 2020).

A LSTM é composta por três portões essenciais - esquecimento, entrada e saída conforme 36. Cada um é responsável por controlar o fluxo de informações na célula de memória, proporcionando à LSTM sua habilidade única de processar sequências temporais extensas. As LSTM diferem das redes neurais na nomenclatura, pois ao invés de usarmos "neurônios", utilizamos "células" (Chen and Chang, 2021; Ma and Mao, 2020).

A célula LSTM consiste em uma célula de memória ( $c_t$ ) e três estruturas de portão: o portão de entrada ( $i_t$ ), o portão de esquecimento ( $f_t$ ) e o portão de saída ( $o_t$ ). No momento  $t$ ,  $x_t$  representa os dados de entrada e  $h_t$  representa o estado da camada oculta. O símbolo  $\times$  representa o produto externo de vetores e o símbolo  $+$  representa a operação de sobreposição.

As fórmulas de operação da LSTM são mostradas nas Eq. (1)–(6). Onde,  $U$  e  $W$  representam pesos de matriz,  $b$  representa o deslocamento,  $\sigma$  é a função sigmoide e o símbolo  $\cdot$  representa o produto dos vetores (Chen and Chang, 2021; Ma and Mao, 2020; Wang et al., 2022).

$$f_t = \sigma(U_f x_t + W_f h_{t-1} + b_f) \quad (1)$$

$$i_t = \sigma(U_i x_t + W_i h_{t-1} + b_i) \quad (2)$$

$$\tilde{c}_t = \tanh(U_c x_t + W_c h_{t-1} + b_c) \quad (3)$$

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tilde{c}_t \quad (4)$$

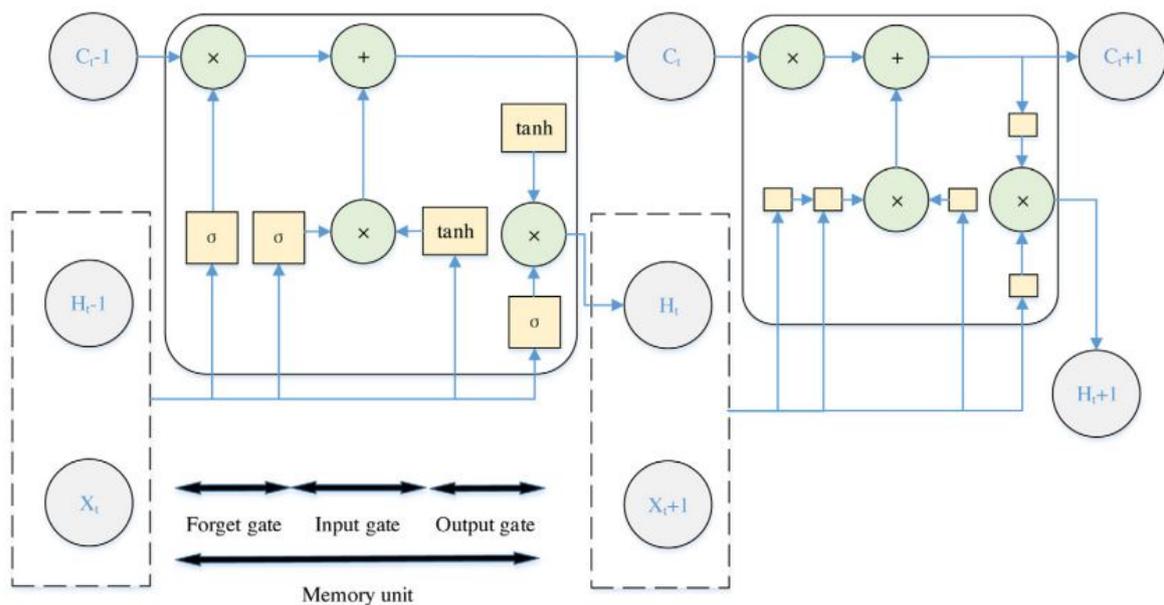
$$o_t = \sigma(U_o x_t + W_o h_{t-1} + b_o) \quad (5)$$

$$h_t = o_t \cdot \tanh(c_t) \quad (6)$$

O portão de esquecimento decide o que deve ser descartado da célula de memória anterior  $c_{t-1}$ . É calculado aplicando a função sigmoide à combinação linear dos dados de entrada  $x_t$  e o estado da camada oculta anterior  $h_{t-1}$ . O portão de entrada decide quais valores atualizar na célula de memória.

É calculado aplicando a função sigmoide à combinação linear dos dados de entrada  $x_t$  e o estado da camada oculta anterior  $h_{t-1}$ . O vetor de candidato à nova célula cria novos valores candidatos que podem ser adicionados ao estado da célula. É calculado aplicando a função tangente hiperbólica ( $\tanh$ ) à combinação linear dos dados de entrada  $x_t$  e o estado da camada oculta anterior  $h_{t-1}$ . O novo estado da célula de memória é uma combinação do estado da célula anterior  $c_{t-1}$ , modulado pelo portão de esquecimento  $f_t$ , e o novo candidato à célula  $\tilde{c}_t$ , modulado pelo portão de entrada  $i_t$ . O portão de saída decide qual parte do estado da célula será usada para a saída. É calculado aplicando a função sigmoide à combinação linear dos dados de entrada  $x_t$  e o estado da camada oculta anterior  $h_{t-1}$ . Por fim, o novo estado da camada oculta é obtido aplicando a função tangente hiperbólica ao novo estado da célula  $c_t$ , modulado pelo portão de saída  $o_t$  (Yu et al., 2019).

Figura 36: Unidade de memória de uma LSTM



Fonte: Chen and Chang (2021).

## 2.7.9 Métricas aplicadas em algoritmos

Para avaliar se um algoritmo de ML apresenta capacidade de aprender conforme os dados fornecidos, é preciso obter uma pontuação, ou métrica, para comparar a evolução do algoritmo ao longo do aprendizado e para compará-lo com outros algoritmos. Para cada campo do ML, seja classificação ou regressão, existem métricas mais adequadas. Portanto, uma explicação das métricas utilizadas neste trabalho, será abordado nas seções posteriores.

### 2.7.9.1 MSE e MAE para Regressão

Para a regressão, onde saídas numéricas são esperadas pelo algoritmo, as métricas mais utilizadas são o *Mean Squared Error* (MSE) e o *Mean Absolute Error* (MAE). Estes dois modelos quantificam

as diferenças entre os valores previstos e os valores reais. O MSE penaliza grandes erros, devido ao termo quadrático. Para o MAE, a penalização ocorre linearmente, ou seja, quanto maior a diferença entre a saída real e a prevista, maior a pontuação. Em ambos os casos, uma pontuação excelente se dá quando a métrica se aproxima de zero (Chicco et al., 2021).

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (1)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2)$$

onde  $y_i$  são os valores reais,  $\hat{y}_i$  são os valores previstos pelo modelo e  $n$  é o número de observações. Essas métricas são essenciais para avaliar a precisão de modelos de regressão, fornecendo uma medida clara de quão próximas às previsões do modelo estão dos valores reais.

### 2.7.9.2 Curva ROC e AUC Score para classificação

Para as tarefas de classificação, onde se tem em vista determinar se um evento está relacionado a um estado, seja um defeito ou um e-mail do tipo spam, é necessária uma métrica que contabilize os acertos e erros. A Curva ROC (Receiver Operating Characteristic) é um gráfico que ilustra o desempenho de um modelo de classificação binário em diferentes limiares de decisão. Os eixos da Curva ROC consideram a razão entre os acertos e erros do algoritmo (Wang and Tang, 2009; Park et al., 2004).

No eixo Y da Curva ROC, temos a taxa de verdadeiros positivos (True Positive Rate, TPR), calculada como:

$$TPR = \frac{TP}{TP + FN} \quad (3)$$

onde  $TP$  é o número de verdadeiros positivos e  $FN$  é o número de falsos negativos. A TPR mede a proporção de positivos reais que foram corretamente identificados pelo modelo.

No eixo X, temos a taxa de falsos positivos (False Positive Rate, FPR), calculada como:

$$FPR = \frac{FP}{FP + TN} \quad (4)$$

onde  $FP$  é o número de falsos positivos e  $TN$  é o número de verdadeiros negativos. A FPR mede a proporção de negativos reais que foram incorretamente classificados como positivos.

A Curva ROC é traçada plotando a TPR contra a FPR para vários limiares de decisão. Um ponto na Curva ROC representa a taxa de verdadeiros positivos e a taxa de falsos positivos para um determinado limiar. O desempenho ideal seria alcançar uma TPR alta com uma FPR baixa, resultando em um ponto no canto superior esquerdo do gráfico. Para facilitar a interpretação da Curva ROC, é calculada a área abaixo da curva, conhecida como AUC (Area Under the Curve). O AUC score varia de 0 a 1, onde um valor de 1 indica um classificador perfeito e um valor de 0.5 indica um classificador que realiza previsões aleatórias. O AUC é uma medida agregada do desempenho do modelo em todos os limiares

possíveis (Wang and Tang, 2009; Park et al., 2004).

Para ilustrar, considere um modelo de classificação para detectar e-mails de spam. A Curva ROC desse modelo pode mostrar como ele se comporta em diferentes limiares de decisão. À medida que o limiar é ajustado, a taxa de verdadeiros positivos (TPR) e a taxa de falsos positivos (FPR) mudam. O AUC score resultante fornece uma métrica única que resume o desempenho do modelo: um AUC score próximo de 1 indicaria que o modelo é altamente eficaz em distinguir entre e-mails de spam e não spam.

### 2.7.9.3 Matriz de confusão para classificação dos algoritmos

Outra métrica utilizada para interpretar a tarefa de classificação é a chamada Matriz de Confusão, onde os acertos e erros do algoritmo de ML são exibidos. Nela também é possível verificar os verdadeiros positivos, falsos positivos, verdadeiros negativos e falsos negativos. Da pontuação da matriz, pode-se extrair uma série de outras métricas, como a precisão, *recall* e o fbeta-score (Xu et al., 2020; Luque et al., 2019).

A matriz de confusão é uma ferramenta fundamental na avaliação de modelos de classificação, permitindo uma visualização clara do desempenho do algoritmo em termos de suas predições corretas e incorretas. Ela é organizada de modo a mostrar as comparações entre os valores reais e previstos pelo modelo, conforme a tabela abaixo:

Tabela 5: Matriz de Confusão

	Predição Positiva	Predição Negativa
Real Positivo	Verdadeiro Positivo (TP)	Falso Negativo (FN)
Real Negativo	Falso Positivo (FP)	Verdadeiro Negativo (TN)

Fonte: (Xu et al., 2020; Luque et al., 2019).

Cada elemento da matriz tem um significado específico: - **Verdadeiro Positivo (TP)**: número de casos corretamente previstos como positivos. - **Falso Positivo (FP)**: número de casos previstos como positivos, mas que são negativos. - **Falso Negativo (FN)**: número de casos previstos como negativos, mas que são positivos. - **Verdadeiro Negativo (TN)**: número de casos corretamente previstos como negativos.

Esses valores permitem calcular diversas métricas importantes para a avaliação do modelo: - **Precisão (Precision)**:

$$\text{Precisão} = \frac{TP}{TP + FP} \quad (5)$$

A precisão indica a proporção de predições positivas corretas.

- **Recall (Sensibilidade)**:

$$\text{Recall} = \frac{TP}{TP + FN} \quad (6)$$

O recall mede a capacidade do modelo de identificar corretamente os casos positivos.

- **F1-Score:**

$$\text{F1-Score} = 2 \times \frac{\text{Precisão} \times \text{Recall}}{\text{Precisão} + \text{Recall}} \quad (7)$$

O F1-Score é a média harmônica da precisão e do recall, proporcionando uma única métrica que balanceia ambos.

- **Fbeta-Score:**

$$F_{\beta} = (1 + \beta^2) \times \frac{\text{Precisão} \times \text{Recall}}{(\beta^2 \times \text{Precisão}) + \text{Recall}} \quad (8)$$

O Fbeta-Score é uma generalização do F1-Score que permite ajustar a ênfase entre precisão e recall, sendo  $\beta$  um parâmetro que controla essa ênfase.

Essas métricas fornecem uma compreensão detalhada do desempenho do modelo, ajudando a identificar pontos fortes e fracos em diferentes aspectos da classificação. A matriz de confusão não só informa sobre a exatidão das predições, mas também orienta melhorias e ajustes nos algoritmos (Xu et al., 2020).

### 2.7.10 Fluxograma para aplicação dos algoritmos de monitoramento

Apesar de existirem diversos grupos de algoritmos que podem ser utilizados para monitorar um ativo, algumas premissas seguem para todas as aplicações, independente se os algoritmos são de classificação ou regressão. Portanto, esta seção se concentrará em explicar o fluxo de trabalho envolve a aplicação de um algoritmo conforme Fig. 37 exibe.

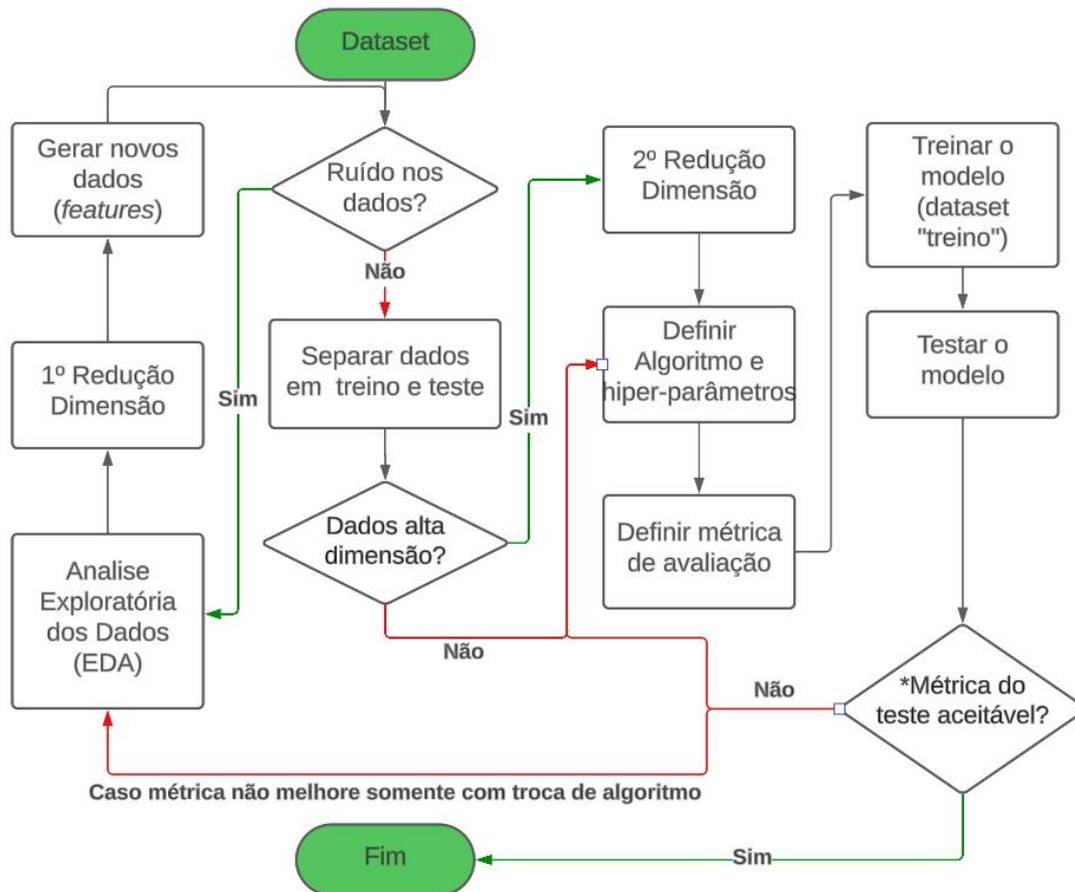
Primeiramente, se obtém os dados que serão usados para alimentar o algoritmo de processamento de sinais, isto marca o início do fluxo e esta representado pelo diagrama *Dataset* na cor verde. Após isto, o usuário irá verificar se os dados iniciais estão completos, sem *Not a Number (NaN)* ou *missing values* entre outros. Caso o banco de dados esteja aceitável, segue-se para a próxima atividade. Porém, em caso contrário, será necessária uma análise exploratória dos dados (EDA), para se entender o impacto destes valores faltantes. Em alguns exemplos, nesta fase, pode-se combinar as *features* (características) dos dados para gerarem novos *features*.

O uso de opções de redução da dimensão, também pode ser aplicada nesta etapa, para se gerar novas *features* a partir do *Dataset* original, aplicando-se, por exemplo, o PCA. Se o usuário avaliar que os dados são representativos, se passa para a próxima etapa.

A etapa seguinte consiste em uma boa prática aplicada a dados com alta dimensão e a sua redução. Este processo facilita a visualização espacial dos dados. Também pode-se citar que uma redução de dimensão irá demandar uma menor quantidade de processamento computacional se comparado com os dados no espaço original. Além disso, espaços reduzidos podem resolver problemas de *over-fitting* e *under-fitting*, citados na Sec. 2.7.5 (Lee et al., 2007)

Após concluir a manipulação dos dados e sua redução de dimensão, segue-se para a etapa centrada nos algoritmos. Dentre as opções de algoritmo, a depender se supervisionado ou não, de classificação ou regressão, com redes neurais ou series-temporais, o usuário deve definir seu algoritmo e os hiper-parâmetros que irão definir a taxa de aprendizado do modelo, a função de custo e a função de otimização, por exemplo. Seguinte a esta etapa, a escolha da métrica de avaliação é definida.

Figura 37: Fluxograma aplicado ao conjunto de dados.



Fonte: Próprio Autor.

A métrica tem por objetivo fornecer ao modelo um número que mensura o quão bom ou ruim é o resultado. Na literatura são apresentadas diversas formas para avaliar problemas de classificação como: matriz de confusão, curva ROC, acurácia, precisão entre outros. Já para problemas envolvendo regressões, existe o *Mean Squared Error (MSE)* e o *Mean Absolute Error (MAE)*. Após definidos estes pontos, inicia-se o treinamento do algoritmo.

Posterior a etapa de treino, a fase dedicada ao teste é conduzida. Nesta etapa se compara as métricas de teste e treino a fim de extrair informações quanto a aprendizagem do algoritmo. Esta etapa é uma das mais importantes no processo de aplicação do ML, sendo que, resultados não interpretados corretamente, resultam em modelo que não conseguirão extrair e generalizar respostas reais.

Neste momento, é crucial mencionar que a capacidade de generalizar os pressupostos do algoritmo para outros equipamentos, este diretamente relacionado a qualidade do *dataset*, ou banco de dados. Como já explicado na Sec. 2.7.1, caso o conjunto de dados não apresente certas características, como *IID*, generalizar as conclusões do algoritmo para outros ativos, não retornara uma resposta válida.

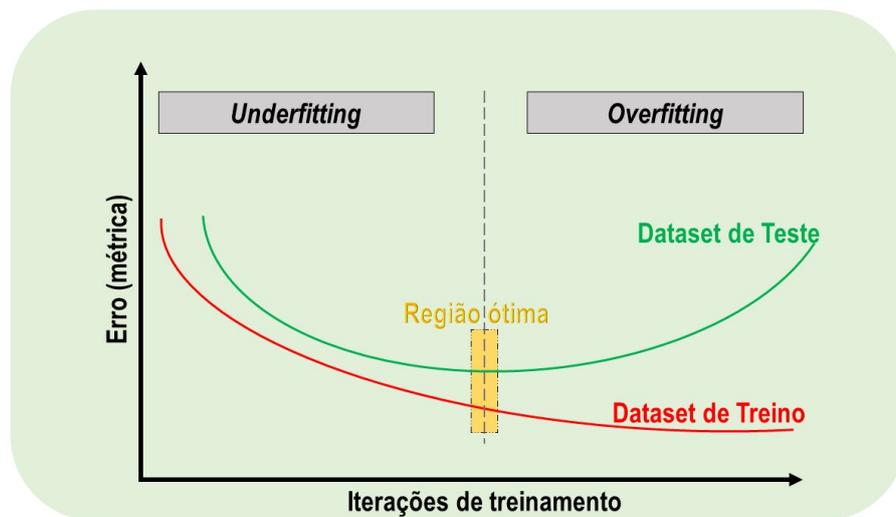
Retornando a importância das métricas e dos erros, a Fig. 38 retorna um exemplo onde o erro, que está associado a métrica, se comporta em função do número de iterações e dos conjuntos de dados de treino e teste. Nas primeiras iterações, o erro associado ao teste e ao treino apresentam valores

maiores.

Isto indica que o algoritmo não conseguiu aprender a extrair os padrões e comportamentos dos dados e por consequência, o teste performou de maneira pobre, ou seja, na área de *underfitting*.

Por outro lado, caso a pontuação do seu teste seja baixa e aceitável, nos critérios estabelecidos pelo usuário, e o erro usando os dados de teste aumenta com o passar das iterações, isto resulta que o algoritmo "decorou" as respostas durante a fase de treino e não conseguiu generalizar as saídas para os dados de teste. Este comportamento, é caracterizado como o *overfitting*.

Figura 38: Relação entre o erro do treino e teste.



Fonte: Próprio Autor.

## 2.8 Índices de Dano (*Damage Index*) - DIs

Além das técnicas de monitoramento convencionais apresentadas na Sec. 2.5, pode-se implementar aos sinais da ESDV, equações matemáticas que resumem todo o comportamento de um vetor (assinatura de pressão ou torque), em um único valor escalar. Seja cada ciclo da válvula, gerado um vetor depois do tratamento, este vetor poderá ser transformado em um valor escalar.

Aplicando esta abordagem a todos os ciclos da ESDV, ao fim, se obtém um vetor de posição  $1 \times N$ , sendo  $N$  o número de aberturas e fechamentos totais da ESDV. Isto facilita o estudo de possíveis degradações ao longo do tempo. Esta abordagem, recebe o nome de *Damage Index* - DIs. Na literatura, esta metodologia é aplicada em estruturas, no monitoramento da saúde (Silva, 2021; Lizé, 2018).

O conceito também foi aplicado para classificar danos de vazamento em sedes de ESDVs. Nesse contexto, os DIs apresentaram excelente desempenho, superando os KPs em termos de precisão e se aproximando significativamente dos resultados obtidos pela classificação que utilizou o sinal da assinatura completa (de Gouveia et al., 2024).

Adicionalmente, há trabalhos recentes que empregam o *Health Index* (HI), um conceito similar aos DIs, para monitorar a integridade de equipamentos. Por exemplo, (Zheng et al., 2021) demonstra o uso de redes neurais do tipo LSTM para estimar a vida útil remanescente de rolamentos, destacando a eficácia do HI nessa aplicação.

Tabela 6: Funções para gerar os DIs. Parte 1.

Nº	Função	Acrônimo	Expressão
1	Cross Correlation FFT	CC	$1 - \max \left( \frac{\text{IFFT}[\text{FFT}(x_1) \times \text{FFT}(x_2)^*]}{\sqrt{E_s(x_1) \times E_s(x_2)}} \right)$
2	Zero lag da CC	CC0	$1 - \hat{R}(x_1, x_2)(0)$
3	Ampl. Max. da CC	CCA	$1 - \max(\hat{R}(x_1, x_2))$
4	Cross-Corr. Max. Perc. Diff.	CCMPD	$1 - \left  \frac{\max(\hat{R}_{x_1, x_1}) - \max(\hat{R}_{x_1, x_2})}{\max(\hat{R}_{x_1, x_1})} \right $
5	CC-based Time of Flight perc. of diff.	CCTOF	$1 - \left  \frac{\text{argmax}(\hat{R}_{x_1, x_1}) - \text{argmax}(\hat{R}_{x_1, x_2})}{\text{argmax}(\hat{R}_{x_1, x_1})} \right $
6	Coef. da Corre. Cruzada	CRC	$1 - \rho_{x_1, x_2}$
7	Ampli. em $f_0$ da Trans. Fourier	FFT	$\frac{\text{FFT}\{x_1 - x_2\}(f_0)}{\text{FFT}\{x_1 + x_2\}(f_0)}$
8	Maximum Amplitude	MA	$\max( x_1 - x_2 )$
9	Maximum Amplitude Ratio	MAR	$\frac{\max( x_1 - x_2 )}{\max( x_1 )}$
10	Signal Ampli. Hilbert trans. Max	SAHM	$\left[ \frac{\max(\text{env}(x_2)) - \max(\text{env}(x_1))}{\max(\text{env}(x_1))} \right]^2$
11	Signal Ampli. Peak Ratio	SAPR	$\left  1 - \frac{\max( x_2 )}{\max( x_1 )} \right $
12	Signal Ampli. Peak Squared perce. diff.	SAPS	$\left[ \frac{\max( x_2 ) - \max( x_1 )}{\max( x_1 )} \right]^2$
13	Envelop Difference Energy	ENV	$\frac{\sqrt{E_s(\text{env}(x_2 - x_1))}}{E_s(\text{env}(x_1))}$
14	Normalized Residual Energy	NRE	$\frac{E_s(x_1 - x_2)}{2(E_s(x_1) + E_s(x_2))}$
15	Relative Energy Difference	RED	$\frac{E_s(x_1) - E_s(x_2)}{\max(E_s(x_1), E_s(x_2))}$

Fonte: Adaptadas de Lizé (2018).

## 2.9 Vida útil remanescente - RUL

A Vida Útil Remanescente, em inglês, *Remaining Useful Life* - RUL, é um conceito utilizado em diversas áreas para avaliar a expectativa de vida ou o tempo restante de operação de um determinado componente, equipamento ou sistema. Sua aplicação está na chamada manutenção baseada na condição, em inglês *Condition Based Maintenance* - CBM, e da Gestão de prognóstico de Saúde, *Prognostic Health Management* - PHM (Prajapati et al., 2012).

Em muitos casos, RUL é aplicado a equipamentos industriais, máquinas ou estruturas, onde é essencial prever a probabilidade de falha ou a degradação ao longo do tempo. A ideia é estimar quanto tempo um ativo pode continuar operando de maneira eficiente antes de requerer manutenção,

Tabela 7: Funções para gerar os DIs. Parte 2.

Nº	Função	Acrônimo	Expressão	
16	Energy Ratio	ER	$1 - \frac{\min(E_s(x_1), E_s(x_2))}{\max(E_s(x_1), E_s(x_2))}$	
17	Shared Energy	SE	$\sqrt{\frac{E_s(x_1 \times x_2)}{E_s(x_1) \times E_s(x_2)}}$	
18	Normalized Shared Energy Difference	NSED	$\frac{E_s(x_1 - \max(x_1)) - E_s(x_2 - \max(x_2))}{2 \times (E_s(x_1 - \max(x_1)) + E_s(x_2 - \max(x_2)))}$	
19	Normalized Shared Energy	NSE	$(1 - \text{NSED}) \times \frac{\min(E_s(x_1), E_s(x_2))}{\max(E_s(x_1), E_s(x_2))}$	
20	Energia da diff. de fase	PHI	$\sqrt{E_s(\phi(x_2 - x_1)) / E_s(\phi(x_1))}$	
21	Signal Sum of Squared difference	SSSD	$E_s(x_1 - x_2) / E_s(x_1)$	
22	Time Delay	TD1	$ \text{argmax}_1[\text{env}(x_2)] - \text{argmax}_1[\text{env}(x_1)]  / \text{argmax}_1(x_1)$	—
23	Time Delay Max	TDM	$ \text{argmax}[\text{env}(x_2)] - \text{argmax}[\text{env}(x_1)]  / \text{argmax}(x_1)$	—
24	Welch-based Power Spectral Density	WPSD	$1 - \frac{\int \text{PSD}(x_2) d\omega}{2\omega_0} / \frac{\int \text{PSD}(x_1) d\omega}{2\omega_0} / \int \text{PSD}(x_1) d\omega / 2\omega_0$	—
25	Welch-based Transfer Function	WTF	$1 - \frac{\int \text{FFT}(x_2) d\omega}{2\omega_0} / \frac{\int \text{FFT}(x_1) d\omega}{2\omega_0} / \int \text{FFT}(x_1) d\omega / 2\omega_0$	—
26	Discrete Wavelet Transf. approx. Coefficients	DWTC	$1 - \frac{E_s(\text{DWT}(x_1) - \text{DWT}(x_2))}{E_s(\text{DWT}(x_1))}$	

Fonte: Adaptadas de Lizé (2018).

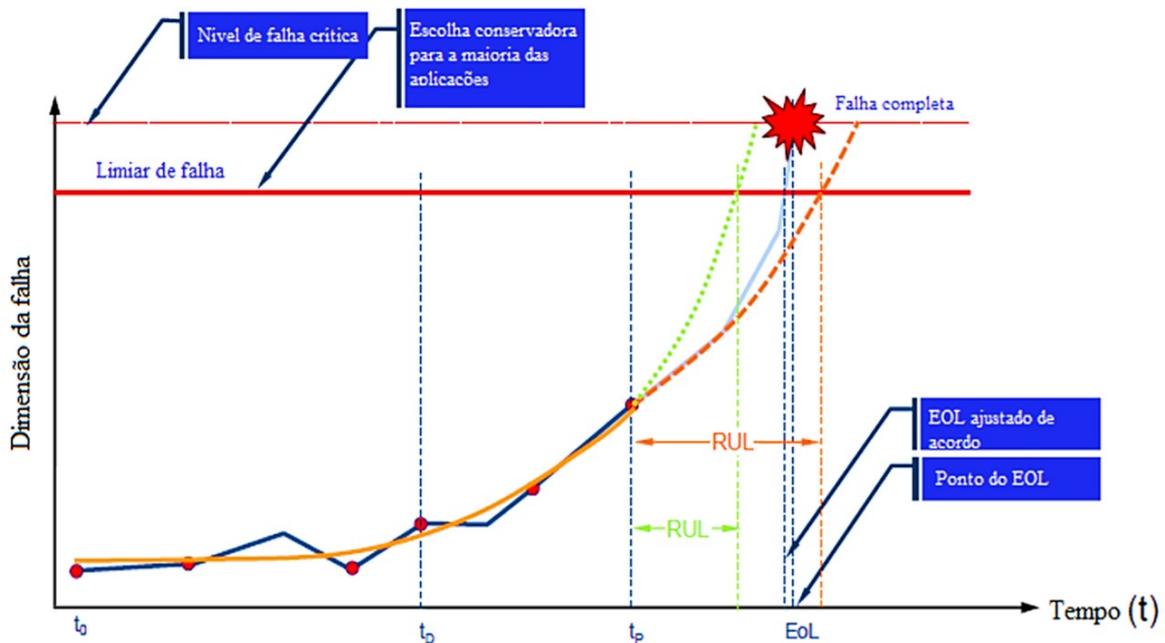
substituição, ou apresentar um risco significativo (Cai et al., 2021).

A análise da RUL envolve geralmente o uso de dados históricos, técnicas estatísticas, modelos de séries temporais e algoritmos de aprendizado de máquina. Esses métodos ajudam a identificar padrões, tendências e comportamentos que podem indicar o estado atual e futuro de um ativo. Para ilustrar o conceito de RUL, a Fig. 39 exibe o RUL em função do tempo “t”. Conforme o tempo se passa, existe um aumento no nível da dimensão da falha, diminuindo assim, a vida útil do ativo. O limiar de falha, indicado pela linha em vermelho, mostra o momento que a curva intercepta este limiar e ocorre a falha completa (Mesquita, 2021; Si et al., 2011).

Um dos pontos cruciais para o correto desenvolvimento da previsão do RUL, é definir um vetor de comportamento, baseada nos dados, que resuma o estado do equipamento e tenha o poder de capturar sua degradação. Em equipamentos complexos, como o caso das ESDVs, compostos de vários sub-sistemas, obter estes vetores é uma tarefa complexa, onde o pós-processamento dos dados deve ser realizado com extrema atenção. Pois pequenas flutuações podem mascarar uma tendência de degradação e isto, passar despercebido ao operador.

Portanto, o estudo de métricas para definir o estado da ESDV se torna essencial. Na Sec. 2.8, o conceito de *Damage Index* - DIs será introduzido e aprofundado dando uma noção mais clara de como estes indexes podem ser utilizados em ESDVs. Além disto, tais indexes, por vezes são chamados de *Health Index* - HIs, por ter esta capacidade de capturar a tendência de degradação do sistema e

Figura 39: Conceito do *RUL* juntamente com os limites máximos de operação e o momento da falha.



Fonte: Mesquita (2021).

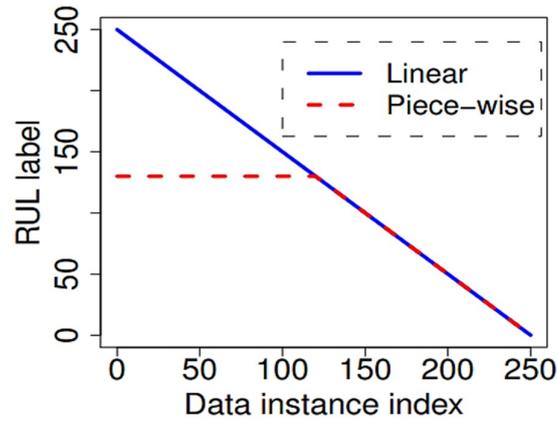
correlacionar com a saúde da estrutura (Mihai et al., 2022; Lee and Dong, 2019).

De modo a simplificar a representação do RUL, seja por métricas de *Damage Index* ou *Health Index*, também se utiliza uma curva com tendência negativa exibindo uma degradação linear do equipamento. Em muitos casos iniciando em um e indo até o valor de zero, onde o valor um representa o equipamento totalmente íntegro e o valor de zero quando a falha se apresenta 100%. Para a aplicação de tal curva, é aplicado o método de "Curva *Piece-Wise*", onde para valores determinados de intervalos em X, os valores de Y assumem comportamentos lineares. A Fig. 40 mostra a função onde no eixo X, *Data Index*, no momento de 130, o RUL mudou de comportamento e começou a apresentar uma degradação linear negativa, terminando em zero.

Para a determinação da RUL, existem diferentes abordagens que podem ser aplicadas, indo deste uma simples análise dos dados disponíveis, uma análise probabilística ou até mesmo, a implementação de redes neurais, da área de *Machine Learning*.

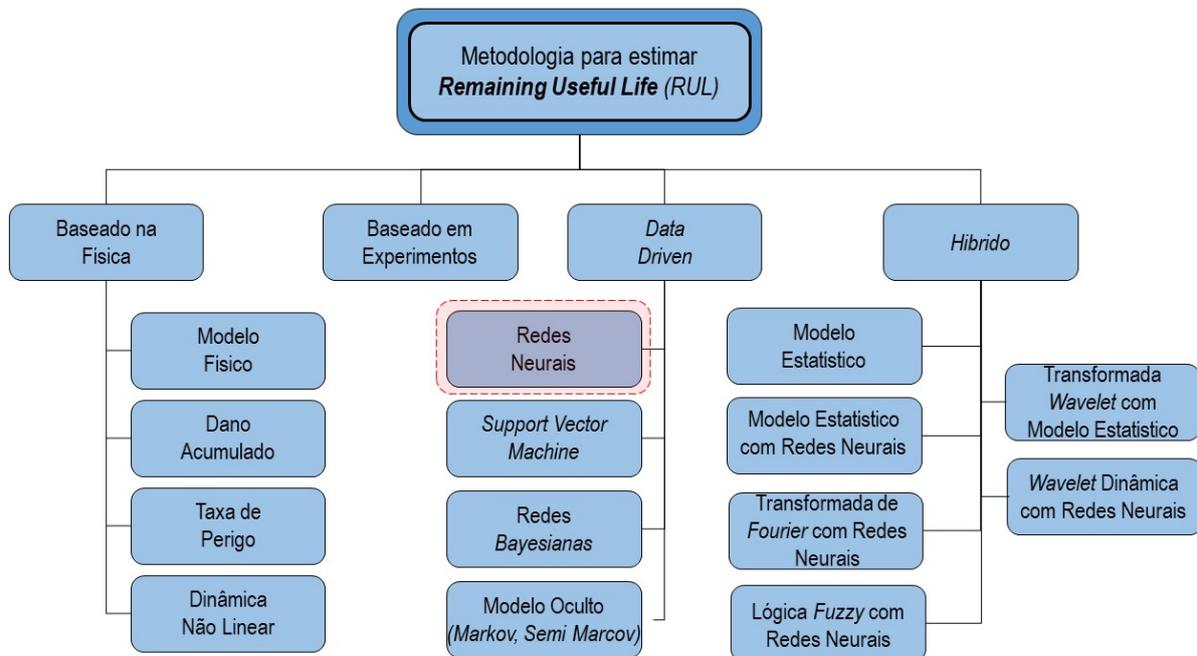
A Fig. 41 exhibe os possíveis aplicações para se estimar e calcular a RUL de um ativo, sendo que nesta tese, será utilizado a abordagem *Data Driven* caracterizado pela implementação de uma *Neural Networks*, mais precisamente as *Long Short Term Memory* e a abordagem *Hybrid*, com foco nos modelos estatísticos estocásticos utilizando os movimentos Brownianos, também chamados de modelos de difusão (Ahmadzadeh and Lundberg, 2014).

Figura 40: *RUL* representado pela função *Piece-Wise*.



Fonte: Wang et al. (2019).

Figura 41: Metodologias para os cálculos de RUL. Em vermelho, a metodologia aplicada nesta tese, sendo Redes Neurais, pertencentes ao grupo abordado por *Data Driven*.



Fonte: Adaptado de Ahmadzadeh and Lundberg (2014).

### 3 MATERIAIS E MÉTODOS

Neste capítulo são apresentados detalhes sobre o ensaio conduzido para gerar os dados de teste, além dos equipamentos utilizados e sensores instalados para garantirem a operabilidade do ensaio e coleta dos dados. Além disto, será apresentado a metodologia usada para extrair os sinais e o processamento utilizado associado com as técnicas de monitoramento para detectar possíveis danos ocorridos na ESDV.

De maneira geral, foi utilizado a pressão de trabalho máximo da classe de pressão para esta válvula, ou seja, 102.1 bar, equivalente a aproximadamente 10MPa. Após o ensaio, a válvula é desmontada e avaliada visualmente. Os ensaios foram conduzidos nas dependências da empresa Micromazza, fabricantes de válvulas, no Laboratório Técnico Micromazza (LTM). Os detalhes da válvula e do sistema de atuação estão dispostos na Tab. 8.

#### 3.1 Testes vedações da válvula - estática

Antes de avançar para os testes, é de suma importância que, após a montagem minuciosa da válvula, das sedes e do atuador, a válvula esteja alinhada de forma precisa com a passagem do fluido, garantindo, assim, uma vedação eficaz. Nesse contexto, foram realizados testes de vedação antes de dar início à operação do equipamento em um contexto cíclico seguindo a norma API 598, os chamados *Factory Acceptance Test*.

Para realizar esses testes, adotou-se água como fluido de trabalho na válvula, pressurizando tanto a montante quanto a jusante. No que diz respeito à operação da válvula, foi utilizado óleo para gerar as pressões necessárias que possibilitam a abertura e o fechamento da válvula através da pressurização da câmara do atuador. Todo o processo foi monitorado por meio de sensores de pressão e manômetros, além da contagem por bolhas relacionados aos vazamentos. Esses sensores foram integrados ao sistema de aquisição Eclipse, e as leituras foram acompanhadas por meio de uma interface gráfica, exibidas em gráficos detalhados. A Figura 42 fornece uma representação visual desses testes preliminares.

#### 3.2 Testes cíclicos

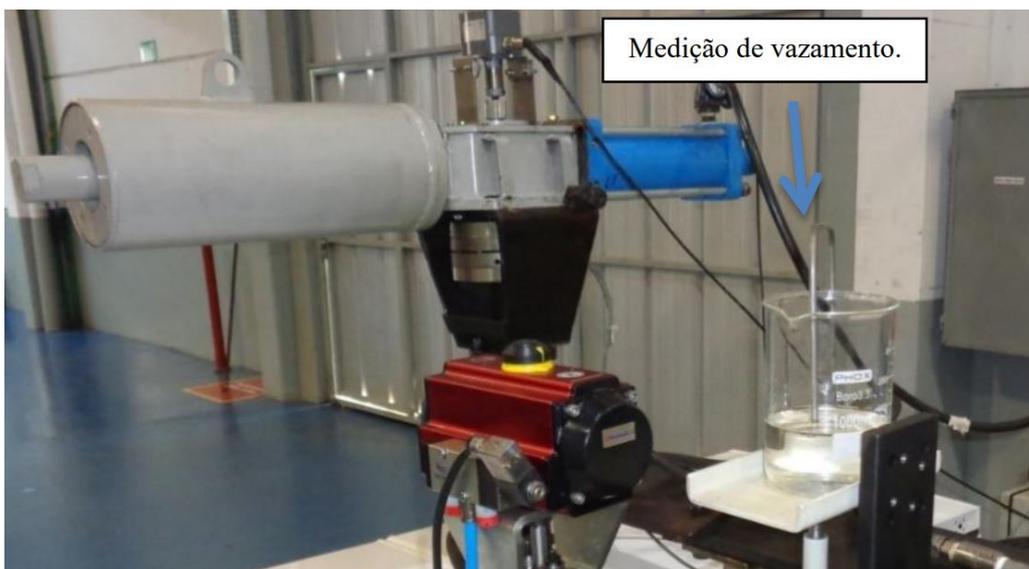
Os testes cíclicos foram conduzidos após os ensaios de vedação com o intuito de simular as condições de campo, realizando aberturas e fechamentos com máximo diferencial de pressão entre a montante e jusante a fim de impor ao equipamento degradações aceleradas que simulassem as condições extremas do campo. Essas degradações foram projetadas para replicar fielmente as condições encontradas no ambiente de operação real, pois o objetivo deste estudo é simular precisamente as condições de campo, bem como as metodologias de monitoramento dos sinais

Tabela 8: Dados da válvula e do atuador hidráulico.

Componente	Norma / Material	Detalhes
<b>Válvula</b>	API 6D (2014), ASME 16.34 (2017) API 6DX (2012)	Esfera — Trunnion
<b>Diâmetro</b>	-	3"
<b>Classe Pressão</b>	-	CL 600
<b>Avanço</b>	-	Atuação Hidráulica
<b>Retorno</b>	-	Retorno por mola
<b>Em caso de falha</b>	-	Posição Fail Safe
<b>Transmissão</b>	API 6DX (2012)	Scotch-Yoke assimétrico
<b>Corpo Válvula</b>	ASTM A 216 GR WCB (2018)	-
<b>Componentes Internos</b>	ASTM A 2017 GR CA15 (2020)	-
<b>Sedes</b>	PTFE 2891 (23% Carbono + 2% Grafite)	SPE montante — SPE jusante

Fonte: Adaptado de Teles (2020)

Figura 42: Testes de vedação realizados antes e após os testes cíclicos.



Fonte: Adaptado de Teles (2020).

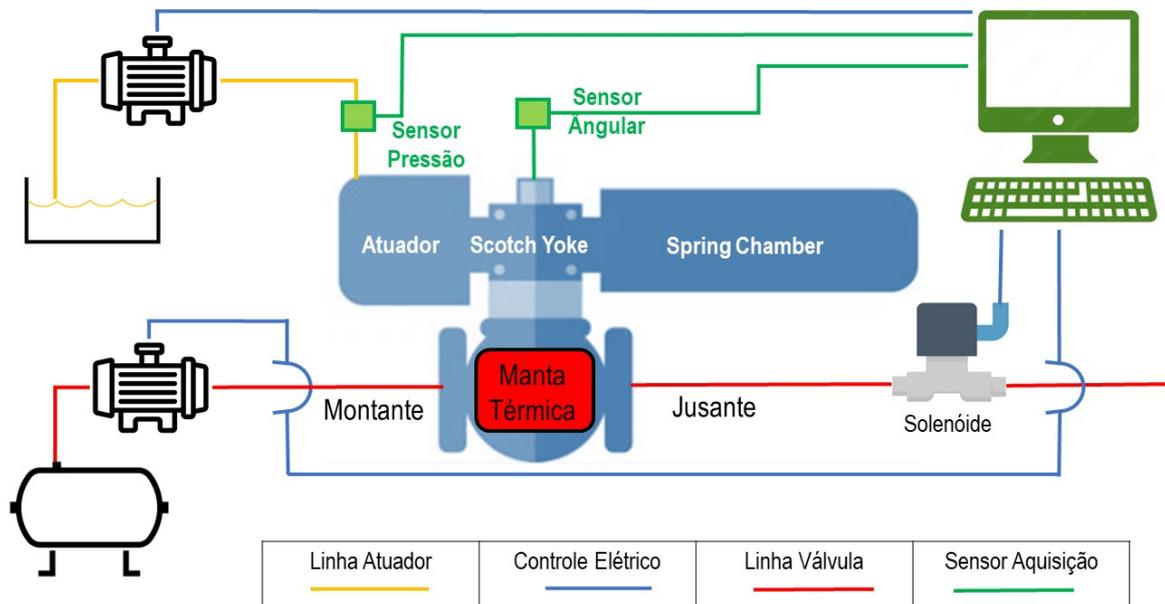
gerados pela ESDV ao longo dos ciclos.

Os testes consistiram em ciclos repetitivos de abertura e fechamento, realizados na faixa de pressão de trabalho máxima da válvula esférica em análise. Além disso, foi considerada a temperatura máxima de trabalho desta família de válvula ESDV, estabelecida em 120 °C. Estes ensaios seguiram o esquema hidráulico conforme apresentado na Figura 43.

Os testes contaram com a válvula, alvo dos teste e aparatos que controlaram as pressões de atuação no pistão do atuador hidráulico e no corpo da válvula. Além disto, foram instrumentados sensores de pressão e ângulo em locais específicos da válvula para posterior construção das assinaturas de pressão.

A fim de explicar a metodologia utilizada para descrever as etapas que resultaram nos testes de

Figura 43: Esquemático do teste executado nos testes cíclicos.



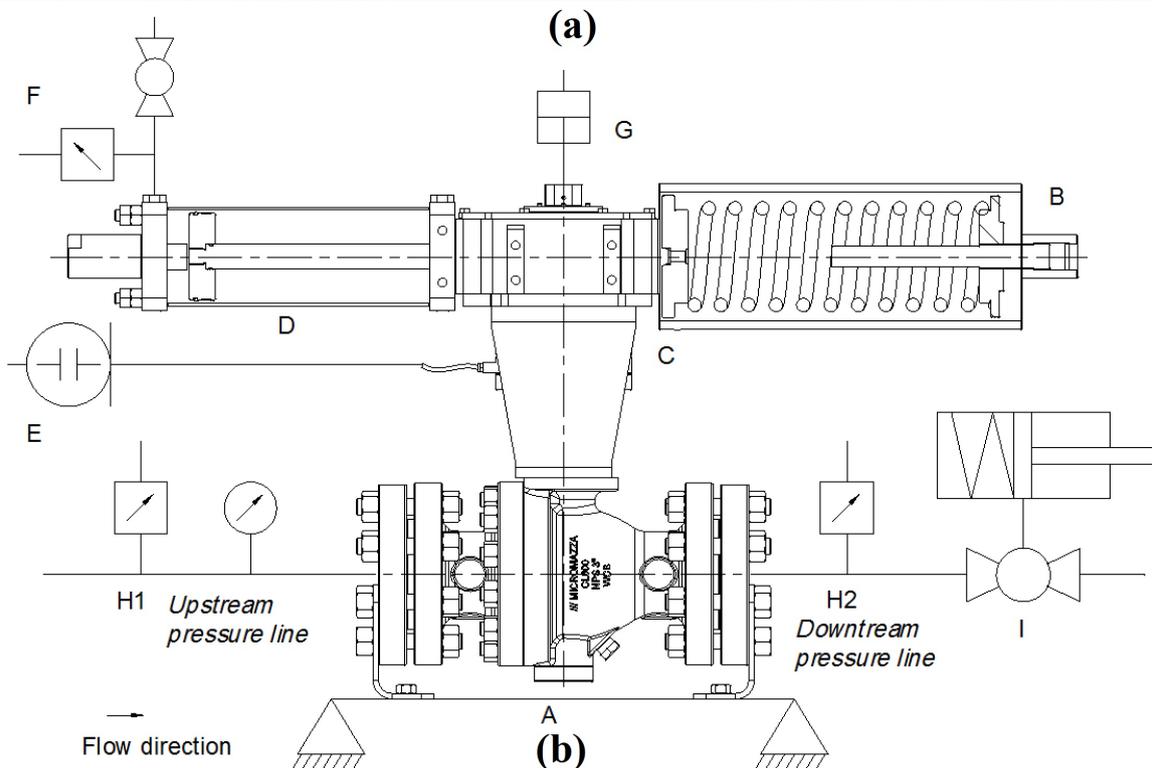
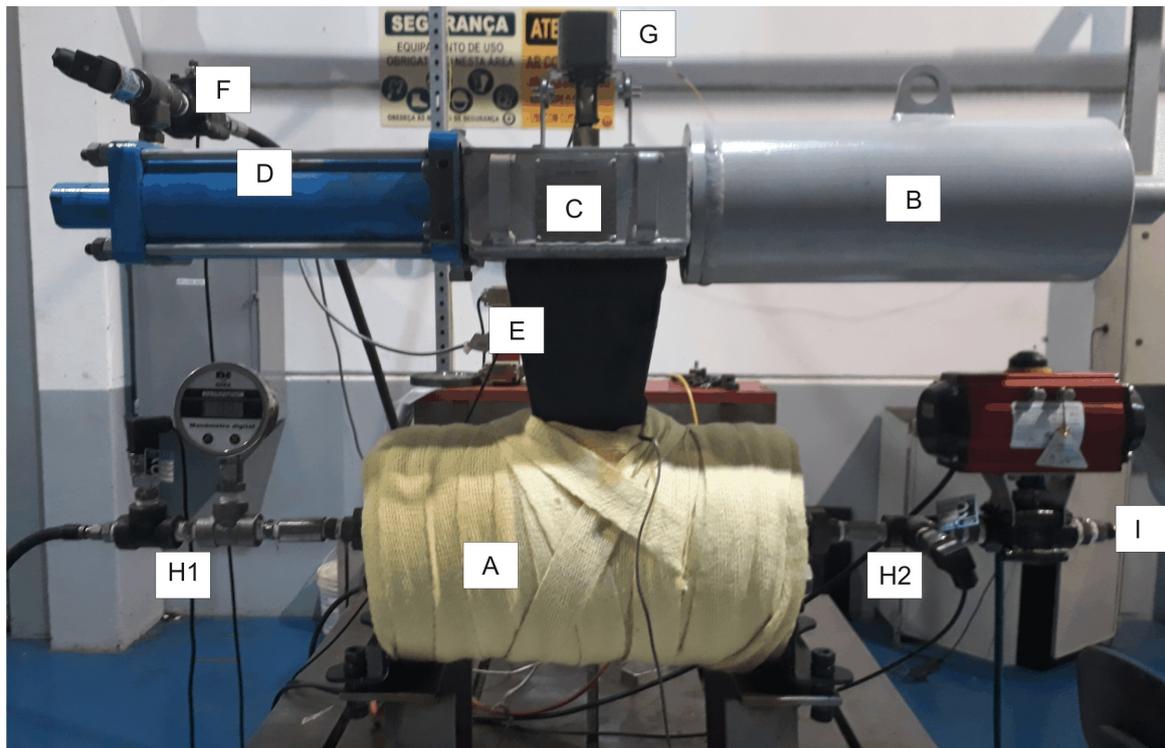
Fonte: Adaptado de Teles (2020).

ciclagem, os seguintes passos são ilustrados abaixo, para mais detalhes, consultar o Apêndice B juntamente com o trabalho de Teles (2020).

- A - Manter a válvula na posição fechada;
- B - Pressurizar o lado da montante até a pressão máxima de trabalho;
- C - Iniciar a pressurização do atuador para movimentação do pistão/ giro do obturador;
- D - Gerar o diferencial de pressão na abertura entre montante e jusante;
- E - Manter a pressurização do atuador até a abertura completa da válvula;
- F - Aguardar a equalização das pressões entre montante e jusante;
- G - Aliviar a pressão do atuador para fechamento da válvula;
- H - Aguardar até o momento de *crack-open*;
- I - Abrir a válvula solenoide na jusante para alívio de pressão;
- J - Gerar o diferencial de pressão no fechamento;
- K - Manter o alívio do atuador até o completo fechamento da válvula.
- L - Voltar ao passo A e iniciar o próximo ciclo.

Durante todos os passos descritos para realizar o ensaio, os dados de pressão e posição angular da esfera, foram adquiridos e armazenados.

Figura 44: Detalhes da ESDV e da Manta Térmica utilizada.



Fonte: Adaptado de Teles (2020). Onde as letras alfabéticas, correspondem a: A) Manta Térmica, B) Câmara da Mola, C) Scotch-Yoke, D) Câmara do Atuador, E) Haste Torque, F) Sensor Pressão Atuador, G) Sensor de Ângulo, H1) Sensor Pressão Montante, H2) Sensor Pressão Jusante e I) Solenoide da Jusante.

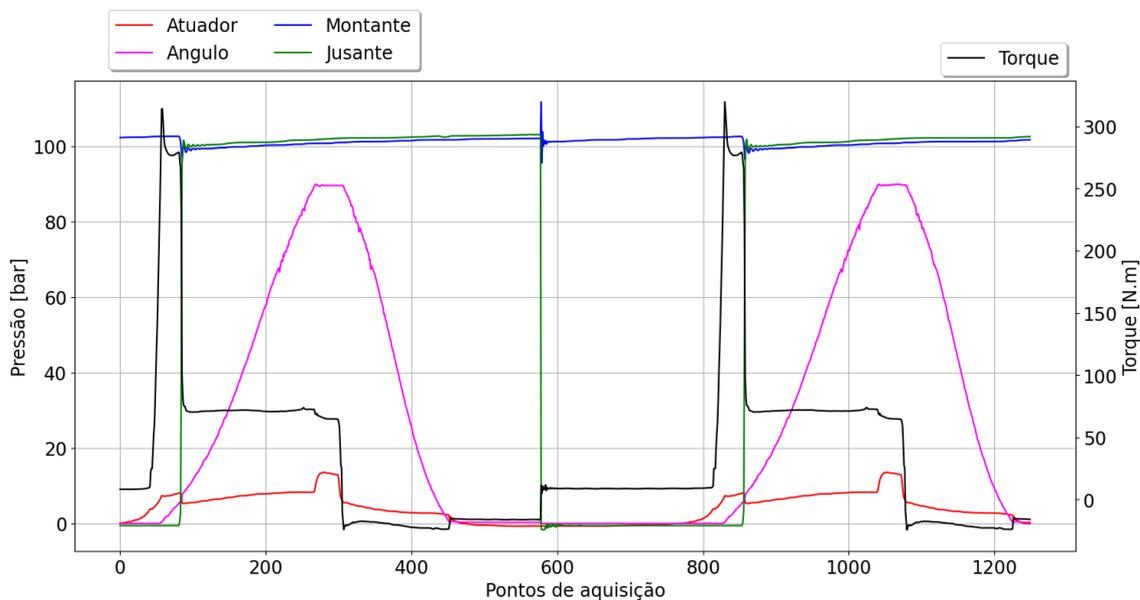
### 3.3 Sinais gerados

Os dados foram coletados e armazenados no computador responsável pelo controle e aquisição dos dados de testes. Os sensores de ângulo, pressão no atuador, montante e jusante, formaram uma série temporal. A coleta dos sinais, foi realizada com uma taxa constante de 10Hz. Os sinais foram salvos em planilha eletrônica, Excel.

Após o fim dos ciclos, estes dados em \*.xlsx foram tratados utilizando a linguagem de programação em código aberto Python. A Fig. 46 mostra uma porção destes valores medidos sobrepostos sem nenhum pós-processamento. Os sinais do atuador foram utilizados para gerar a assinatura de pressão e estão representados pela linha em vermelho. Entre uma abertura e a próxima, existe um delta de tempo para o sistema de bombeamento atingir a pressão de trabalho, de 102.1 bar nesta tese, este delta de tempo deve ser descartado da análise, uma vez que a válvula ESDV se encontra em repouso, sem movimentação do obturador.

Portanto, para gerar o *dataset* que será usado para alimentar os algoritmos que irão monitorar a válvula de bloqueio, é necessário o pós-processamento para localizar o movimento do obturador, ou esfera, para analisar somente este intervalo. Este procedimento foi realizado, totalizando 323 ciclos durante o teste.

Figura 45: Sinais gerados durante os testes e sem o processamento. O eixo y no lado da esquerda, representa a pressão no atuador, medidos em Bar. Já o eixo t da direita, representa os valores de Torque, medidos em N.m.

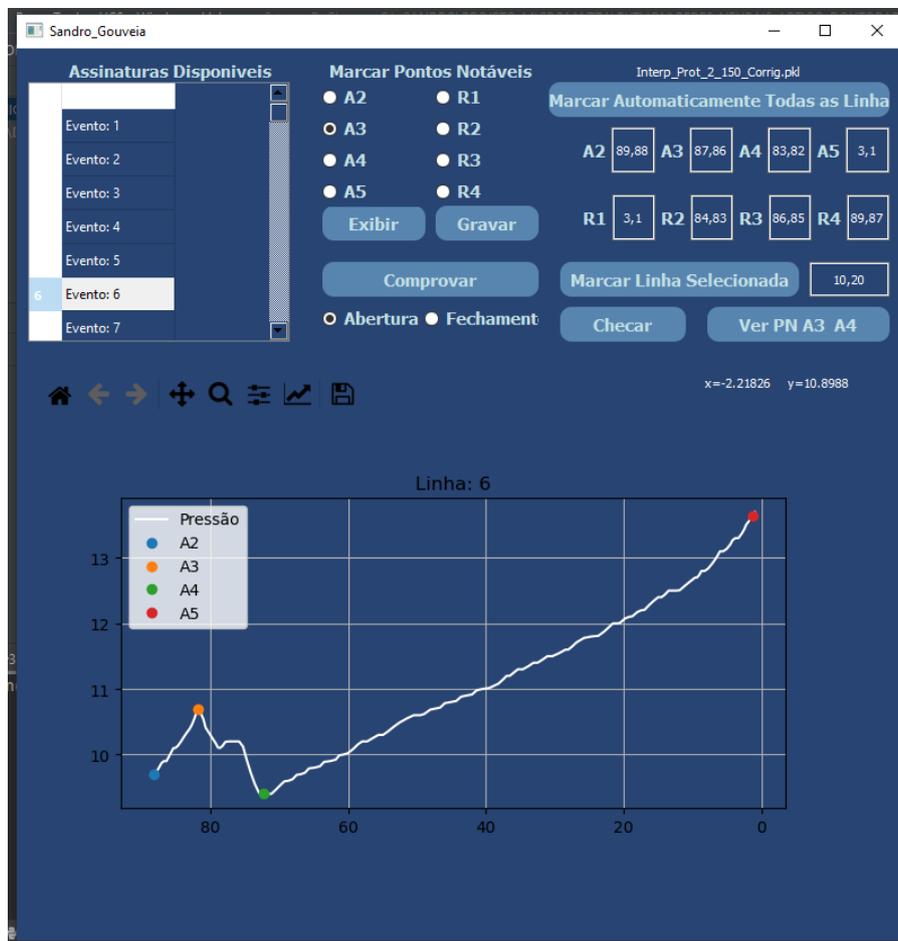


Fonte: Próprio Autor.

Para definir os KPs, presentes em cada assinatura, foi necessário analisar cada assinatura individualmente com o intuito de reconhecer os pontos determinados para cada um dos 4 KPs deste trabalho. Para isto, foi construído uma interface gráfica, na linguagem Python, utilizando o pacote PyQt5. Esta interface, permitiu visualizar as assinaturas e marcar, manualmente, os KPs.

A marcação dos KPs foi realizado pelo autor desta tese, mediante cliques na janela da interface gráfica. O processo todo levou, ao todo, 3 horas. Aqui não foi contabilizado o tempo necessário para escrever, corrigir e implementar o código em Python que gera a interface gráfica. Vale mencionar, que este processo, não possui flexibilidade alguma, na identificação dos KPs, visto que, é preciso fornecer ao operador especializado, a representação gráfica da assinatura, ou seja, a própria interface, para que este operador, indique e marque cada KP.

Figura 46: Demonstração da interface gráfica desenvolvida pelo autor para realizar a identificação, marcação manual e armazenamento dos KPs (A2, A3, A4 e A5) presente em cada um dos 323 ciclos, ou eventos, nas assinaturas pressões abordadas neste trabalho. Pacote PyQt5, linguagem Python



Fonte: Próprio Autor.

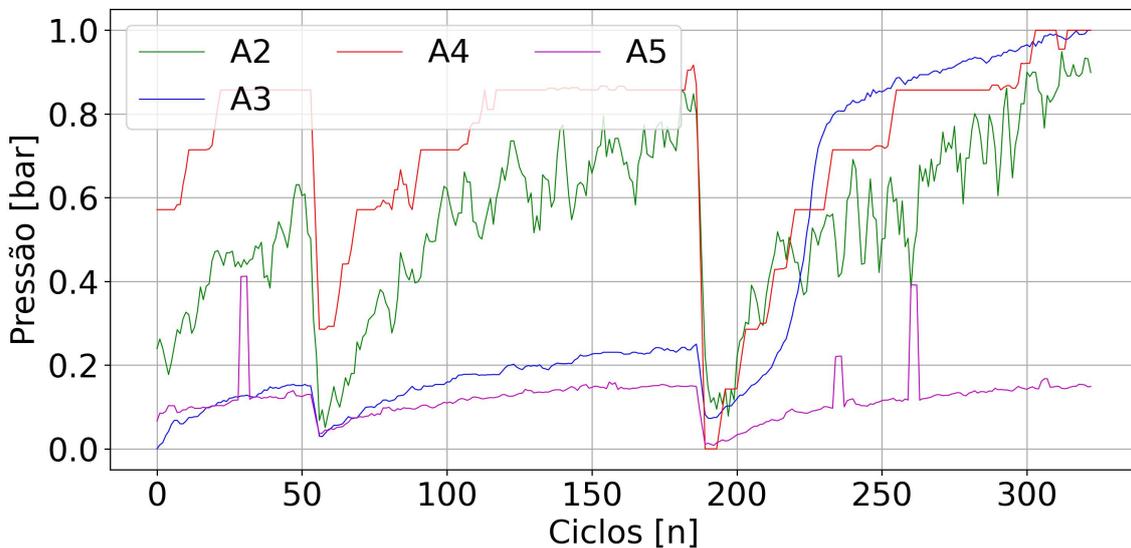
Após o processamento que gerou o banco de dados, vale destacar a limitação imposta pela ausência de outras válvulas (fabricantes, tamanhos, aplicações), outros modos de falha e, por fim, a falta de adequação ao termo *Independent and Identically Distributed*, necessárias para entregar as soluções puramente no campo de *Machine Learning* (ver Sec. 2.7.1).

### 3.4 Labels

Para determinar se uma ESDV possui ou não algum tipo de dano, uma análise dos KPs é a metodologia mais usada. Conseqüentemente, nesta tese, será usada suas tendências e características para gerarem os respectivos estados de degradação e dano da ESDV submetida aos ensaios neste trabalho.

Serão usados os KPs de Pressão, adquiridos e pós-processados, conforme explicado na Sec. 3.3. Sua tendência pode ser visualizada na Fig. 47 para os *Key Points* relacionados ao avanço do atuador, A2, A3, A4 e A5.

Figura 47: Tendência temporal, medidos em ciclos, de cada *Key Point* extraído das assinaturas de pressão da válvula ESDV durante os ensaios cíclicos.



Fonte: Próprio Autor.

### 3.5 Curva piecewise

A curva *Piecewise* que modela o comportamento de degradação de um equipamento pode ser descrita por uma função  $f(x)$  composta por duas partes distintas. Esta função descreve inicialmente um comportamento constante, seguido por uma degradação linear negativa. O instante onde a degradação começa é representado pela letra  $d$ .

A função  $f(x)$  é definida da seguinte forma:

$$f(x) = \begin{cases} 1 & \text{se } 0 \leq x < d \\ 1 - \frac{x-d}{L-d} & \text{se } d \leq x \leq L \end{cases} \quad (9)$$

onde:

- $x$  é a variável independente, que geralmente representa o tempo.

- $d$  é o instante específico no eixo  $x$  onde a degradação do equipamento começa.
- $L$  é o ponto no eixo  $x$  onde a função atinge zero, indicando a falha completa do equipamento.
- $f(x)$  é a função que descreve o estado do equipamento, variando entre 1 (totalmente funcional) e 0 (totalmente falho).

Para o comportamento constante (sem degradação):

$$f(x) = 1 \quad \text{para } 0 \leq x < d \quad (10)$$

Nesta região, de  $x = 0$  até  $x = d$ , a válvula de bloqueio está em perfeito estado, sem sinais de degradação. A função  $f(x)$  é constante e igual a 1, representando que o equipamento está totalmente funcional.

Para o comportamento linear decrescente (com degradação):

$$f(x) = 1 - \frac{x - d}{L - d} \quad \text{para } d \leq x \leq L \quad (11)$$

Nesta região, de  $x = d$  até  $x = L$ , a válvula começa a se degradar. A degradação é modelada por uma função linear decrescente. No instante  $x = d$ , a função  $f(x)$  começa a decrescer a partir de 1. A inclinação negativa da função é dada por  $-\frac{1}{L-d}$ , garantindo que a função atinja 0 em  $x = L$ , onde o equipamento é considerado totalmente falho.

### 3.6 DIs - *Damage Index*

Para aplicar os DIs aos dados, foram utilizados os cálculos descritos nas Tab. 6 e 7. Porém, para se calcular os DIs, é necessário definir um sinal de referência, ou um sinal base que será comparado com os sinais restantes. Para se obter um sinal que represente o comportamento sem degradação ou defeitos da válvula, foram definidos  $N$  ciclos para se extrair a média ponto-a-ponto.

Com isto, será descartada qualquer variação mais acentuada que um único sinal poderia causar, sendo a média dos  $N$  primeiros ciclos, irá representar uma população mais homogênea dos eventos iniciais do equipamento. Neste trabalho, ficou estabelecido que o sinal padrão, será obtido fazendo-se uma média dos 20 primeiros ciclos ( $N$ ). A aplicação do cálculo dos DIs segue conforme abaixo:

Seja o número de matrizes neste trabalho igual ao número de DIs, sendo 28  $\mathbf{A}_1, \mathbf{A}_2, \dots, \mathbf{A}_{28}$ , cada matriz  $\mathbf{A}_i$  tem dimensão  $N \times M$ , onde  $N$  representa o número de ciclos ou eventos que o equipamento executou durante os testes e  $M$  o tamanho do vetor que representa cada ciclo.

Para cada matriz  $\mathbf{A}_i$ , considere a submatriz  $\mathbf{A}_i^{(20)}$  que contém as 20 primeiras linhas, ou ciclos, de  $\mathbf{A}_i$ . Assim,  $\mathbf{A}_i^{(20)}$  é uma submatriz de dimensão  $20 \times M$ .

A média dos 20 primeiros eventos, ou ciclos, de  $\mathbf{A}_i$  é um vetor  $\bar{\mathbf{A}}_i$  de dimensão  $1 \times M$ , onde cada elemento  $\bar{A}_i^{(j)}$  é a média da  $j$ -ésima coluna das 20 primeiras linhas de  $\mathbf{A}_i$ .

$$\bar{A}_i^{(j)} = \frac{1}{20} \sum_{k=1}^{20} A_i^{(k,j)} \quad \text{para } j \in \{1, 2, \dots, M\} \quad (12)$$

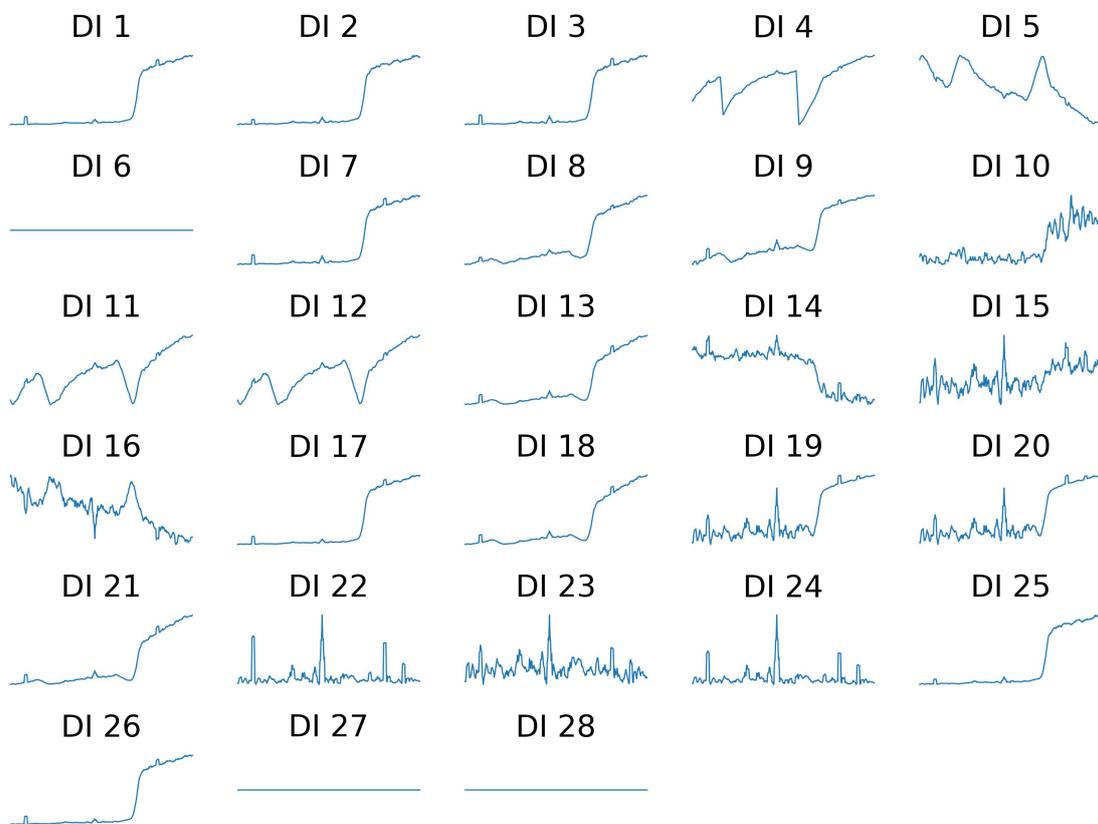
Aqui,  $A_i^{(k,j)}$  representa o elemento na  $k$ -ésima linha e  $j$ -ésima coluna da matriz  $\mathbf{A}_i$ .

As médias das 20 primeiras linhas de todas as 28 matrizes podem ser representadas como uma matriz  $\bar{\mathbf{A}}$  de dimensão  $28 \times 100$ , onde a  $i$ -ésima linha de  $\bar{\mathbf{A}}$  é o vetor  $\bar{\mathbf{A}}_i$ . Esta matriz é a referência que será aplicada a cada sinal.

$$\bar{\mathbf{A}} = \begin{bmatrix} \bar{\mathbf{A}}_1 \\ \bar{\mathbf{A}}_2 \\ \vdots \\ \bar{\mathbf{A}}_{28} \end{bmatrix} \quad (13)$$

Após obter o sinal referencia, sendo a média dos 20 primeiros eventos, se aplica algumas das equações resultantes da (Tab. 6 e 7) para cada sinal. Com isto, são gerados vetores de tamanho  $1 \times M$  para cada DI conforme mostrado na Fíg. 48.

Figura 48: Tendência de cada DI de pressão da ESDV.



Fonte: Próprio Autor.

Ao fim, se obtêm os DIs que serão utilizados nesta tese, os quais serão

as seguintes: CrossCorrelation, CrossCorrelationCoef, CrossCorrelationFFT, CrossCorrelationMax, CrossCorrelationMaxPercentDiff, CrossCorrelationTimeOfFlight, CrossCorrelationZerolag, DTW, EnergyEnvRatio, EnergyPhase, EnergyRatio, EnergyRelativeDiff, EnergyResidualNorm, EnergyShared, EnergySharedDiffNorm, EnergySharedNorm, EnergySignal, EnergySignalSumSquareDiff, L1Max, L1MaxNomr, L2, SignalAmpHilbertMax, SignalAmpPeakRatio, SignalAmpPeakSquaredPercentDiff, SignalDiffCoef, SpatialPhase, SpectrumLoss, SpectrumLossCentral.

### 3.7 Monte Carlo para gerar os dados sintéticos

A fim de expandir a base de dados e verificar se é possível treinar os algoritmos com estes dados expandidos, aqui chamados de Sintéticos, esta seção irá expor a metodologia usada para gerar os sinais e posterior extração das características que alimentarão os modelos de ML.

#### 3.7.1 Primeiro e segundo momento estatístico.

Os momentos estatísticos são descritores quantitativos de uma distribuição de probabilidade, que capturam várias características importantes do comportamento de uma variável aleatória. Os dois primeiros momentos estatísticos, a média e a variância, são amplamente utilizados para resumir e caracterizar distribuições de dados em estatística descritiva e inferencial.

O primeiro momento estatístico, comumente conhecido como média, é uma medida de tendência central que representa o valor médio de uma distribuição de dados. Matematicamente, a média de uma variável aleatória  $X$  é definida como a soma de todos os valores observados dividida pelo número total de observações. A média fornece uma estimativa do centro da distribuição e é frequentemente utilizada como um indicador de localização em análises estatísticas. Em muitos casos, a média é calculada como uma média aritmética simples, mas em distribuições assimétricas ou com *outliers*, outras medidas de tendência central, como a mediana, podem ser mais apropriadas.

O segundo momento estatístico, conhecido como variância, é uma medida de dispersão que quantifica a extensão onde os valores de uma variável aleatória se desviam da média. A variância é calculada como a média dos quadrados das diferenças entre cada valor observado e a média da distribuição. Em outras palavras, a variância representa a média dos desvios ao quadrado em relação à média, fornecendo uma medida da dispersão dos dados em torno do valor médio. Uma característica importante da variância é que ela é sempre não negativa, pois os quadrados dos desvios são sempre não negativos.

#### 3.7.2 Médias móveis e diferenciação de ordem 1 (Lag 1)

As médias móveis são uma técnica estatística utilizada para suavizar séries temporais, calculando a média de um número fixo de pontos de dados consecutivos. Essa média é então atribuída ao ponto central do intervalo de dados. As médias móveis são frequentemente usadas para remover flutuações de curto prazo nos dados e destacar tendências de longo prazo.

Já as diferenças de ordem 1 (lag 1) são uma técnica estatística utilizada para identificar mudanças entre pontos de dados consecutivos em uma série temporal. Matematicamente, a diferença de ordem 1 entre dois pontos de dados consecutivos  $x_t$  e  $x_{t-1}$  é dada por  $x'_t = x_t - x_{t-1}$ . Essa técnica permite destacar variações de curto prazo nos dados e identificar pontos de inflexão na série temporal.

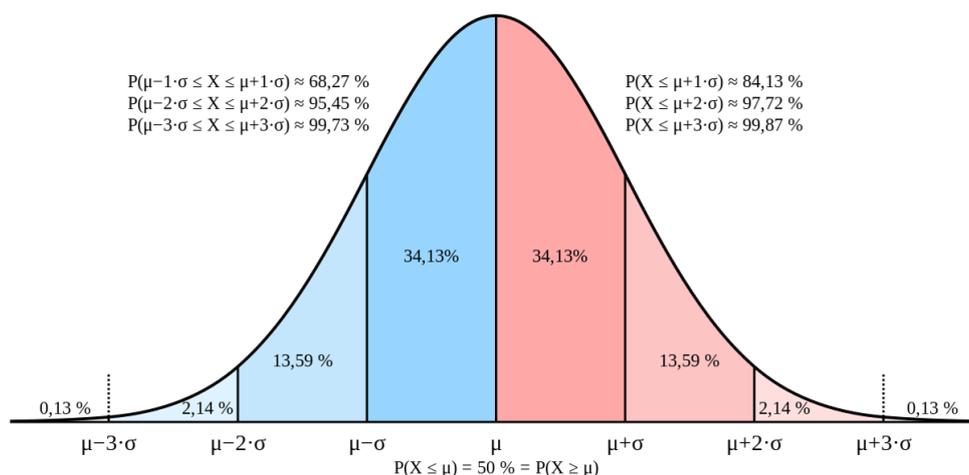
### 3.7.3 Criação dos sinais sintéticos

Com os dados reais, são separadas sessenta assinaturas que serão utilizadas como entrada (*baseline*) para o método de Monte Carlo, estas sessenta assinaturas serão divididas em trinta sem defeito e trinta com defeitos. Estas assinaturas utilizadas no MC, não serão mais usadas, pois como darão origem as sintéticas, serão descartadas das análises futuras. Este processo irá garantir que as assinaturas sintéticas, que serão usadas no treinamento dos algoritmos, nunca tenham sido "enxergadas" pelos modelos antes.

Ao fornecer as assinaturas *baseline*, o primeiro e o segundo momento estatístico de cada ponto das assinaturas, é calculado. Com isto, em um código em Python, as primeiras assinaturas sintéticas são geradas, respeitando as características estatísticas extraídas. Com relação ao segundo momento, para haver uma variabilidade dos dados, foi definido um desvio padrão correspondente a um intervalo de  $3\sigma$ . Desta maneira, garantiremos que nossas assinaturas sintéticas representem 99 % dos dados.

Geradas as assinaturas, é preciso aplicar uma suavização aos sinais recém-criados através da média móvel de valor 1. Isto é necessário, pois, a assinatura sintética não possui um compromisso entre dois pontos sequenciais, visto que no intervalo de  $3\sigma$ , teremos 99,73 % dos dados originais, conforme Fig. 49.

Figura 49: Intervalo percentual dos dados respeitando as distribuições do segundo momento estatístico,  $\sigma$ .



Fonte: (Commons).

Após a aplicação da média, segue-se para a aplicação do cálculo da diferenciação de ordem um, *Lag 1* aqui chamado. Esta etapa visa calcular a diferença entre dos pontos consecutivos após a suavização. Portanto, definido o *Threshold* com base nos valores de *Lag* dos dados reais, é encontrado

Tabela 9: Parâmetros utilizados para construir a *Long Short Term Memory* (LSTM).

Parâmetros				
-	Camada 1	Camada 2	Camada 3	Camada 4
<b>Epoch</b>	100	100	100	100
<b>Neuronios</b>	256	128	64	1
<b>Bacth Size</b>	16	16	16	16
<b>função Ativação</b>	relu	relu	relu	linear
<b>Loss</b>	MSE	MSE	MSE	MSE
<b>Otimizador</b>	Adam	Adam	Adam	Adam
<b>Metrica</b>	MSE	MSE	MSE	MSE

Fonte: Próprio Autor.

os valores limites para os dados com dano, sendo igual a 0.4 e com os dados sem dano sendo igual a 1.0. Aplicando-se estes limiares, as assinaturas que possuem valores de *Lag 1* inferiores aos tais, permanecem sendo agrupadas para fazerem partes do *dataset* sintético.

### 3.8 Algoritmos de monitoramento

Esta seção irá se dedicar em esclarecer como os dados foram manipulados para alimentarem os algoritmos, além de exibir a metodologia de aplicação dos algoritmos aos sinais.

#### 3.8.1 Arquitetura e otimização da LSTM - RUL

A LSTM neste estudo, foi proposta para trabalhar com cinco camadas ocultas e uma de entrada e outra de saída, totalizando assim, cinco níveis. A construção de um LSTM, exige, além de determinar sua arquitetura, quais serão as funções de ativação, número de células, otimizador e bacth size.

O otimizador, a função de custo e métrica, foram definidos de maneira heurística. Sendo que o otimizador usado foi o *adam*, função de custo e a métrica designada foram a *Mean Squared Error* para ambas, ao serem amplamente utilizadas em problemas que envolvem regressão.

Portanto, foram definidos os parâmetros que serão utilizados conforme a Tab. 9.

#### 3.8.2 Arquitetura e otimização do kNN - LR - GB

Como esta tese não possui como foco, o melhor ajuste de cada algoritmo, não realizando um *fine tuning*, os modelos utilizados serão construídos com seus parâmetros padrões (*default*), conforme disponibilizados dentro de cada biblioteca do pacote *scikit-learn* a fim de verificar se tais algoritmos podem ser aplicados aos sinais das válvulas de bloqueio.

Isto também se deu por conta da limitação imposta pelo banco de dados (ver Sec. 2.7.1) ao uso de algoritmos puramente de *Machine Learning*. Portanto, estas análises será uma avaliação inicial do potencial destes algoritmos no monitoramento de válvulas de emergência. Para detalhes dos *hyper-parâmetros*, de cada algoritmo utilizado, consultar diretamente as informações no *scikit-learn* (Hao and Ho, 2019).

### 3.9 Fluxograma proposto — Entrada dos dados até a regressão e previsão do RUL

Com os dados obtidos da válvula, o processamento para gerar os dados que alimentarão os algoritmos assinaturas é aplicado, iniciando com a localização do momento quando a válvula está rotacionando e realizando o armazenamento das pressões do atuador nestes instantes de rotação. Este intervalo, chamado de vetor, é então separado, sendo definido como um ciclo ou evento. Após separar todos os ciclos, uma matriz é criada a partir destes vetores. A matriz armazena todo o funcionamento da válvula com relação a sua parte dinâmica, ou seja, onde houve movimentação do obturador. Esta matriz é chamada de matriz das assinaturas de pressão.

A segunda etapa consiste em gerar os *Key Points* e os *Damage Index*. Para isto, em cada ciclo, onde estão presentes as pressões de acionamento (parte dinâmica), a localização dos KPs é necessária. Ou seja, para cada vetor, exigira a localização de 4 KPs de maneira totalmente manual mediante um operador altamente especializado. Já para o desenvolvimento dos DIs, operações matemáticas são aplicadas aos vetores, para se gerar um único número. Ou seja, entra um vetor, sai um escalar.

A diferença entre os KPs e os DIs se dá da seguinte forma: para os KPs são definidos pontos na própria assinatura, estes pontos, como já explicados na Sec. 2.5.2, estão relacionados com a posição angular da esfera. Logo, para os KPs, não há a "flexibilidade" de selecionar outros pontos. Já para os DIs, o cálculo considera toda a informação do sinal e o representa em um único valor, um escalar.

Ao fim do processo, cada KP (A2, A3, A4, A5) e cada DI (28) terá a dimensão  $z = Nx1$ , sendo N a quantidade de ciclos que a ESDV apresentou. Após a geração dos dados, os KPs são analisados para se determinar o momento dos danos. Com esta informação, a curva RUL é construída usando o método de *Piecewise*.

A primeira análise, conforme Fig. 50 mostra, será feita pelo método de regressão, onde serão analisados quais algoritmos de processamento possuem a melhor capacidade de aprender a localizar e selecionar os KPs em uma assinatura de pressão. Esta etapa será analisada pela métrica *Mean Squared Error* juntamente com o R quadrado ( $R^2$ ).

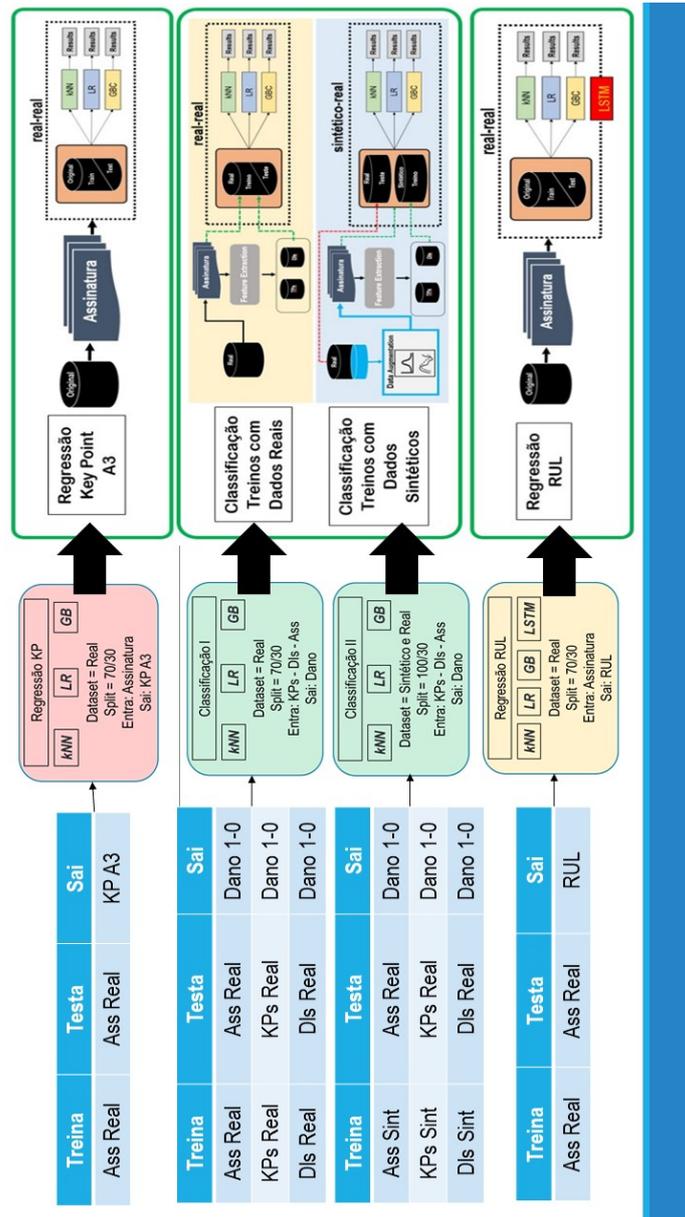
A análise posterior, se concentrará na avaliação dos algoritmos de classificação, onde após definido o momento do dano na válvula de bloqueio, teremos os "rótulos" (*Labels*) que serão usados como saída para cada algoritmo. O estudo sobre a classificação utilizará as 3 técnicas: assinatura completa, KPs e DIs como entrada.

A análise será mensurada utilizando a curva ROC, que contabiliza os erros e acertos de cada modelo. A área sob a curva ROC dá origem a pontuação chamada de *Area Under Curve - AUC Score*, que também será usada para se comparar os algoritmos de monitoramento. Nesta fase, também serão gerados os sinais sintéticos, via Monte Carlo, para que estes dados treinem cada algoritmo. Também serão comparados as pontuações utilizando-se somente dados sintéticos e reais no treinamento e os reais no teste.

Por fim, esta tese irá analisar como cada algoritmo, kNN, LR e GBR irá realizar o cálculo da Vida Útil Remanescente da válvula de bloqueio. A fim de seguir o estado da arte, já discutido e

apresentado na Sec. 2.6, com relação ao uso de uma *Short Long Term Memory*, um modelo de redes neurais, será inserido para comparar a eficácia deste contra os três modelos anteriores no cálculo do RUL. A métrica em uso será MSE.

Figura 50: Fluxograma desta tese aplicado nas abordagens de: regressão dos *Key Points*, classificação de dano usando dados reais e sintéticos e cálculo do *Remaining Useful Life* (RUL). Todos têm em comum o uso dos mesmos algoritmos de processamento de sinais.



Fonte: Próprio Autor.

## 4 RESULTADOS E DISCUSSÕES

Nesta seção serão apresentados os resultados provenientes da aplicação dos testes cíclicos, o que resultou em 323 ciclos de aberturas e fechamentos na válvula. A primeira análise será uma inspeção visual e discussão da falha ocorrida na válvula, focando na sede ao lado montante e sua deformação excessiva. Consequentemente, será analisado qual *Key Point* mais resumiu o comportamento associado ao defeito e juntamente, qual o ciclo onde a falha ocorreu através de uma redução de dimensão utilizando a técnica de *Principal Component Analysis* (PCA). Com a identificação do ciclo da falha, os rótulos para alimentar os algoritmos de classificação são definidos.

Após, será apresentado a aplicação de três algoritmos aos dados reais da ESDV para realizar a tarefa de automatizar a identificação e localização dos *Key Points* no domínio da regressão. A próxima etapa dos resultados será a aplicação dos algoritmos na localização dos ciclos associados ao dano, usando tanto os dados reais como os dados sintético e introduzindo os *Damege Index* como potenciais substitutos aos KPs. Esta etapa está dentro do domínio da classificação.

Por fim, será introduzido o algoritmo de redes neurais, as *Long Short Term Memory* no cálculo de vida útil remanescente.

### 4.1 Análise da falha pela inspeção visual

Ao fim dos ensaios cíclicos, a atuação da ESDV resultou em um aumento substancial dos valores de pressão necessários para promover a abertura da ESDV. Porém, ao se realizar o teste de vedação, descrito pela Fig. 42, foi constatado que não houve vazamento da montante para a jusante, pelo método de contagem de bolhas.

Logo, na desmontagem da ESDV, as sedes foram analisadas, para investigação do comportamento que resultou no aumento dos valores de pressão durante os ciclos.

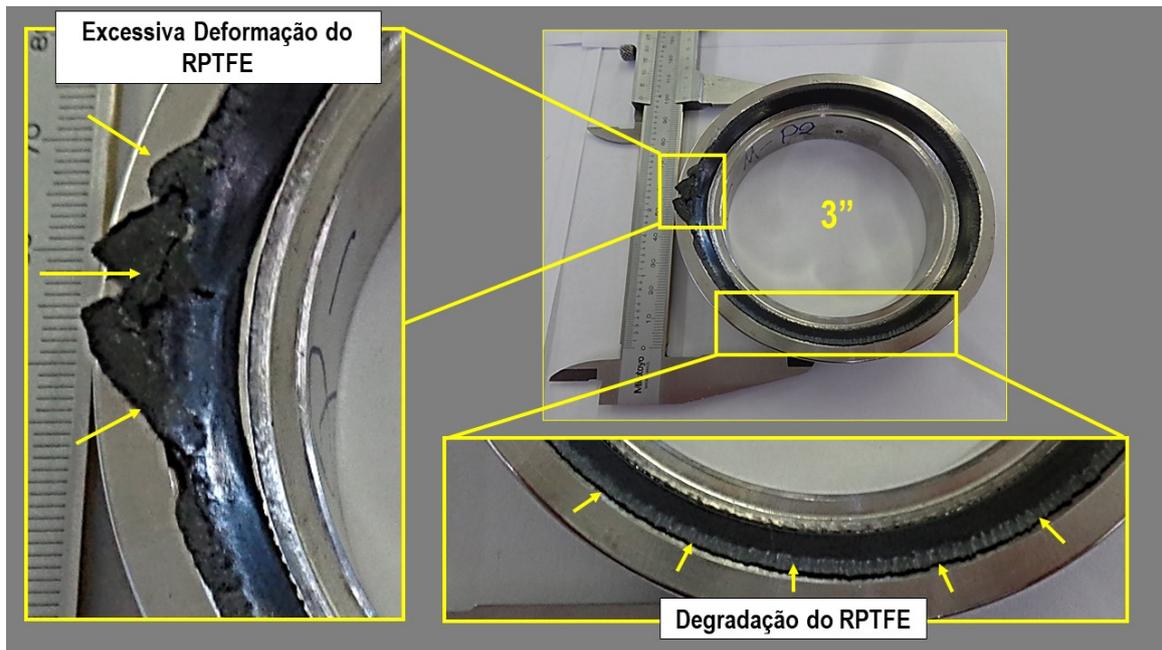
Na Fig. 51 é mostrada que o material polimérico RPTFE, no lado montante, sofreu uma deformação considerável, invadindo assim a banda de vedação da sede. Este material, provavelmente impôs um aumento de atrito durante a rotação de abertura da ESDV, levando assim, ao aumento de pressão exigido pelo atuador para promover a abertura.

O restante da válvula e do atuador, não apresentaram desgastes significativos que interferissem nos valores de pressão durante as aberturas da válvula.

Para se compreender o impacto da deformação polimérica na sede com o aumento de pressão, observado nos sinais, é necessário ter em mente o momento descrito como *crack-open* da válvula. Neste momento, onde o diferencial de pressão entre montante e jusante é máximo, ao se iniciar a rotação da ESDV para promover sua abertura, uma mínima passagem é criada na seção transversal do *bore* da válvula.

O fluido de trabalho, passa com velocidades supersônicas, conforme explicado em

Figura 51: Vista dos defeitos encontrados na sede ao lado montante da válvula ESDV.



Fonte: Próprio Autor.

literatura (Rossetto, 2016; Teles, 2020). Este aumento de velocidade, cria uma zona que acelera o desgaste em uma área principal da sede. Este comportamento, explica a razão da deformação do RPTFE ser visualizado em um lado somente da sede.

Outro fator que, aliado a explicação acima, também resulta no aumento de pressão necessária durante as operações de uma ESDV, é a curva do coeficiente de torque, descrita na Fig. 52. Nela, a pressão, descrita pelo eixo vermelho, somente equaliza após o momento de *crack-open*. Até este ponto o valor do coeficiente de torque, representado pela linha azul, apresenta um padrão crescente.

Após o *crack-open*, ele decai decorrente da equalização das pressões entre montante e jusante. Como o máximo valor do coeficiente ocorre justamente no *crack-open*, qualquer corpo sólido entre o obturador e a sede, poderá promover um aumento deste coeficiente.

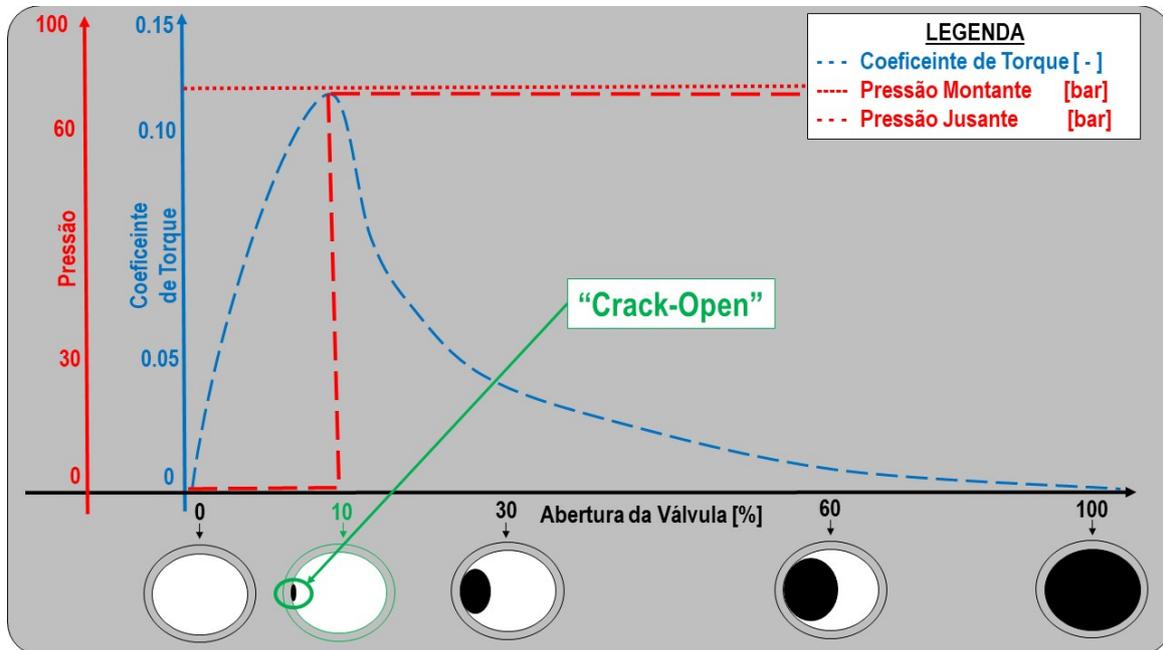
Portanto, a deformação vista na Fig. 51, promoveu esta contribuição nos valores adquiridos durante os ensaios e que serão analisadas nas seções posteriores deste trabalho.

Outros pontos também estão relacionados ao desgaste, conforme explica Khedkar et al. (2002), onde o contato deslizante de dois materiais resulta em um aumento calor, devido ao atrito de contato, logo a resistência ao desgaste adesivo dos materiais em contato, depende da capacidade do material de dissipar esse calor.

A capacidade de um material de resistir ao desgaste adesivo, causado pelo contato contínuo e movimento entre as superfícies, como a sede e a esfera durante os ensaios cíclicos, está diretamente ligada à sua capacidade de dissipar esse calor.

Isto conduz a um tema pouco explorado em vedações de válvulas, a dissipação de calor nas sedes aliado a lubrificação.

Figura 52: Gráfico mostra o comportamento do coeficiente de torque ( $y_1$ ) e pressões na montante e jusante da válvula em função das porcentagens de abertura ( $x$ ). Percebe-se que o coeficiente de Torque tende a aumentar no momento do *Crack-Open*.



Fonte: Próprio Autor.

Já em outros trabalhos, o modo de falha associados as sedes poliméricas RPTFE das válvulas, é resultado de uma fina camada de transferência dos materiais de contato, que podem contribuir significativamente para o aumento do coeficiente do torque resultante dos atritos. Isso implica que quando essa camada, que se forma durante o deslizamento entre as duas superfícies, falha ou se deteriora, isso pode levar a um aumento substancial na resistência ao movimento, que por fim, é perceptível através das pressões que o atuador hidráulico deve exercer para abrir a ESDV. Essa falha pode resultar em uma série de efeitos adversos, incluindo aumento do desgaste, geração de calor excessivo e diminuição da eficiência do sistema (Ben Jemaa et al., 2012).

Outro fator que contribui para a falha é o estresse de relaxamento associado aos movimentos cíclicos, como a abertura e o fechamento da ESDV, resultando principalmente em uma perda de massa atribuída a fenômenos de desgaste (Mnif et al., 2013). Isso sugere que, além do desgaste causado pelo atrito direto entre as superfícies, os movimentos repetitivos também desempenham um papel significativo na degradação do material. Esses ciclos de estresse e relaxamento podem levar a deformações graduais e microfissuras, aumentando assim a taxa de desgaste ao longo do tempo.

Portanto, para mitigar a perda de massa e garantir a integridade operacional da ESDV e sistemas similares, é crucial considerar não apenas o desgaste direto, mas também os efeitos dos movimentos cíclicos nos materiais envolvidos.

## 4.2 Análise da falha pela inspeção dos dados

As seções a seguir explorarão a falha ocorrida na sede polimérica através dos algoritmos de ML, aplicando técnicas de regressão, classificação e a estimativa da vida útil remanescente (RUL) da ESDV.

### 4.2.1 Labels para a classificação e regressão (RUL)

Primeiramente é necessário definir os ciclos onde ocorreram as falhas mostradas na Sec. 4.1. Isto é necessário para correlacioná-las com os dados obtidos através da instrumentação. Para isto, a abordagem inicial é analisar os KPs de maneira isolada, para então localizar os possíveis momentos onde a deformação excessiva do RPTFE ocorreu conforme já explicado na Fig. 51.

Esta etapa é necessária, pois a partir da localização das degradações, pode-se atribuir o *label* que será usado para especificar o RUL da ESDV além de servirem de entrada como "rótulos" para as técnicas de classificação envolvendo os algoritmos de monitoramento.

A análise inicia-se pela distribuição estatísticas dos KPs a partir de um histograma. Visto que houve a presença de um defeito (sede RPTFE deformada), é de se esperar que algum dos 4 KPs apresente dois comportamentos distintos.

Um relacionado ao comportamento normal da ESDV e outro, após a deformação, relacionado ao comportamento com defeito. Isto é explicado devido ao fato que o atuador hidráulico, responsável pela abertura e fechamento da ESDV, é sensível a qualquer mudança proveniente de atritos que ocorram no conjunto válvula e atuador.

Esta sensibilidade, é então, traduzida em uma mudança de pressão necessária para abrir a ESDV. Como os KPs são originários da assinatura de pressão, é esperado que esta mudança de pressão, seja perceptível a eles.

Conforme ilustrado na Fig. 53, é apresentado o histograma dos *Key Points* (KPs), onde é possível observar que, entre os quatro KPs, apenas o KP A3 parece apresentar um comportamento bi-modal.

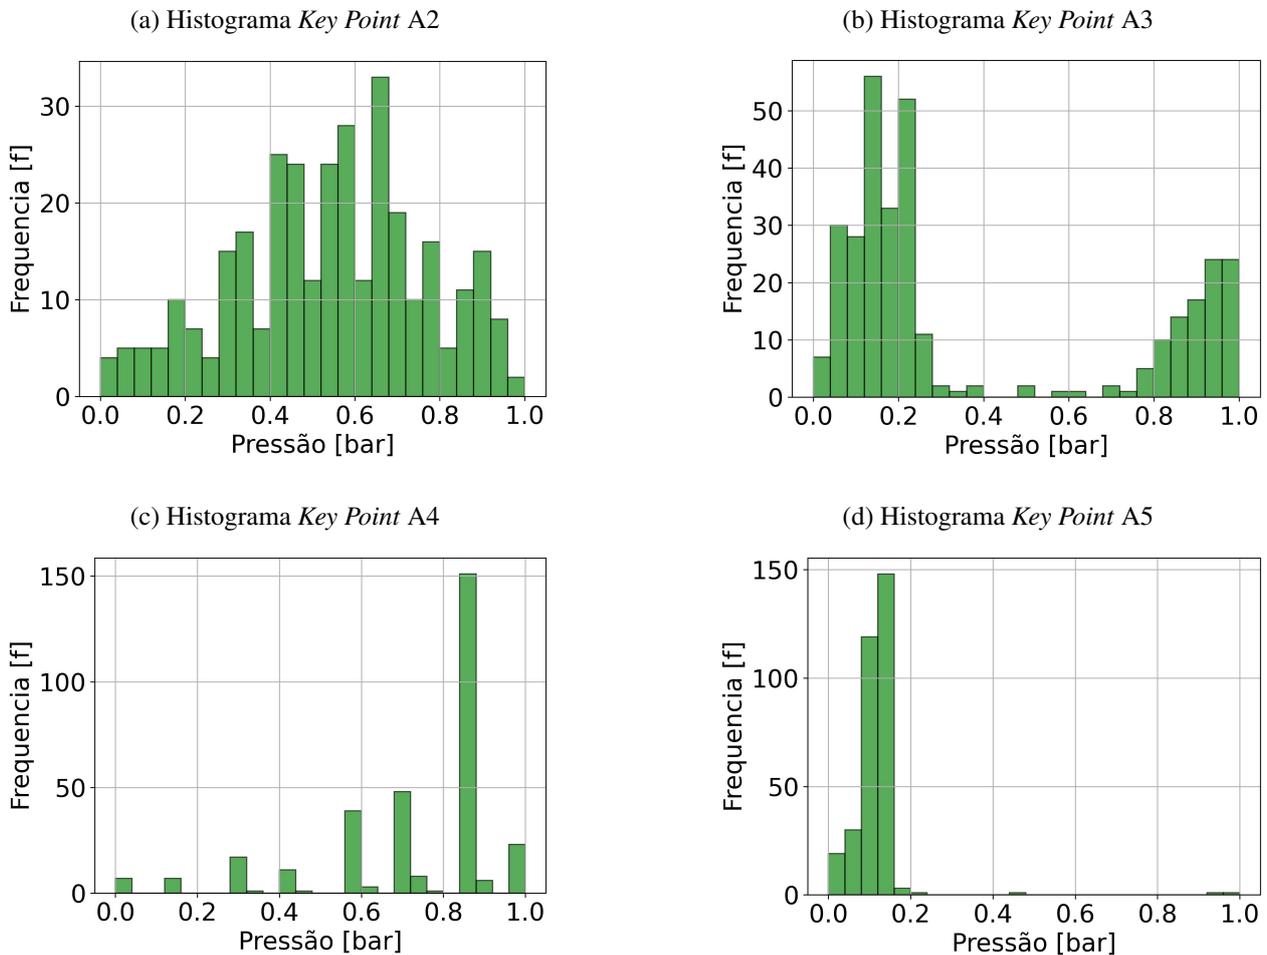
Essa observação sugere que o KP A3 pode estar associado a duas distribuições distintas de dados ou a dois estados diferentes do sistema sob análise. Essa característica bi-modal do KP A3 pode indicar uma mudança significativa no comportamento ou na operação da ESDV em relação aos outros KPs.

Essa análise do histograma dos KPs fornece informações importantes sobre a distribuição dos dados e ajuda a identificar padrões ou anomalias que podem não ser imediatamente evidentes em uma inspeção visual dos dados brutos.

A partir dos dados de assinatura, é possível utilizar algoritmos de redução da dimensionalidade, conforme explicado na Sec. 2.7.5, para facilitar a compreensão de dados em fatores de ordem acima do  $R^3$ , como as assinaturas de pressão de uma ESDV.

Esses algoritmos são essenciais para transformar dados complexos e de alta dimensionalidade em representações mais simples e compreensíveis, permitindo uma análise mais eficaz. Ao se comparar a assinatura em seu estado bruto, ou seja, sem nenhum pós-processamento, há uma certa dificuldade

Figura 53: Histograma dos KPs a fim de identificar um comportamento bi-modal relacionado com dois estados: normais e degradados da ESDV em estudo.



Fonte: Próprio Autor.

para o observador extrair informações sobre mudanças de estado.

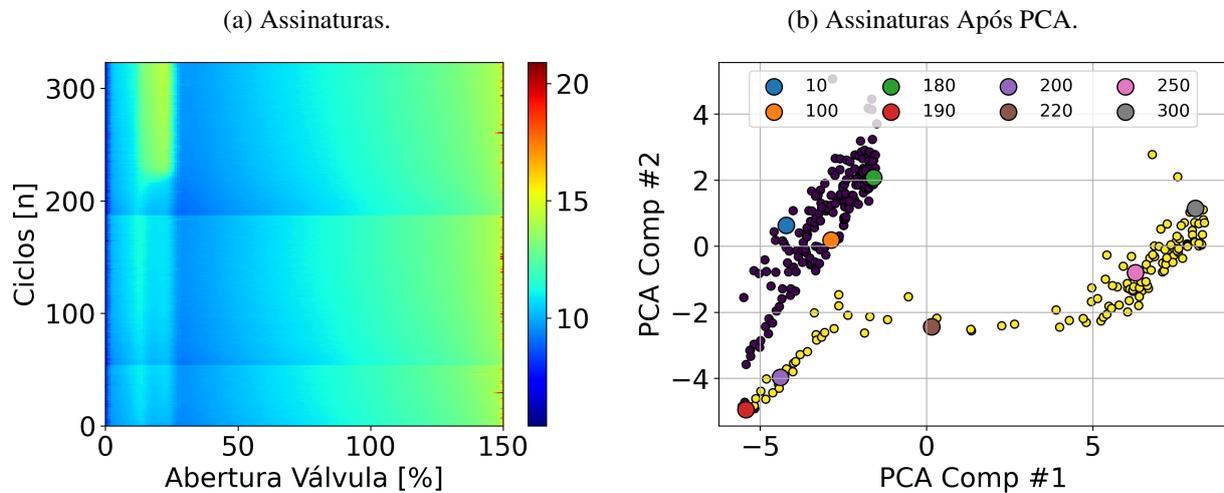
Isso é ilustrado na Fig. 54, onde as variações sutis e os padrões importantes podem não ser facilmente discerníveis. No entanto, ao aplicar o *Principal Component Analysis* (PCA) a esses mesmos dados, é possível visualizar as informações de maneira mais clara em  $R^2$ .

O PCA reduz a complexidade dos dados mantendo a maioria da variância, facilitando a identificação de padrões e anomalias.

Na Fig. 54b, os círculos maiores representam os ciclos de cada evento (assinatura). Observa-se que entre os ciclos 100 e 190 há uma fronteira bem definida. Esta clara demarcação indica que próximo ao evento 190 pode ser o início da deformação excessiva do RPTFE.

Essa conclusão é derivada dos valores de pressão lidos no sensor da câmara de atuação e resumidos na análise PCA. Portanto, o uso do PCA não só simplifica a visualização dos dados, mas também ajuda a identificar pontos críticos de transição no comportamento da válvula, fornecendo percepções valiosas para a manutenção e operação da ESDV.

Figura 54: Identificação da mudança de comportamento através da aplicação de *Principal Component Analysis* (PCA) aos dados de assinatura. Notar o ciclo 190, através do círculo vermelho.



Fonte: Próprio Autor.

A partir do exposto nas explicações acima, este trabalho utilizará o ciclo 190 como o momento em que a deformação excessiva do RPTFE ocorreu. Essa decisão é fundamentada na análise detalhada dos dados de assinatura, que revelou uma fronteira bem definida entre os ciclos 100 e 190, indicando uma possível mudança significativa no comportamento da válvula ESDV. O ciclo 190 foi identificado como o ponto onde essa transição ocorreu, representando o momento em que a deformação excessiva do RPTFE se manifestou.

#### 4.2.1.1 KPs

Os dados resultantes dos ensaios foram processados e estão dispostos na Fig. 55 na forma de *Key Points*. O momento em que ocorreram a deformação do RPTFE foi determinado no ciclo 190 conforme estudo conduzido na Sec. 4.2.1.

Analisando os *Key Points* A2, A4 e A5, percebe-se que nenhum destes mencionados, capturou o dano ocorrido na sede, como já foi mostrado na Fig. 51. O KP A2, representado pela linha em vermelho, sofre as variações antes do defeito, no ciclo 190, porém, repete este padrão após o dano, sendo assim, insensível à degradação ocorrida da ESDV. O KP A4, apresenta comportamento semelhante, mas com patamares de pressão mais lineares, porém, se chegar ao ponto de ser sensível ao dano.

O KP A5, que está representado pela linha em magenta, esta relacionada ao fim da abertura e consequentemente, a completa compressão da mola, fica insensível ao dano. Isto já era esperado, uma vez que a degradação na sede polimérica, ocorreu nos 10% da abertura iniciais da válvula e o A5 costuma ocorrer nos 95% finais.

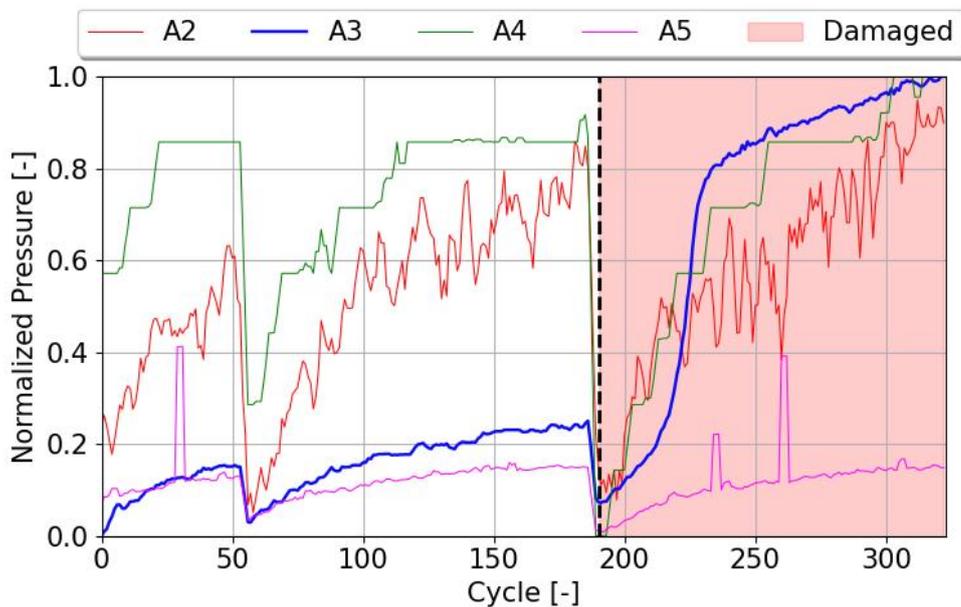
Relacionando a Fig. 55 com a Fig. 53, nota-se que o KP A3 parece ser o único KP sensível à mudança de estado decorridos do defeito na ESDV. Isto por que, como ocorreu o defeito na sede

polimérica da ESDV enquanto o teste ocorria, é de se esperar que algum KP consiga extrair esta informação e resumir a mudança de funcionamento, traduzindo a variação na pressão do atuador necessária para promover a abertura da válvula.

Isto corresponde com a literatura e o esperado, uma vez que o KP A3 está diretamente relacionado com o *crack-open*, ele é o KP mais indicado para notar uma degradação ocorrida neste momento durante a abertura.

Portanto, o KP A3 será utilizado nas metodologias envolvendo o *Key Point* para alimentar os algoritmos.

Figura 55: Tendência temporal, por ciclos, de cada KP após a localização do ciclo onde o dano se iniciou. Nota-se que o KP A3 aparenta ser mais sensível ao dano, visto que foi o único que apresentou um comportamento estável antes do ciclo 190 e uma subida após este ciclo.



Fonte: Próprio Autor.

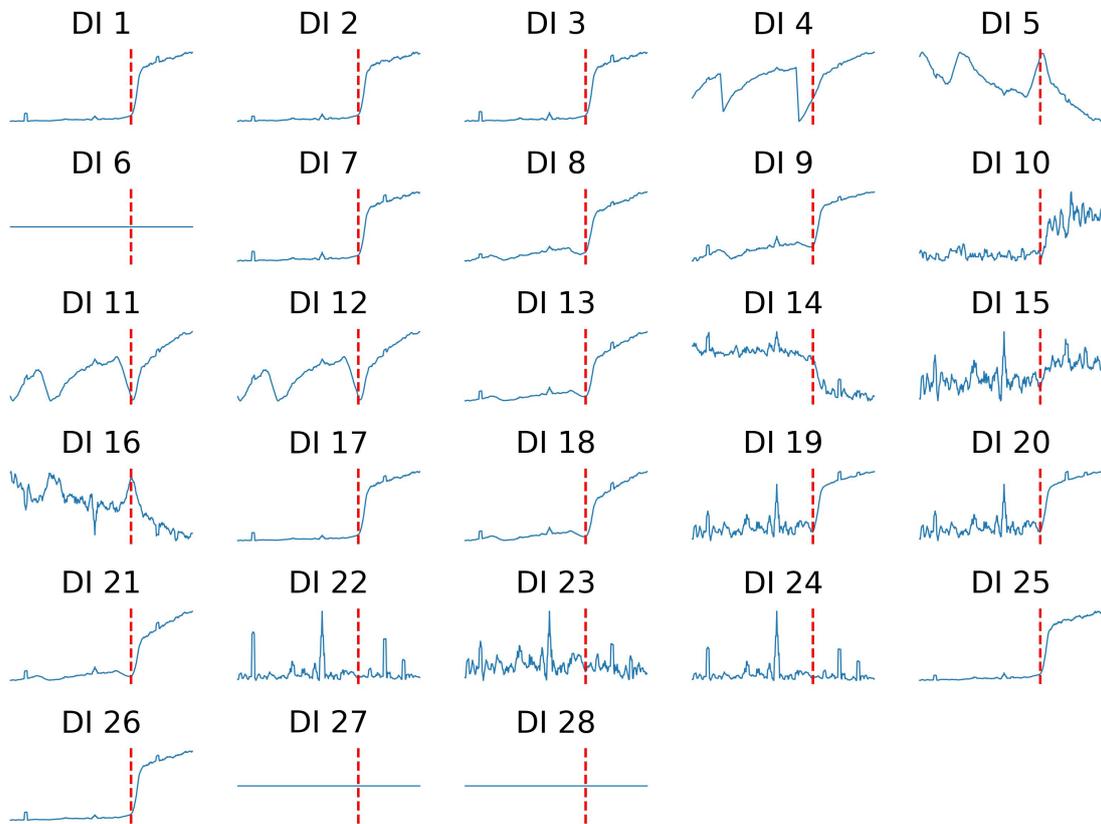
#### 4.2.1.2 DIs

Aplicando as equações descritas nas Tab. 6 e 7, os DIs são obtidos conforme ilustra as Fig. 56 para os dados de pressão. Na figura, o momento do dano está descrito com as linhas tracejadas em vermelho, representando o ciclo 190. Para os DIs, seu respectivo índice numérico se encontra na parte superior.

Conforme já explicado nas seções anteriores, teremos 28 DIs para serem avaliados nesta tese. Os eixo y e x, embora omitidos desta representação, possuem seus valores em magnitude associada a cada DI e o ciclo (evento) da ESDV, respectivamente.

Para o dano, grande parte dos DIs de pressão foram sensíveis a ele, como os DIs: 1, 2, 7, 8, 9, 10, 14, 25 e 26. A fim de ilustrar o potencial dos DIs como uma alternativa ao uso dos KPs, pode-se utilizar o comportamento do DI 10, ilustrado na Fig. 57. Este DI apresentou um nível de ruído com

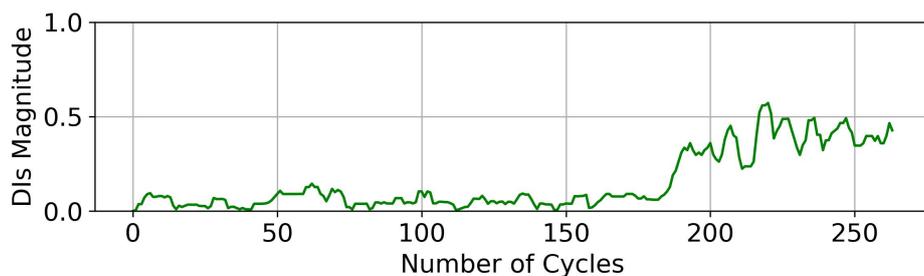
Figura 56: *Damage Index* (DIs) aplicados nos conjunto de dados resultantes dos dados de pressão. As linhas tracejadas em vermelho representam o dano. O eixo y esta normalizado entre 0 e 1. O eixo x representa os ciclos realizados durante os ensaios cíclicos.



Fonte: Próprio Autor.

um patamar comportado nos ciclos iniciais, porém, com uma amplitude elevada no momento do dano. Este comportamento evidencia o potencial dos DIs aplicados em danos de válvulas, por conseguirem obter o comportamento não linear do sinal e resumi-lo em um valor escalar.

Figura 57: *Damage Index Score Energy Phase* — DI 10 aplicados aos dados. Nota-se ele é capaz, mesmo com ruídos, de capturar um comportamento antes e após o ciclo 190.



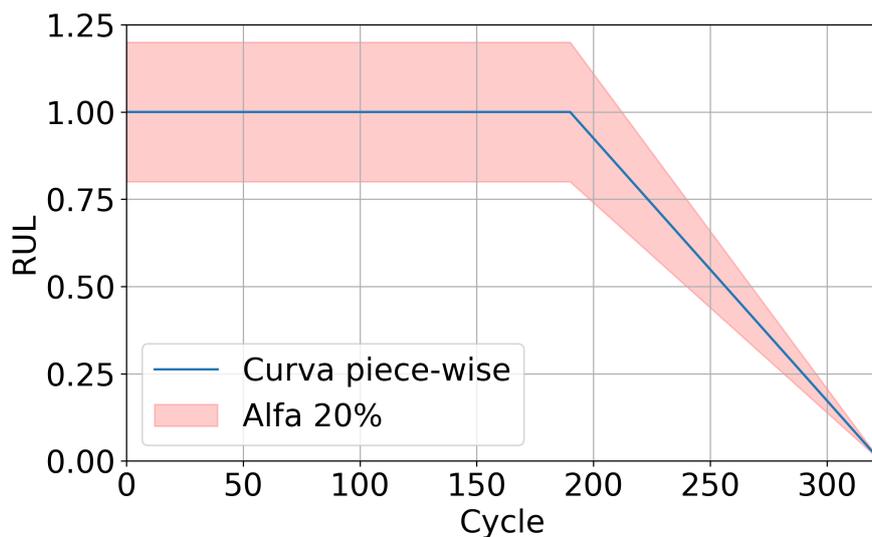
Fonte: Próprio Autor.

#### 4.2.1.3 RUL

Com os momentos de degradação já associado aos ciclos da ESDV, é possível descrever a curva que representa o *Remaining Useful Life* RUL do equipamento, desde seu funcionamento de maneira normal, passando por um estágio de degradação aceitável até sua degradação total.

Conforme abordado na Sec. 2.9, a curva *Piecewise* é amplamente aplicada para descrever RUL de sistemas, desde componentes eletrônicos, como baterias de Lítio, turbinas de aeronaves até rolamentos utilizados em bombas mecânicas. O RUL inicia no patamar de valor numérico igual a um, descrevendo a ESDV operando de maneira totalmente satisfatória. No decorrer dos testes, ao superar o limiar do dano, no ciclo 190, a curva inicia o regime de degradação, assumindo uma função linear de primeira ordem conforme ilustrado pela Fig. 58. Além disto, foi calculado o intervalo de confiança *alpha* da curva RUL, como sendo 20% do valor real. Este intervalo está representado pela cor vermelha.

Figura 58: *Remaining Useful Life* (RUL) curva para descrever o estado de degradação do equipamento. Foram utilizados uma curva *Piece-Wise* para capturar o estágio de degradações.



Fonte: Próprio Autor.

Para a proposta de realizar a regressão do RUL através de algoritmos redes neurais, esta curva será utilizada como o *Label* (rótulo) para o algoritmo, ou seja, como serão usadas as assinaturas de pressão como entrada (*input*), as saídas (*output* serão os valores desta curva que representa a vida útil remanescente (RUL) da válvula ESDV.

#### 4.2.2 Monte Carlo para dados sintéticos

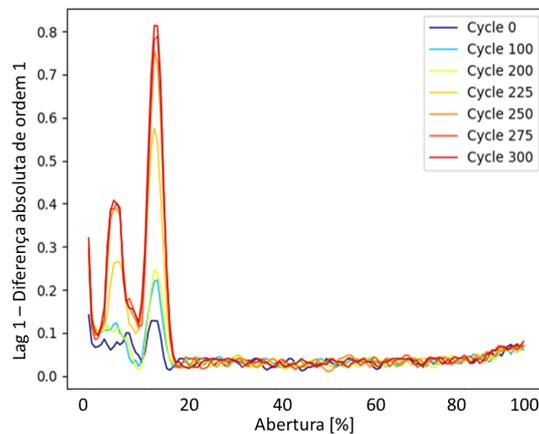
As assinaturas sintéticas geradas pelo método proposto e explicado anteriormente serão exibidas nesta seção. Após a geração das assinaturas, totalizando 15000 amostras, foi necessário aplicar uma média móvel em todo o sinal para suavizar os "picos" de pressão e obter uma assinatura mais homogênea. Esse processo é fundamental para melhorar a qualidade dos dados e facilitar a análise

subsequente.

Em seguida, foi realizada a diferenciação de uma posição entre a aquisição da assinatura e seu valor posterior, utilizando um *Lag* igual a um. Essa etapa é importante para capturar variações sutis no sinal que podem ser críticas para a detecção de padrões.

Após a aplicação do *Lag*, foi determinado um limiar de corte, conforme ilustrado na Fig. 59. Este limiar é essencial para filtrar os dados e garantir que apenas as assinaturas mais relevantes sejam consideradas. Com base nesse critério, terminamos com 1621 assinaturas sintéticas que serão utilizadas para treinar os algoritmos. Essas assinaturas refinadas e selecionadas fornecerão uma base para o treinamento dos modelos.

Figura 59: Aplicação de *Lag* 1 nos dados para verificar qual os valores limites antes e após o dano, no ciclo 190. Isto será para estipular o *Threshold* na seleção das assinaturas sintéticas, sendo 0.4 para assinaturas sem defeitos (anteriores ao ciclo 190) e 1 para assinaturas com defeitos (posteriores ao ciclo 190).



Fonte: Próprio Autor.

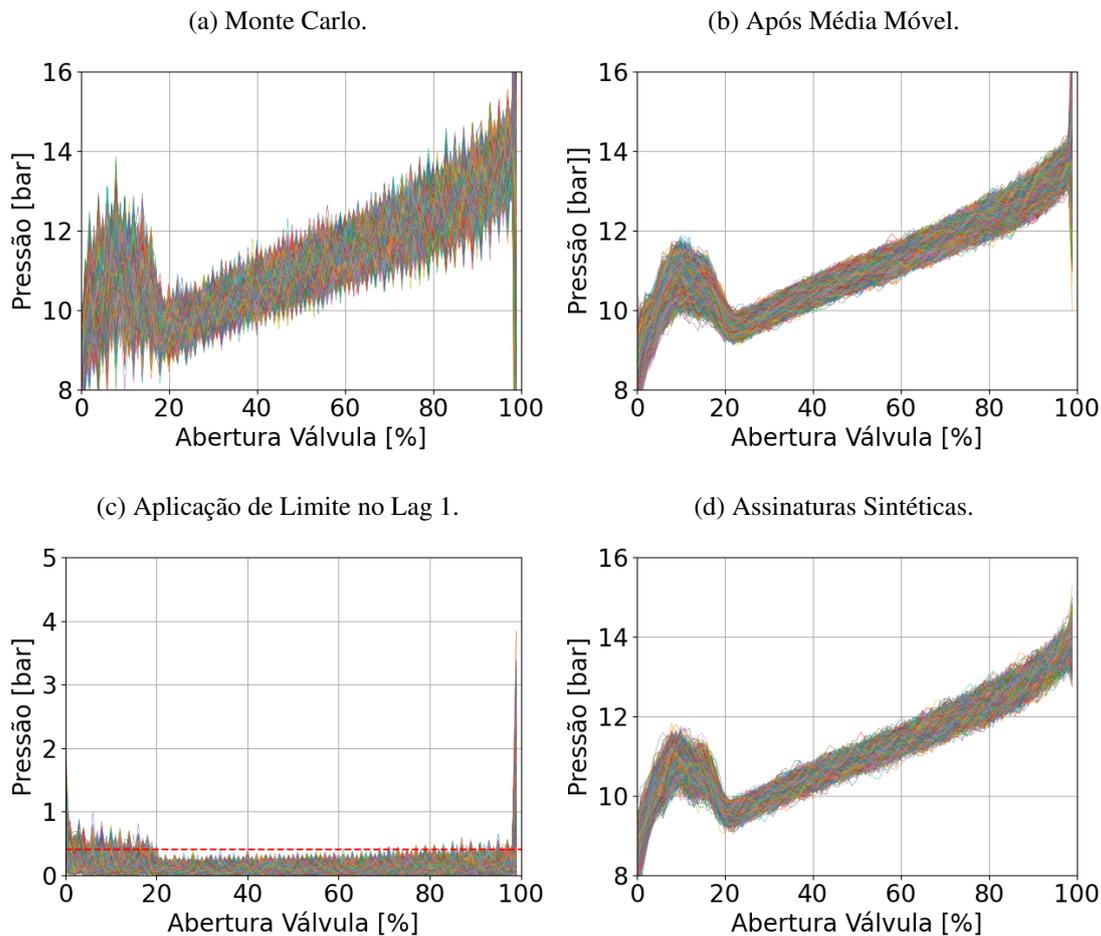
O mesmo raciocínio foi aplicado aos sinais com dano. Após a aplicação do método de geração e processamento, incluindo a média móvel para suavização e a diferenciação com *Lag* igual a um, totalizamos, após o corte, 1103 dados de assinaturas com defeitos. Esse procedimento garante que os sinais relacionados ao dano da válvula, sejam tratados consistentemente com os dados reais com dano. As 1103 assinaturas com defeitos serão utilizadas para treinar e validar os algoritmos.

De modo a mostrar a variação dos dados sintéticos, a Fig. 62 apresenta a média geral das assinaturas sintéticas, juntamente com algumas assinaturas selecionadas para ilustrar o comportamento de cada sinal sintético.

Nota-se que, em ambos os casos, as assinaturas sintéticas conseguiram capturar e reproduzir a variabilidade estatística do sinal. Especificamente, a partir da abertura, entre as porcentagens de 30% a 90%, a sombra em vermelho indica que existe informação relevante nessa região da assinatura.

É importante destacar que essa região é ignorada pelo método tradicional dos *Key Points* (KP), pois entre os KP A4 e A5 não existe um KP intermediário que possa extrair informações sobre a operação da válvula ESDV nesse intervalo. Agora o diferencial de pressão entre a montante e jusante

Figura 60: Assinaturas Sintéticas geradas pelo método de Monte Carlo para os dados sem defeitos.



Fonte: Próprio Autor.

não existe, pois o momento de *crack-open*, já ocorreu, logo, só existe a força que o pistão exerce contra a mola, comprimindo-a.

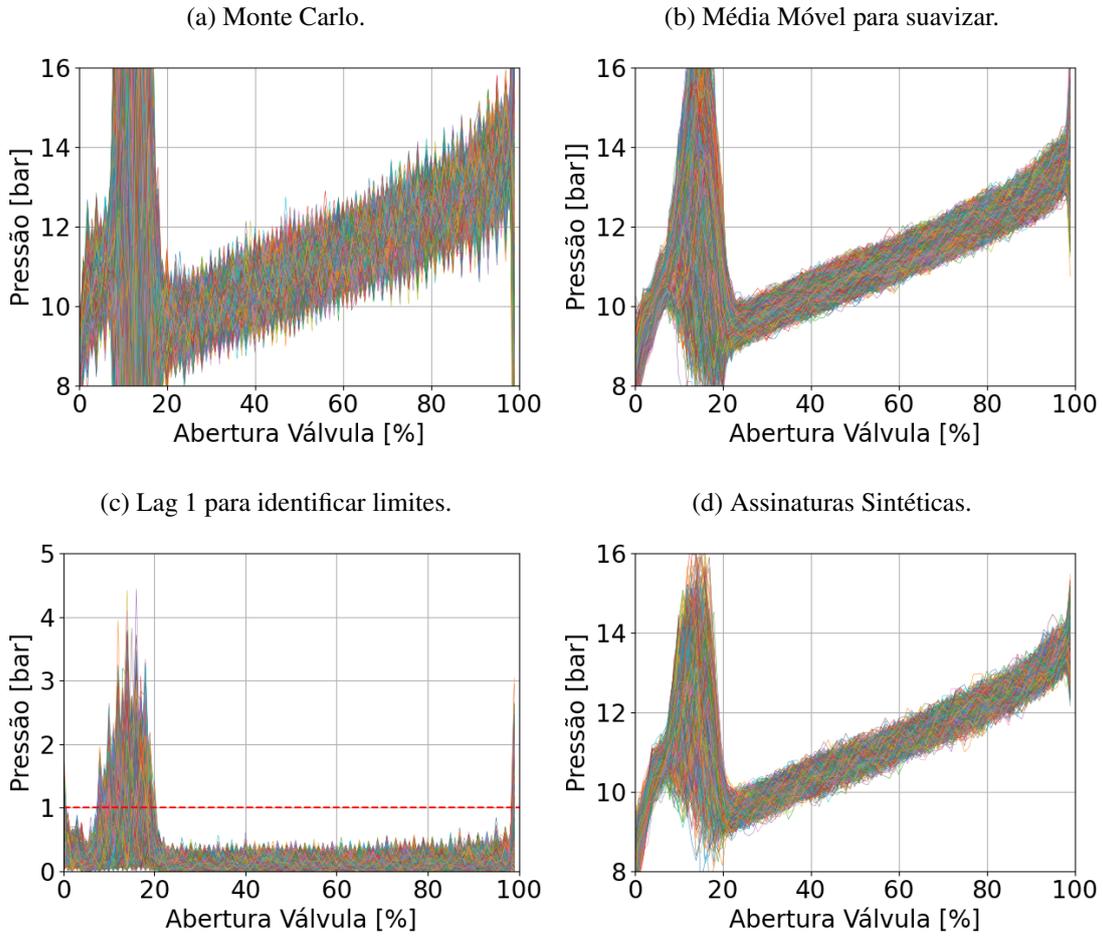
Caso a mola apresente uma mudança de rigidez nesta região, o método dos KPs não irá conseguir capturar tal comportamento. Portanto, a variabilidade dos dados sintéticos nesta região, comprovam que estes foram capazes de abstrair um comportamento geral na assinatura em toda a sua extensão, desde a abertura em zero por cento, como em quarenta, sessenta e indo até os cem por cento.

Ao analisar a razão entre a quantidade de dados reais e os dados criados sinteticamente, é obtido a Tab. 10, onde é comprovado que a criação dos dados não desbalanceou o banco de dados.

A razão entre os dados normal-dano, se manteve entre 0,70 para o conjunto real e para o conjunto sintético, apresentou 0,68. Para a razão entre somente os dados sem dano, ou seja, normal, a razão do banco real e sintético apresentou 8,5. Já para os dados com dano, a razão de 8,2 entre dados reais e sintéticas, foi obtida.

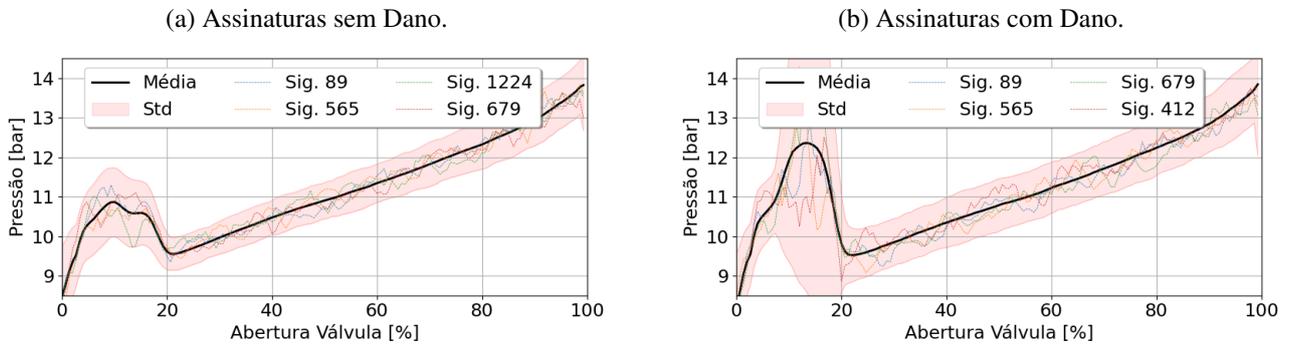
Isto comprova que os dados sintéticos, não geraram um banco desbalanceados, o que poderia criar um viés de pontuação vantajosa. A relação, em ambos os cenários, se mostrou próxima, resultando na capacidade de utilização destes dados sintéticos durante a etapa de treinamento dos algoritmos de

Figura 61: Assinaturas Sintéticas geradas pelo método de Monte Carlo para os dados sem defeitos.



Fonte: Próprio Autor.

Figura 62: Exemplos de assinaturas sintéticas geradas pelo método de Monte Carlo, tanto para os sinais sem defeito como para os sinais com defeito.



Fonte: Próprio Autor.

classificação de dano.

Tabela 10: Razões entre os dados reais e sintéticos para os sinais com e sem a presença do dano.

	Normal	Dano	Razão Normal-Dano
<b>Real</b>	190	133	0.70
<b>Sintética</b>	1621	1103	0.68
<b>Razão</b>	8.5	8.2	

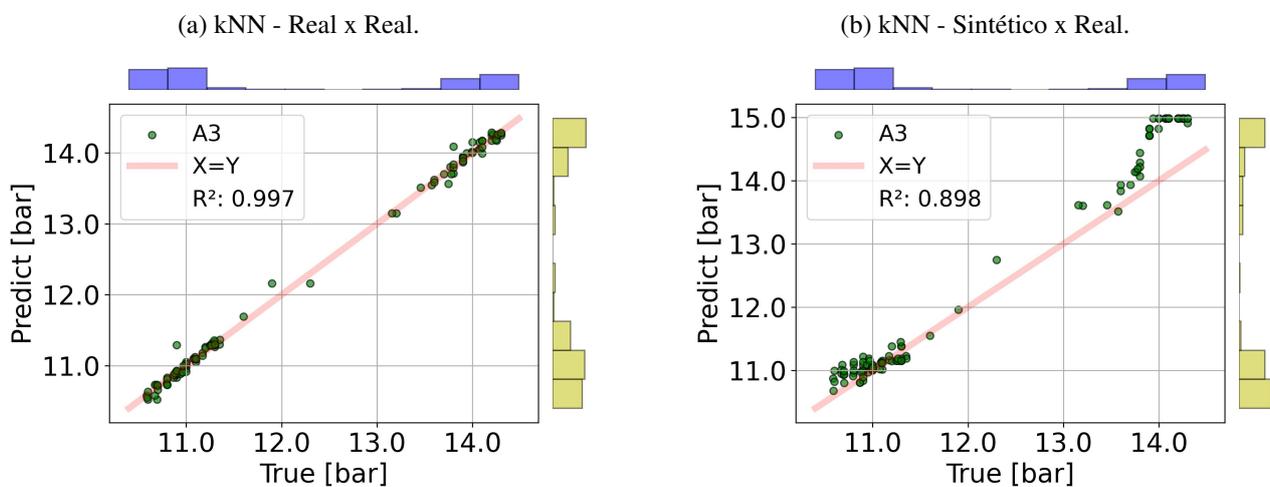
Fonte: Próprio Autor.

### 4.2.3 Regressão para os KPs

Um dos objetivos deste trabalho, é verificar se os algoritmos de ML podem aprender a reconhecer e marcar os KPs de uma assinatura de pressão de maneira automática. Portanto, nas Figuras abaixo, estão exibidos os resultados da regressão aplicando as assinaturas de pressão e os “rótulos” de saída, sendo o KP A3, identificado por cada algoritmo.

O algoritmo kNN apresentou ótimo resultado na regressão do KP A3 usando dados reais para e para o teste. Porém, quando se treina o modelo apenas com dados sintéticos, o r quadrado, recuou, apresentando um valor final de 0,898.

Figura 63: Resultado da regressão do *Key Point* A3 utilizando o algoritmo kNN. Os dados de entrada foram a assinatura de pressão.

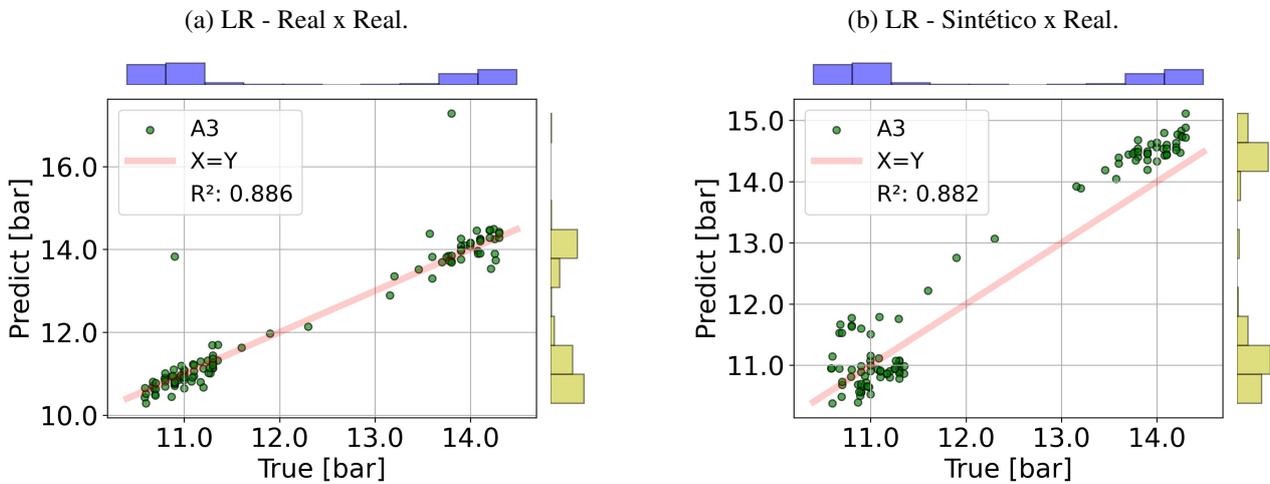


Fonte: Próprio Autor.

O LR apresentou resultados medianos na regressão do KP A3. O uso de dados sintéticos não tão perceptível ao modelo como o kNN a fim de diminuir a pontuação comparada aos dados apenas reais. Em ambos os conjuntos de dados, o *score* pelo método do R quadrado, ficou na casa de 0.88.

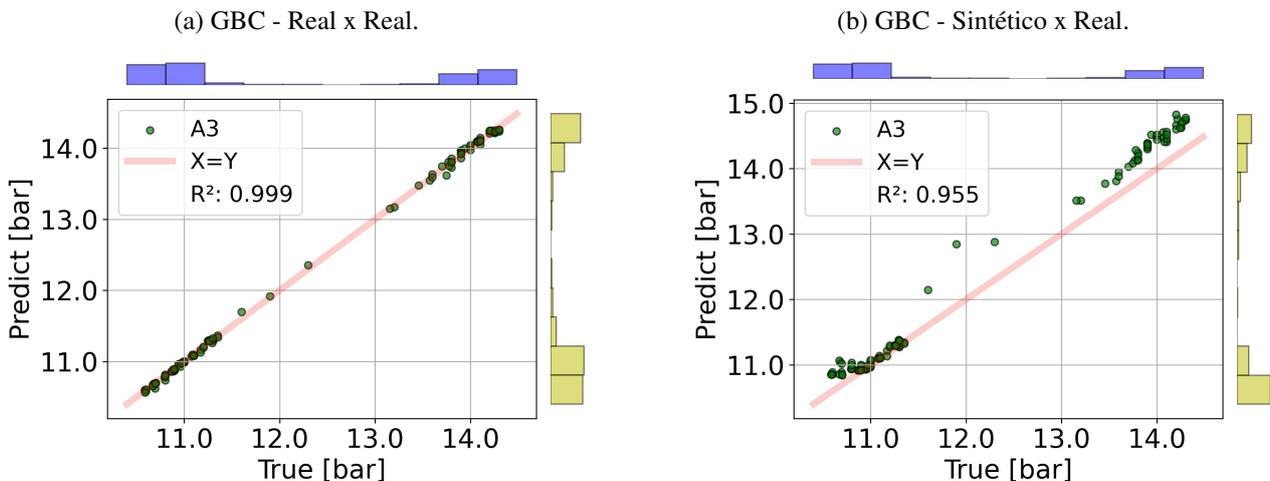
O modelo GBC apresentou resultados excelentes, tanto usando os dados reais, como os dados sintéticos durante a fase de treinamento para a regressão do KP A3. Quando se utilizou apenas dados reais para o treino, a pontuação final chegou a impressionantes 0,999. Ao se treinar o algoritmo com os dados sintéticos, o GBC apresentou o incrível score de 0,955 superando o LR utilizando dados reais no treinamento.

Figura 64: Resultado da regressão do *Key Point* A3 utilizando o algoritmo LR. Os dados de entrada foram a assinatura de pressão.



Fonte: Próprio Autor.

Figura 65: Resultado da regressão do *Key Point* A3 utilizando o algoritmo GBC. Os dados de entrada foram a assinatura de pressão.

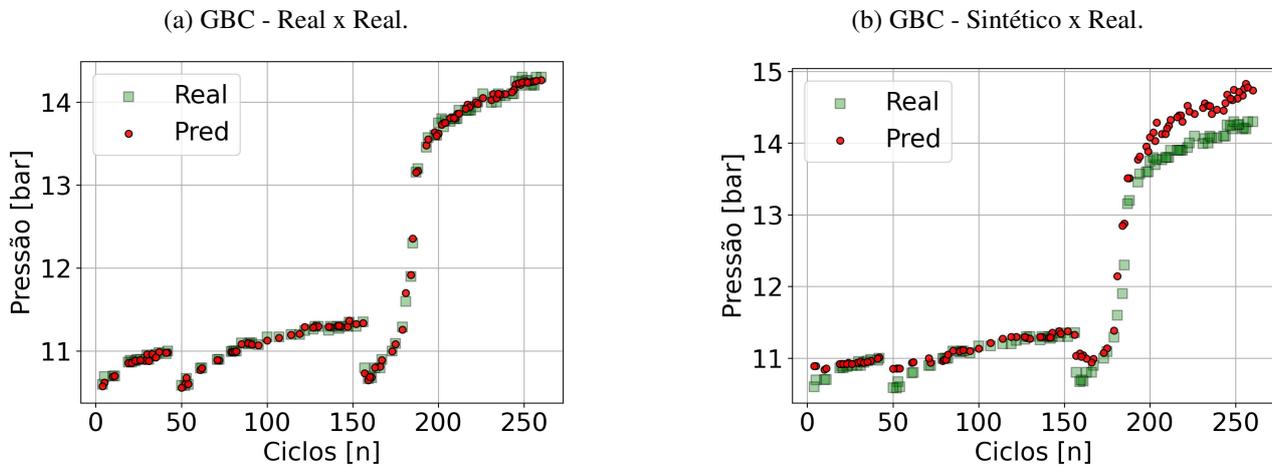


Fonte: Próprio Autor.

Para mostrar o potencial de aplicação de algoritmos de ML para realizar a identificação dos KPs, a Fig. 67 exibe a regressão pelo algoritmo GBR temporalmente. Os valores reais estão dispostos na forma de quadrados verdes, já os valores previstos pelo modelo, são descritos pelos círculos avermelhados.

Percebe-se que para os dados sintéticos, Fig. 66, o modelo encontrou certa dificuldade para prever os valores de pressão nos ciclos finais, justamente onde houve a deformação excessiva do RPTFE. Porém, este fato não exclui o impressionante resultado atingido pelo GBR mesmo utilizando dados sintéticos no treinamento.

Figura 66: Resultado em disposição temporal (ciclos) da regressão do KP A3 usando o algoritmo GBC.



Fonte: Próprio Autor.

#### 4.2.4 Classificação de dano usando dados reais e sintéticos

Esta seção irá abordar e discutir os resultados provenientes da classificação de dano, usando três métodos: KPs, DIs e assinatura. Cada método será avaliado por dois conjuntos de dados:

- Treino com dados reais e Teste com dados reais
- Treino com dados sintético e Teste dados com reais

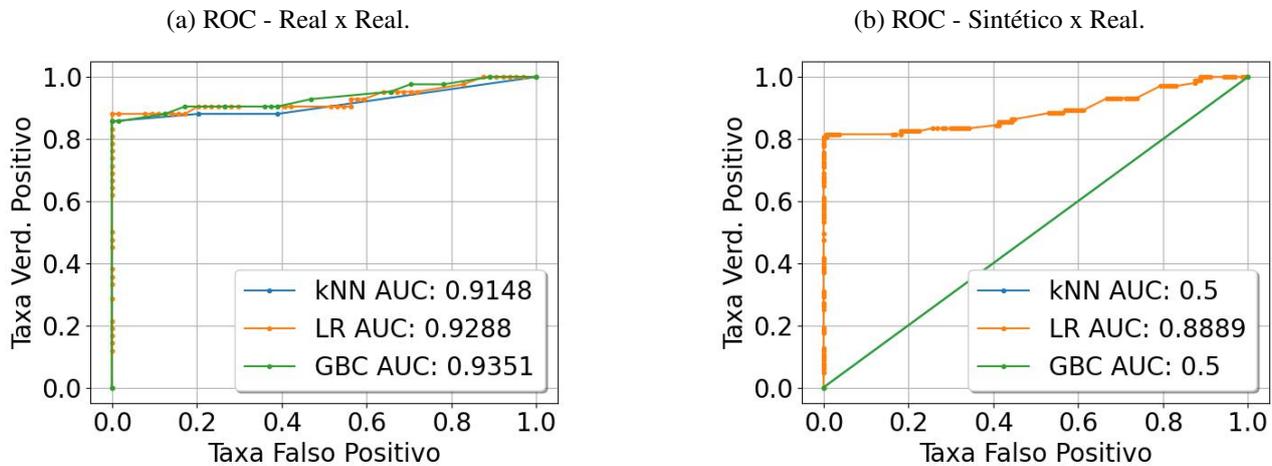
##### 4.2.4.1 Classificação pelo Key Point

A classificação usando o KP A3 como entrada, resultou nos resultados dispostos abaixo. Foi utilizado a curva ROC como métrica de avaliação. Com os dados reais durante o treino, todos os algoritmos obtiveram uma pontuação semelhante, na casa dos 0.9.

Porém, assim como já verificado na regressão dos KPs, o algoritmo GBC, apresentou o melhor desempenho, chegando a demonstrar um *score AUC* de 0,9351, conforme Fig. 67 mostra. Ao se mudar o conjunto de dados para realizar o treinamento e passando os dados sintéticos, o LR surpreendeu e apresentou um resultado próximo à média dos seus concorrentes usando dados reais. Por outro lado, os algoritmos kNN e GBC não conseguiram extrair as informações do KP A3 e correlacioná-los com o estado final da ESDV.

Isto pode se dar a simplicidade que o LR funciona, uma vez que sua fronteira de decisão esta relaciona a curva *sigmoid* utilizada para decidir se uma entrada pertence à classe "zero" ou "um". Já o GBC, como utiliza as árvores de decisão e os resíduos, também chamados de gradientes, dos erros anteriores, isto pode ter levado este algoritmo a um *overfitting* dos resultados (ver Fig. 32) se adequando de maneira excelente ao treinamento, porém apresentando uma pontuação aleatória e pobre ao se deparar com o conjunto de dados durante a fase de testes.

Figura 67: Resultado da classificação pelo *Key Point* usando os três algoritmos, kNN, LR e GBC. A linha azul representa o modelo kNN, a laranja o LR e o GBC é representado pela linha verde. Os resultados são demonstrados através da curva ROC. Os dados de entrada utilizados foram os KPs A3.



Fonte: Próprio Autor.

#### 4.2.4.2 Classificação pelos Damage Index

A classificação realizada utilizando os DIs está apresentada detalhadamente na Tab. 11. Nesta tabela, são exibidos os resultados obtidos quando os três algoritmos foram treinados com dados reais, sendo que a pontuação foi calculada com base em testes realizados também com dados reais.

A métrica utilizada para avaliar o desempenho dos algoritmos é o *AUC score*, o qual é derivado da análise da curva ROC (Receiver Operating Characteristic), uma técnica amplamente reconhecida para a avaliação de modelos de classificação. Adicionalmente, os resultados referentes aos testes no qual os algoritmos foram treinados exclusivamente com dados sintéticos estão sistematicamente organizados e exibidos na Tabela 12. Esta tabela ilustra o desempenho dos mesmos três algoritmos, desta vez avaliados com dados reais, mas após terem sido treinados apenas com dados sintéticos. A comparação entre estas duas tabelas proporciona uma visão abrangente do impacto que o tipo de dado utilizado no treinamento tem sobre a eficácia dos algoritmos quando submetidos a testes com dados reais.

Para proporcionar uma compreensão mais clara e detalhada dos resultados obtidos, foi gerado um gráfico no formato de *boxplot*. Este tipo de gráfico visualiza de maneira resumida os resultados de cada conjunto de dados, permitindo uma análise comparativa entre os dados reais e os dados sintéticos utilizados no treinamento dos modelos como ilustrado na Fig. 70.

A média da pontuação para os DIs usando o algoritmo kNN, foi de 0,818. Para o LR e GBC foram de 0,77 e 0,82 respectivamente. Novamente, assim como na classificação pelos *Key Points*, nota-se que o GBC obteve uma melhor pontuação com os dados reais durante o treinamento usando os DIs. Na Fig. 68b, usando os dados sintéticos para treinar os três algoritmos, o kNN apresentou a pior média geral, com 0,70. Já o *Gradient Boosting Classifier* apresentou o melhor resultado

Tabela 11: Tabela com os resultados da curva ROC para todos os DIs. Resultados utilizando os dados Reais para treino e Reais para teste.

DI	kNN	LR	GBC
CrossCorrelation	0.97211	0.991935	0.989247
CrossCorrelationCoef	0.959005	0.986559	0.974126
CrossCorrelationFFT	0.941196	0.983871	0.970766
CrossCorrelationMax	0.882056	0.796371	0.879368
CrossCorrelationMaxPercentDiff	0.847782	0.852823	0.841398
CrossCorrelationTimeOfFlight	0.5	0	0.5
CrossCorrelationZerolag	0.941196	0.983871	0.970766
DTW	0.932796	0.928763	0.951613
EnergyEnvRatio	0.933132	0.956317	0.956317
EnergyPhase	0.905914	0.916667	0.945901
EnergyRatio	0.792003	0.860215	0.800739
EnergyRelativeDiff	0.792003	0.860215	0.800739
EnergyResidualNorm	0.896505	0.933468	0.91129
EnergyShared	0.921707	0.922715	0.921707
EnergySharedDiffNorm	0.700605	0.71707	0.710013
EnergySharedNorm	0.822245	0.836022	0.828965
EnergySignal	0.97211	0.991935	0.989247
EnergySignalSumSquareDiff	0.899866	0.928763	0.93582
L1Max	0.882728	0.90457	0.872648
L1MaxNomr	0.882728	0.90457	0.872648
L2	0.899866	0.928763	0.93582
SignalAmpHilbertMax	0.742944	0.456989	0.711358
SignalAmpPeakRatio	0.476142	0.561492	0.455309
SignalAmpPeakSquaredPercentDiff	0.476142	0.561492	0.455309
SignalDiffCoef	0.959005	0.986559	0.974126
SpatialPhase	0.97211	0.991935	0.989247
SpectrumLoss	0.5	0	0.5
SpectrumLossCentral	0.5	0	0.5

Fonte: Próprio Autor.

dentro os três concorrentes, com uma média final de 0,768 AUC Score.

Como os DIs possuem um potencial para descreverem o estado de operação de uma ESDV, outra análise foi proposta, focando em cada família de DIs individualmente, para verificar qual apresenta mais potencial para descrever a ESDV. Assim, a Fig. 69 mostra estes resultados, onde se nota que os DIs de energia, apresentaram pouca dispersão entre os resultados, apresentando um *AUC Score* médio de 0.86, 0.89 e 0.88 para kNN, LR e GBC respectivamente.

Em comparação, os DIs de correlação, conforme mostra a Fig. 69, apresentaram uma dispersão maior nos seus resultados, obtendo uma média de 0.87, 0.81 e 0.88 para os algoritmos de kNN, LR e GBC respectivamente.

Para demonstrar a capacidade dos DIs para serem considerados como um potencial substitutos ao uso dos KPs na avaliação de uma ESDV, a Fig. 70 retorna três DIs, juntamente com sua pontuação

Tabela 12: Tabela com os resultados da curva ROC para todos os DIs. Resultados utilizando os dados Sintéticos para treino e Reais para teste

DI	kNN	LR	GBC
CrossCorrelation	0.953883	0.991141	0.971117
CrossCorrelationCoef	0.959951	0.988835	0.961833
CrossCorrelationFFT	0.942931	0.987318	0.962894
CrossCorrelationMax	0.566778	0.703337	0.583829
CrossCorrelationMaxPercentDiff	0.59821	0.783495	0.626244
CrossCorrelationTimeOfFlight	0.5	0	0.5
CrossCorrelationZerolag	0.952093	0.987318	0.964533
DTW	0.838926	0.931796	0.846177
EnergyEnvRatio	0.734375	0.960316	0.725
EnergyPhase	0.848786	0.911529	0.900394
EnergyRatio	0.590473	0.803095	0.611559
EnergyRelativeDiff	0.590473	0.803095	0.611559
EnergyResidualNorm	0.74375	0.93926	0.746875
EnergyShared	0.510649	0.949697	0.605249
EnergySharedDiffNorm	0.654157	0.761104	0.780431
EnergySharedNorm	0.614108	0.829369	0.727336
EnergySignal	0.953883	0.991141	0.971117
EnergySignalSumSquareDiff	0.728914	0.934648	0.747148
L1Max	0.717081	0.916444	0.804854
L1MaxNomr	0.717081	0.916444	0.804854
L2	0.728914	0.934648	0.747148
SignalAmpHilbertMax	0.501942	0.560498	0.5402
SignalAmpPeakRatio	0.422512	0.475516	0.448786
SignalAmpPeakSquaredPercentDiff	0.469812	0.475516	0.452579
SignalDiffCoef	0.959951	0.988835	0.961833
SpatialPhase	0.954005	0.991141	0.970995
SpectrumLoss	0.5	0	0.5
SpectrumLossCentral	0.5	0	0.5

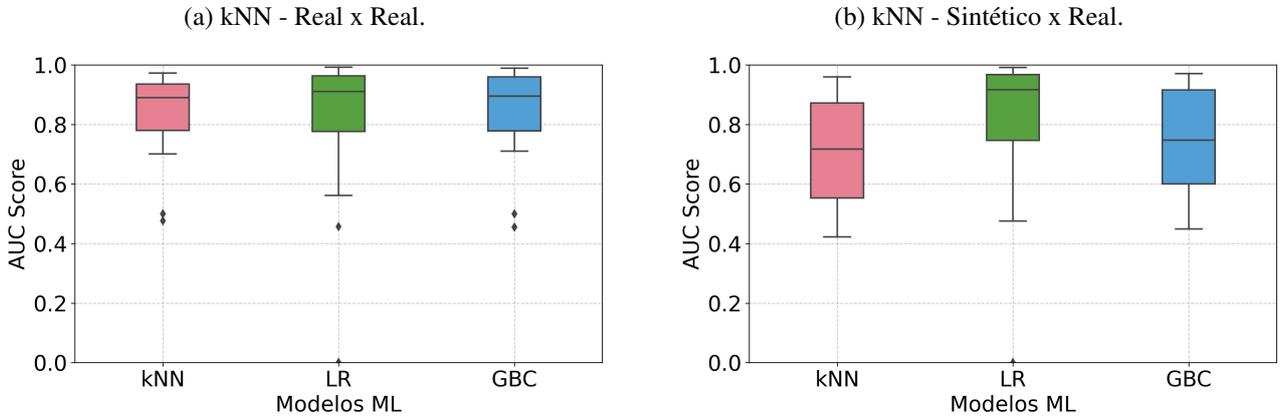
Fonte: Próprio Autor.

utilizando os dados reais.

Nota-se que o DI *Cross Correlation* apresentou um resultado excepcional de 0.99. Tal valor está acima do obtido pelo KP A3 conforme comparação entre Fig. 67 e Fig. 70. Para o DI *Energy Ratio*, pontuação foi de 0.8602 e 0.8031 usando dados reais e sintéticos, respectivamente, no treinamento. Um fator interessante, é o resultado do DI *Energy Shared Normalizada*, pois ele apresenta um certo nível de ruído, porém, após o ciclo da falha, próximo ao ciclo 190, ele demonstrou uma queda abaixo do nível de 0.5 da sua magnitude.

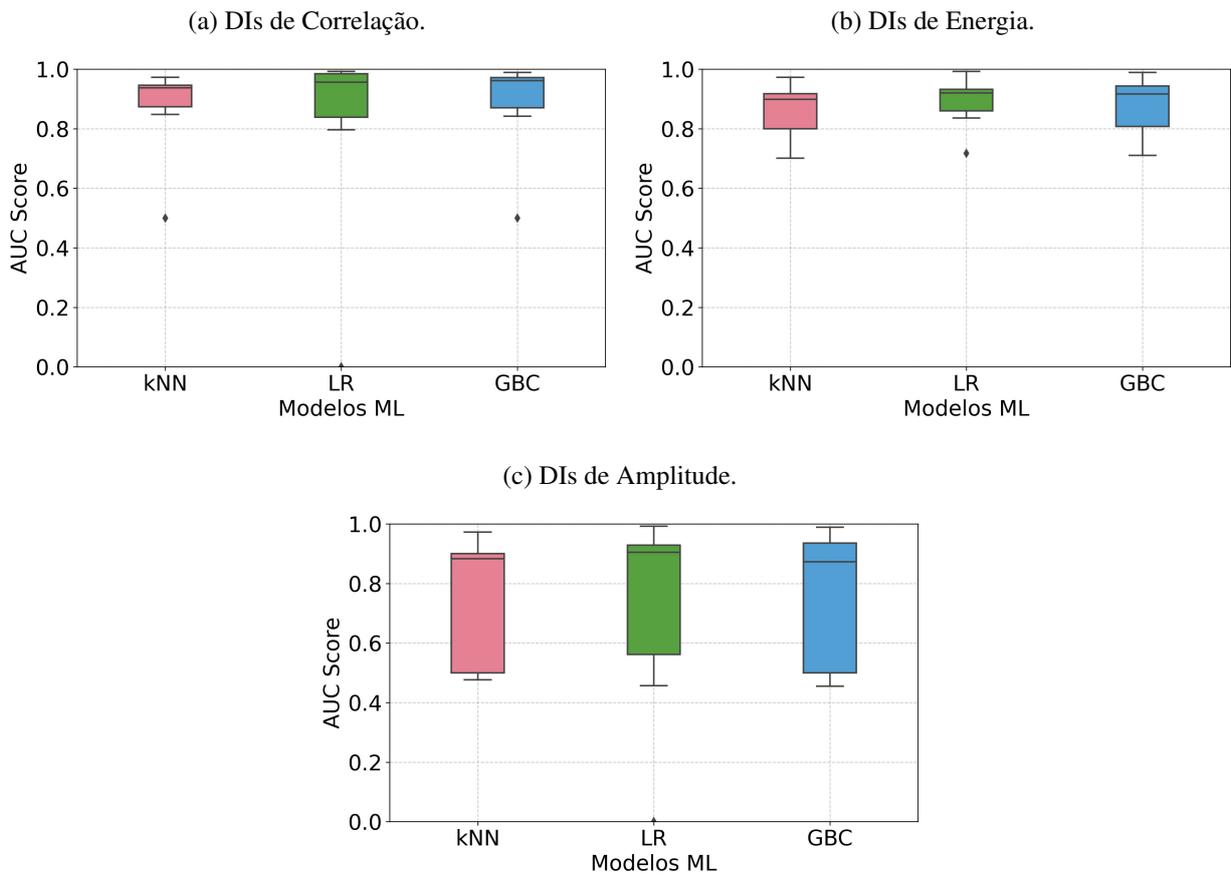
Isto indica que mesmo um DI que captura muito ruído sobre o funcionamento da válvula, ele consegue abstrair o comportamento de uma falha associada a degradação de sedes poliméricas.

Figura 68: Resultado da classificação usando os três algoritmos (kNN, LR e GBC). Cada *boxplot* representa a todos os 28 resultados dos DIs. O eixo y representa o *score* final mensurado pela curva ROC. Os dados de entrada utilizados foram os DIs



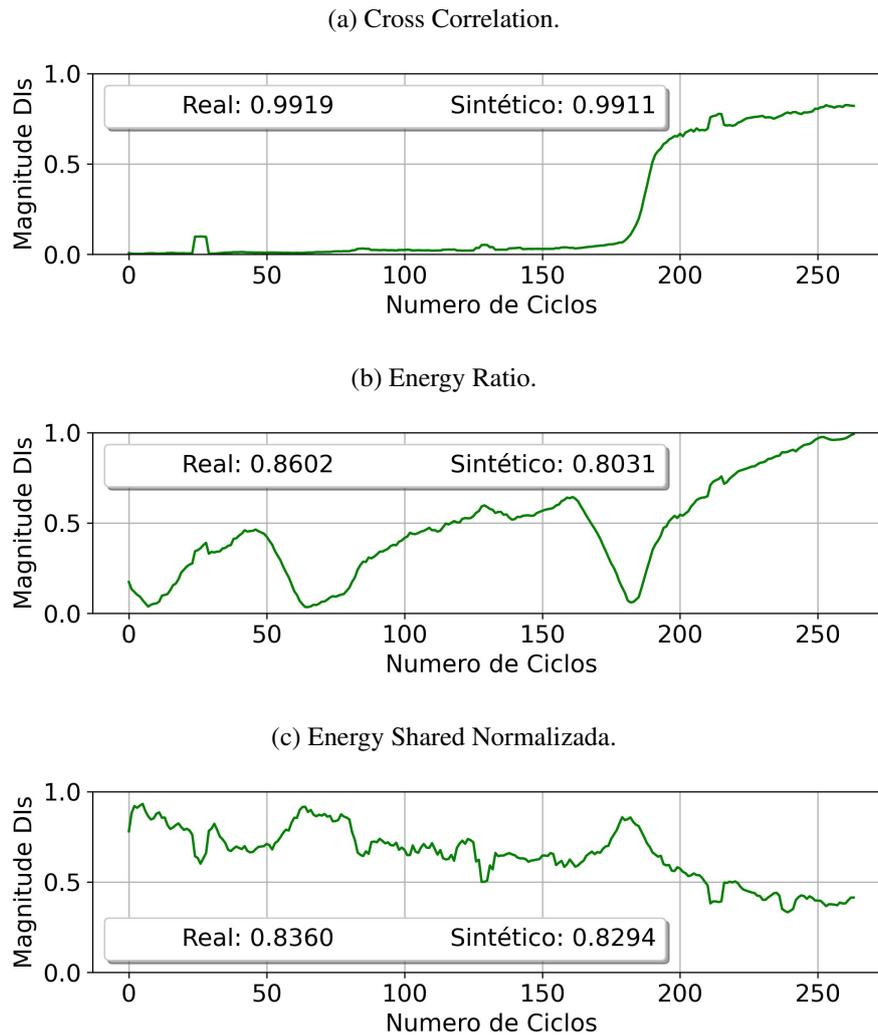
Fonte: Próprio Autor.

Figura 69: Um plot do tipo *boxplot* dos resultados separados das famílias de DIs.



Fonte: Próprio Autor.

Figura 70: Representação dos DIs de forma temporal (ciclos).



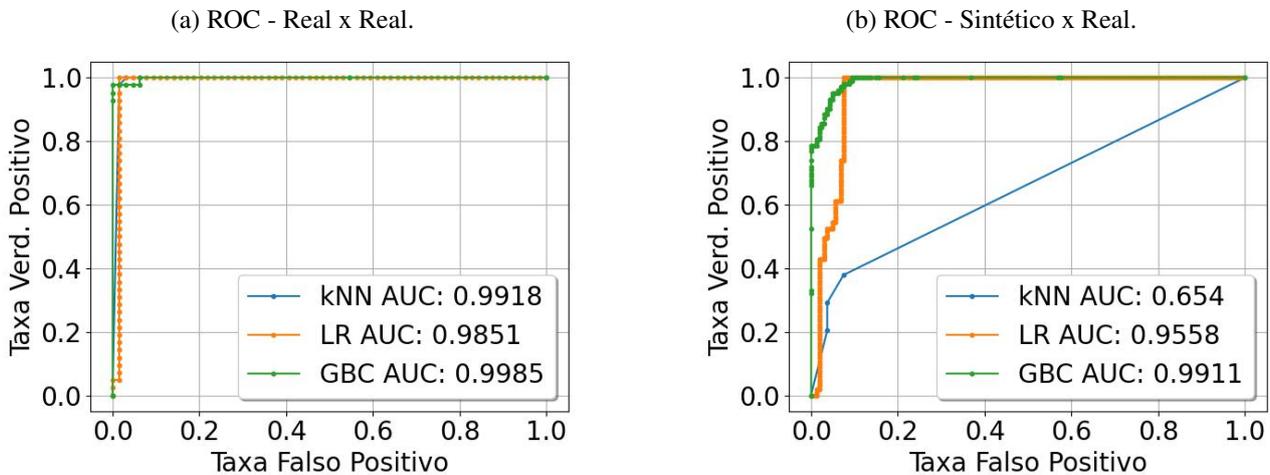
Fonte: Próprio Autor.

#### 4.2.4.3 Classificação pelas assinaturas de pressão

Para as classificações usando os dados reais para o treinamento, o algoritmo GBC, sem surpresas, apresentou a incrível pontuação *AUC Score* de 0.9985, conforme Fig. 82 mostra. O algoritmo kNN, assim como o GBC, também apresentou um excelente resultado, com *AUC Score* de 0.9918. Por fim, para o LR, apesar de ter obtido uma pontuação boa, ficou atrás do kNN e GBC, sendo sua pontuação de 0.9851. Passando para o treinamento com os dados sintéticos, originários do método de Monte Carlo, o GBC ainda obteve um incrível resultado de 0.9911.

Apresentando pouca sensibilidade aos dados sintéticos oriundos do método de Monte Carlo. Ao contrário do treino usando os dados reais, o kNN com dados sintéticos no treinamento, obteve uma piora significativa nos seus resultados, chegando com um *AUC Score* de 0.654. Já o LR, também apresentou uma queda, porém, em uma escala muito menor que o kNN, apresentando a pontuação final de 0.9558.

Figura 71: Resultado da classificação usando os três algoritmos, kNN, LR e GBC com dados provenientes da assinatura de pressão. A linha azul representa o kNN, a laranja LR e o GBC é representado pela linha verde. Os resultados são demonstrados através da curva ROC.



Fonte: Próprio Autor.

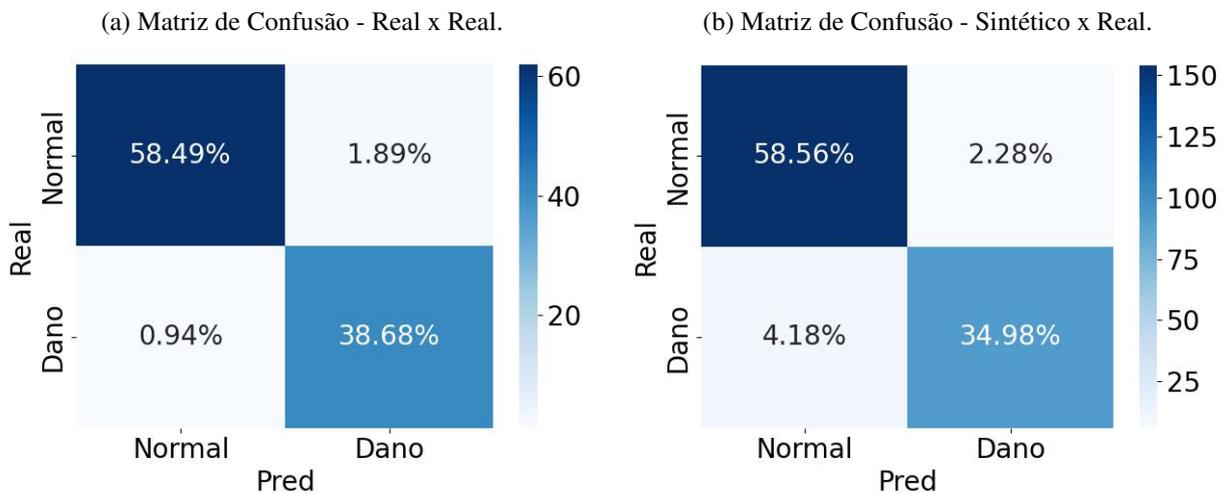
Estes resultados mostram que a assinatura de pressão carrega informações importantes na classificação de danos associados a uma válvula de bloqueio, principalmente com relação ao uso de dados reais. Para explorar um pouco mais estes resultados, uma matriz de confusão foi desenvolvida. A Fig. 82 mostra o resultado para o algoritmo GBC juntamente com as porcentagens de acerto entre as previsões Falso Positivo e Falso Negativo.

Para os eventos onde o GBC classificou como normal, sendo que a real condição da ESDV era dano, temos um total de 0.94% dos casos, sendo este o pior tipo de classificação como mostra a Fig. 72. Quando o *dataset* utilizado para o treinamento foram os dados sintéticos, houve uma ligeira queda na classificação percentual dos casos de Falso Positivos, com um percentual de 4.18% conforme Fig. 72 mostra.

Os Falsos Positivos são os piores tipos de previsão neste trabalho, pois, neste cenário, o algoritmo irá descrever o ciclo como normal, sendo que, na verdade, pode haver um dano que ocasionará, em medida mais extrema, uma explosão ou incêndio, visto que a ESDV perdeu sua capacidade de operar de forma segura, levando a perdas potenciais humanas, ambientais e financeiras. Por outro lado, quando o algoritmo GBC classifica um evento normal, como sendo de dano, haverá apenas as perdas financeiras, visto que a equipe de manutenção poderá se deslocar para realizar o reparo, porém, se deparando com uma válvula operando normalmente. Por esta razão, para uma válvula do tipo ESDV, entre os Falsos Positivos e Negativos, existe uma fronteira bem clara no momento de balancear o acerto do algoritmo para ser mais assertivo em uma ou outra direção.

Em resumo, mesmo diante da queda ao treinar o algoritmo com os dados sintéticos, o *Gradient Boosting Classification* apresentou um excelente resultado, extraíndo as informações das assinaturas sintéticas e correlacionando corretamente com o estado de degradação apresentado pela sede polimérica da válvula ESDV.

Figura 72: Matriz de Confusão dos resultados do algoritmo GBC utilizando assinaturas de pressão como entrada na classificação dos danos.



Fonte: Próprio Autor.

#### 4.2.5 Cálculo da vida útil remanescente - RUL

O cálculo do RUL será realizado pelos três algoritmos já estudados antes: kNN, LR e GB. Nesta etapa, visto que o estado da arte no cálculo do RUL, utiliza o algoritmo de Redes Neurais LSTM, será acrescentado este algoritmo de Redes Neurais na regressão da vida útil remanescente.

Os dados de entrada utilizados serão as assinaturas de pressão e o rótulo esperado será a curva *Piece-Wise*, conforme já explanado na Fig. 58.

O algoritmo kNN, usado no RUL, apresentou os resultados conforme disposto na Fig. 73. Onde o teste resultou em um *mean squared error* MSE de 0.00049 com grande adequação do real com o previsto antes do dano e uma sutil variação nos ciclos finais.

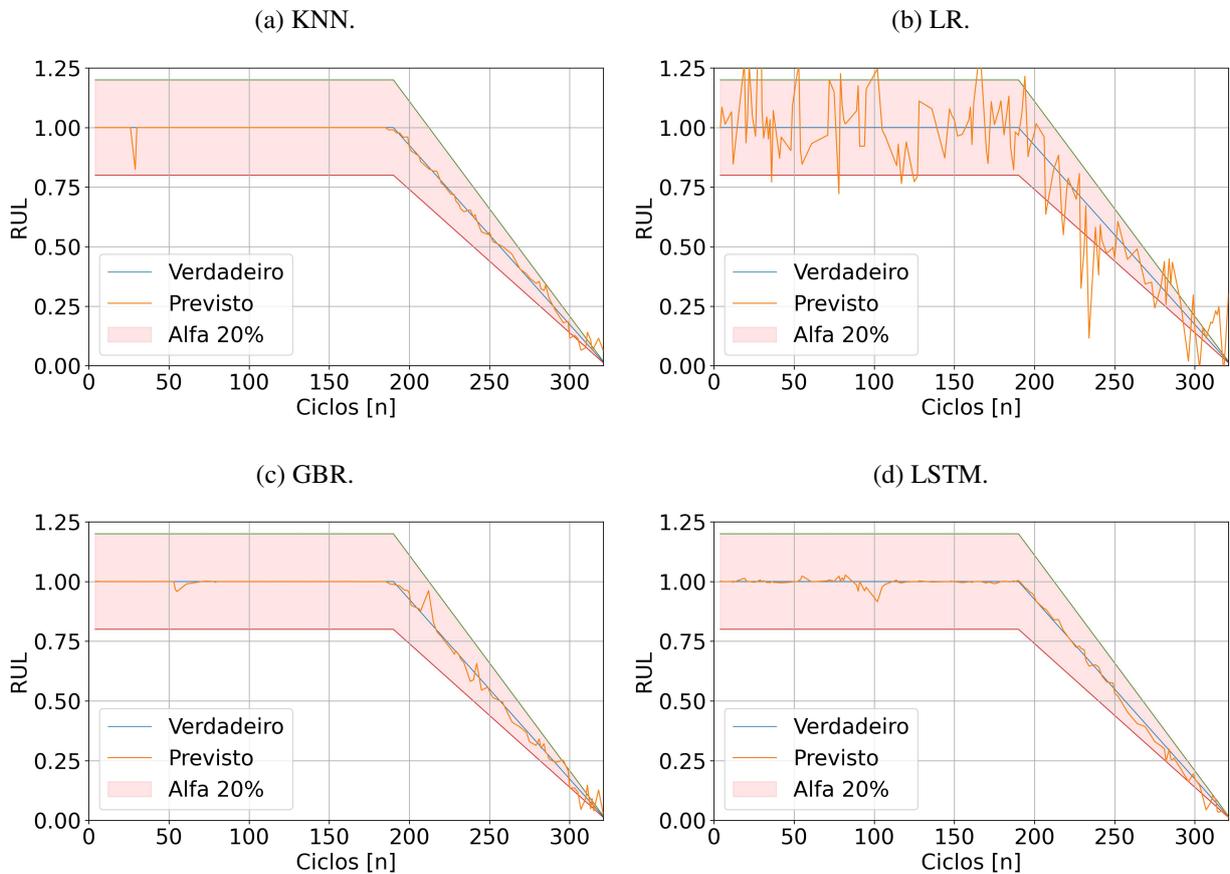
Para o LR, este obteve a pior pontuação, com 0.0233 de MSE, Fig. 73, com grande ruído antes e após o dano. Olhando agora para os resultados do algoritmo GBR, o MSE foi de 0.00046, Fig. 73, ligeiramente melhor que o kNN.

Até aqui, o *Gradient Boosting* se mantém com o melhor resultado se comparado com os outros dois algoritmos. Porém, frente ao algoritmo de *Long Short Term Memory*, o *Gradient Boosting Regressor* não conseguiu o melhor resultado.

O LSTM, conforme mostra a Fig. 73, apresentou um *mean squared error* de 0.00032, sendo este o melhor resultado dentre os algoritmos estudados para o cálculo do RUL. Isto se conforma ao que é observado no estado da arte aplicados aos problemas que envolvam o cálculo de vida útil remanescente, dado que vários trabalhos, de várias áreas do conhecimento, tem aplicado tal algoritmo para estimar a vida útil remanescente de componentes elétrico, turbinas e equipamentos industriais, como rolamentos.

Com as válvulas, o resultado não foi diferente, mostrando o potencial deste tipo de aplicação para auxiliar as equipes de manutenção a anteverem queda no desempenho das válvulas ESDV em campo.

Figura 73: Regressão do RUL para os algoritmos propostos. As entradas foram os sinais de assinatura e as saídas esperadas a Vida Remanescente da ESDV.



Fonte: Próprio Autor.

Analisando os erros residuais, de todos os algoritmos, é notório que o LR apresentou o pior resultado geral, com um  $MSE$  de 0.023, quase 50 vezes pior que o kNN. Na visão agrupada, kNN e GB apresentaram resultados residuais similares a rede neural, LSTM, conforme a Fig. 74 exemplifica.

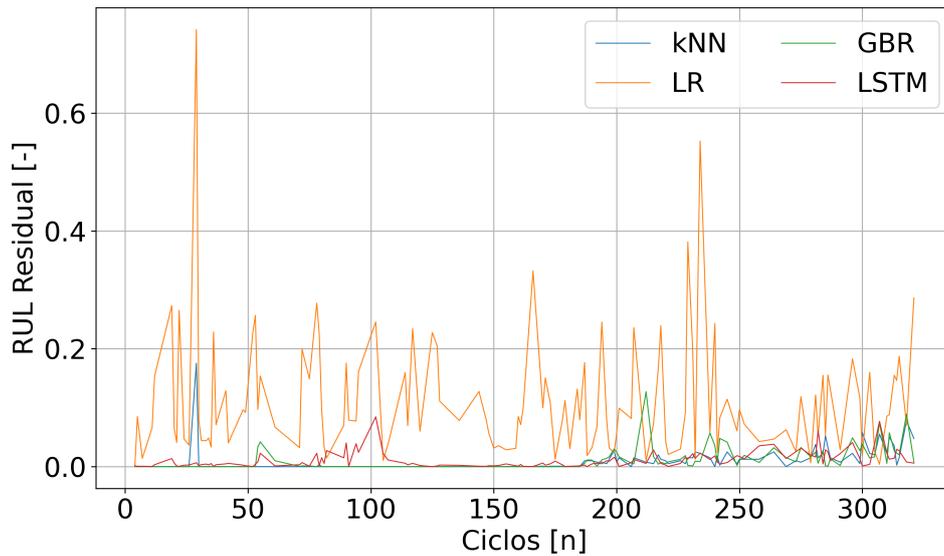
Na Fig. 75, são exibidos os últimos ciclos, do ciclo 180 até o ciclo 320 aproximadamente, visando proporcionar uma melhor compreensão da estimativa do RUL por cada algoritmo utilizado, juntamente com o algoritmo de redes neurais do tipo LSTM.

A linha preta representa a vida remanescente real da válvula, sendo está o alvo que os modelos devem buscar. O modelo de Regressão Linear (LR) apresentou o pior resultado na tentativa de calcular o RUL, apresentando grande ruído, antes e após o dano.

Isto evidencia que o LR não consegue extrair o comportamento não-linear deste tipo de problema, não lidando muito bem com dados de entradas com grandes dimensões, como a assinatura de pressão produz.

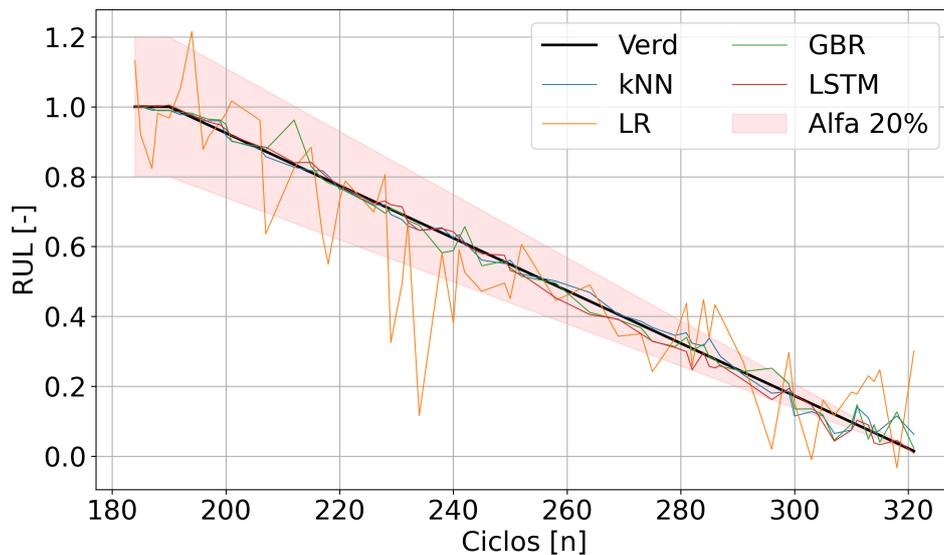
Por outro lado, o modelo de *Long Short Term Memory* (LSTM), representado pela linha azul, comportou-se de maneira muito próxima à curva real, alcançando o menor *Mean Squared Error* (MSE). No entanto, observa-se que ao usar o limite *alpha* igual a 20%, os ciclos finais ficaram fora

Figura 74: Erros residuais das previsões de RUL.



Fonte: Próprio Autor.

Figura 75: RUL nos eventos finais, onde a degradação da sede polimérica se inicia.



Fonte: Próprio Autor.

do intervalo de confiança.

Isto pode estar relacionado ao dano ser mais perceptível na assinatura de pressão, gerando mais ruído nestes eventos, uma vez que nestes ciclos, a degradação da sede polimérica em RPTFE só tende a piorar, isto é refletido nos sinais produzidos. Como consequência, a tentativa de calcular o RUL olhando as assinaturas de pressão, tende a ser dificultada pela degradação correndo. Esta é a causa de todos os modelos, apresentarem certa dificuldade de estimar o RUL na fase final.

## 5 CONCLUSÕES

O monitoramento da condição de uma válvula de bloqueio do tipo esfera foi realizado por 3 diferentes técnicas. As operações de abertura e fechamento de uma válvula implicou no desgaste e degradação da sede polimérica de RPTFE.

A deformação excessiva do material, principalmente na região denominada de *crack-open*, corrobora a ideia que este ponto da sede merece uma atenção especial dos engenheiros e projetista no desenvolvimento de tais equipamentos. Por outro lado, a sede ao lado jusante, não sofreu degradações significativas durante os testes.

O uso de alternativas aos métodos de monitoramento atuais de uma ESDV, apresentou excelentes resultados conforme puderam ser acompanhadas neste trabalho. A assinatura de pressão como entrada para os algoritmos de classificação, é a melhor metodologia, seguida dos DIs e por fim, os KPs.

O potencial do uso dos *Damage Index* (DIs) para extrair o comportamento da válvula de bloqueio através da assinatura de pressão, retornou excelentes resultados. Como o cálculo dos DIs se dá por uma fórmula matemática, sua vantagem frente ao método convencional, os KPs, se torna muito atrativo e deve ser investigado e associado a outros tipos de defeitos para se confirmar a adequação dos resultados. Como a família dos DIs são três principais, correlação de sinal, energia e amplitude, ao aplicar os 28 DIs, é possível que extraímos mais informações que os KPs, técnica convencional, não foi capaz de extrair.

Dentre todas as técnicas avaliadas, o KP, além de necessitar de um operador altamente treinado para localizar e marcar os KPs na assinatura, apresentou os menores resultados durante a fase de classificação de dano. Porém, no caso da continuidade de monitoramento de uma ESDV pelos métodos dos KPs, este trabalho também contribuiu e mostrou ser possível treinar algoritmos de aprendizado de máquina para automatizar a localização dos KPs nas assinaturas, sendo que o *Gradient Boosting Regressor* apresentou um *AUC Score* excelente de 0.999. Mesmo o kNN, apresentou um ótimo resultado na regressão dos KPs, com um *AUC Score* final de 0.997.

O uso do método de Monte Carlo, baseado no primeiro e segundo momento estatístico, para se extrair as características do conjunto de dados, se mostrou robusto e uma solução de fácil implementação. Aliado a isto, a suavização com a janela móvel e a definição de um limiar de corte, auxiliou ao determinar quais assinaturas sintéticas estariam mais associadas aos sinais reais. Isto se prova, analisando alguns dos resultados com treinamento utilizando estes dados oriundos do Monte Carlos, as chamadas, assinaturas sintéticas. Como, por exemplo, na classificação utilizando as assinaturas sintéticas como entrada, o algoritmo *Gradient Boosting Classifier*, retornou um acerto de 0.9911 segundo o *AUC Score* resultante da curva ROC.

Isto prova que os dados sintéticos, carregam informação o suficiente para serem utilizadas para se treinar um modelo de classificação de danos de uma ESDV.

Com respeito ao cálculo da vida útil remanescente (*Remaining Useful Life-RUL*), também foi

abordada nesta tese. Logo, o resultado, usando os algoritmos kNN e GBR, se mostraram promissores para o cálculo do RUL, com um *Mean Squared Error* de 0.00049 e 0.00046 respectivamente. A fim de acompanhar o estado da arte no monitoramento e cálculo do RUL, nesta etapa o algoritmo *Long Short Term Memory* (LSMT) foi introduzido, o que apresentou um valor de MSE final de 0.00032, sendo este o melhor algoritmo para prever a vida útil remanescente.

Isto se adéqua ao poder de processamento das Redes Neurais, visto que, as camadas ocultas, possuem um poder maior de lidar com problemas não-lineares, como os sinais de uma válvula de bloqueio durante sua degradação.

Na maioria das análises, o *Gradiente Boosting* se mostrou o melhor algoritmo para regressão e classificação de danos em válvulas de bloqueio. A única exceção se deu no momento de calcular o RUL, onde o algoritmo de Redes Neurais, LSTM, se adequou melhor aos dados de entrada e performou um resultado melhor.

Por fim, esta tese conclui que o uso potencial de algoritmos de processamento de sinais, do campo de *Machine Learning*, pode ser aplicado aos sinais de uma válvula de bloqueio durante testes cíclicos, embora limitados pelo banco de dados.

A criação de sinais sintéticos para treinar algoritmos de monitoramento abordados nesta tese, é totalmente viável, resultando em resultados excelentes. Além disto, indicamos o uso de DIs como um potencial substituto aos convencionais KPs, sendo que os DIs consideram a totalidade do sinal para gerar o valor escalar que irá representá-la, diferentemente dos KPs que já estão pré-definidos e podem deixar passar informações importantes sobre o estado de saúde da ESDV, caso o dano ocorra em regiões intermediárias da assinatura, como no percentual entre 30% e 80%.

Também, destacamos que as assinaturas carregam informações relevantes aos danos ocorridos em válvulas de bloqueio, sendo as melhores entradas para os algoritmos quando no campo da classificação de danos, se restringindo os danos de sedes avaliadas nesta presente tese, sendo que para maiores conclusões, indica-se sua aplicação em outros modos de falhas em válvulas.

Além disto, o uso de algoritmos de redes neurais, como o LSTM, deve ser mais explorado no monitoramento de válvulas ESDVs que se degradam com o passar da operação a fim de se obter a curva que resuma a condição da sua vida remanescente.

## 6 SUGESTÕES PARA TRABALHOS FUTUROS

Como sugestões para trabalhos futuros, novos estudos podem ser realizados para aperfeiçoar o método desenvolvido:

- Obter sinais de válvulas de bloqueio em campo e analisar as propostas desta tese;
- Ampliar o banco de dados para a implementação de soluções puramente *Machine Learning*;
- Gerar dados provenientes de modelos matemáticos (*Digital Twin*) para treinar uma válvula real;
- Comparar válvula esfera com a válvula gaveta (com atuação hidráulica) na utilização dos algoritmos propostos nesta tese;
- Comparar a degradação de uma válvula de bloqueio com sedes poliméricas contra uma de sedes metálicas - *onshore vs offshore*;
- Estudar a diferença em degradação de uma válvula com sedes DPE e SPE nos sinais;
- Explorar o uso de algoritmos de séries temporais para previsão de sinais futuros, tais como algoritmos de ARIMA e NARX;
- Avaliar se o PCA pode ser utilizado para gerar sinais sintéticos;
- Comparar LSTM com GRU e CNN na previsão da Vida Útil Remanescente (RUL);
- Estimar a Vida Útil Remanescente (RUL) por métodos estocásticos, utilizando Movimentos *Brownianos*;

## REFERÊNCIAS

ABNT NBR 15827. Válvulas industriais para instalações de exploração, produção, refino e transporte de produtos de petróleo - requisitos de projeto e ensaio de protótipo. Standard, Associação Brasileira de Normas Técnicas, Rio de Janeiro, RJ, 2022.

S Agatonovic-Kustrin and Rosemary Beresford. Basic concepts of artificial neural network (ann) modeling and its application in pharmaceutical research. *Journal of pharmaceutical and biomedical analysis*, 22(5):717–727, 2000.

Farzaneh Ahmadzadeh and Jan Lundberg. Remaining useful life estimation. *International Journal of System Assurance Engineering and Management*, 5:461–474, 2014.

AnalyticsVidhya. Pca | what is principal component analysis how it works? (updated 2023), 2016. URL <https://www.analyticsvidhya.com/blog/2016/03/pca-practical-guide-principal-component-analysis-python/>. Disponível em: < <https://www.analyticsvidhya.com/blog/2016/03/pca-practical-guide-principal-component-analysis-python/> >. Acesso em: 14 Julho de 2023.

Santosh V Angadi and Robert L Jackson. A critical review on the solenoid valve reliability, performance and remaining useful life including its industrial applications. *Engineering Failure Analysis*, 136:106231, 2022.

API 6D. Specification for pipeline valves. Standard, American Petroleum Institute, Washigton, WA, 2022.

API 6DX. Standard for actuator sizing and mounting kits for pipeline valves. Standard, American Petroleum Institute, Washigton, WA, 2023.

Vigen Arakelian, Jean-Paul Le Baron, and Manuk Mkrtchyan. Design of scotch yoke mechanisms with improved driving dynamics. *Proceedings of the Institution of Mechanical Engineers, Part K: Journal of Multi-body Dynamics*, 230(4):379–386, 2016.

Facundo Baltazar Argüello. Estudo numérico e experimental de assinaturas de torque de acionamento em válvulas de esfera industriais-predição de condições de operação eavaliação de falhas em serviço. Master's thesis, UFRGS, Rio Grande do Sul, RS, Brasil, 2018.

Taimoor Asim, Rakesh Mishra, Antonio Oliveira, and Matthew Charlton. Effects of the geometrical features of flow paths on the flow capacity of a control valve trim. *Journal of petroleum science and engineering*, 172:124–138, 2019.

ASME B16.34. Valves - flanged, threaded and welding end. Standard, American Society of Mechanical Engineers, New York, NY, 2020.

M Atif Qureshi, Luis Miralles-Pechuán, Jing Su, Jason Payne, and Ronan O'Malley. Vhi: Valve health identification for the maintenance of subsea industrial equipment. In *Joint European Conference on Machine Learning and Knowledge Discovery in Databases*, pages 668–671. Springer, 2018.

Shaeela Ayesha, Muhammad Kashif Hanif, and Ramzan Talib. Overview and comparative study of dimensionality reduction techniques for high dimensional data. *Information Fusion*, 59:44–58, 2020.

Yong Bai and Qiang Bai. *Subsea engineering handbook*. Gulf Professional Publishing, 2018.

MC Ben Jemaa, R Mnif, K Fehri, and R Elleuch. Design of a new tribometer for tribological and viscoelasticity studies of ptfе valve seats. *Tribology Letters*, 45:177–184, 2012.

A. Bencomo. Applications of condition monitoring for the subsea industry. Master's thesis, University of Stavanger, Stavanger, Norway, 2012.

M Bergonzoni, A Campagnolo, D Pellinghelli, M Riboli, A Spagnoli, and G Meneghetti. Experimental tests and fatigue strength assessment of a scotch yoke valve actuator. *Procedia engineering*, 213:58–68, 2018a.

Matteo Bergonzoni, A Campagnolo, D Pellinghelli, M Riboli, A Spagnoli, and G Meneghetti. Experimental tests and fatigue strength assessment of a scotch yoke valve actuator. *Procedia engineering*, 213:58–68, 2018b.

Baoping Cai, Hongyan Fan, Xiaoyan Shao, Yonghong Liu, Guijie Liu, Zengkai Liu, and Renjie Ji. Remaining useful life re-prediction methodology based on wiener process: Subsea christmas tree system as a case study. *Computers & Industrial Engineering*, 151:106983, 2021.

Mikel Canizo, Isaac Triguero, Angel Conde, and Enrique Onieva. Multi-head cnn–rnn for multi-time series anomaly detection: An industrial case study. *Neurocomputing*, 363:246–260, 2019.

Benedito de Almeida Carvalho. Um estudo sobre a variabilidade do desempenho de válvulas submarinas. Master's thesis, UFRJ, Rio de Janeiro, RJ, Brasil, 2007.

Chris Chatfield. *Time-series forecasting*. CRC press, 2000.

Hailang Chen and Xianfa Chang. Photovoltaic power prediction of lstm model based on pearson feature selection. *Energy Reports*, 7:1047–1054, 2021.

Davide Chicco, Matthijs J Warrens, and Giuseppe Jurman. The coefficient of determination r-squared is more informative than smape, mae, mape, mse and rmse in regression analysis evaluation. *Peerj computer science*, 7:e623, 2021.

Wikimedia Commons. File:normal distribution sigma.svg. URL [https://commons.wikimedia.org/wiki/File:Normal\\_Distribution\\_Sigma.svg](https://commons.wikimedia.org/wiki/File:Normal_Distribution_Sigma.svg). Disponível em: < [https://commons.wikimedia.org/wiki/File:Normal\\_Distribution\\_Sigma.svg](https://commons.wikimedia.org/wiki/File:Normal_Distribution_Sigma.svg) >. Acesso em: 12 Abril de 2024.

Baoling Cui, Zhe Lin, Zuchao Zhu, Huijie Wang, and Guangfei Ma. Influence of opening and closing process of ball valve on external performance and internal flow characteristics. *Experimental Thermal and Fluid Science*, 80:193–202, 2017.

L WD Cullen. The public inquiry into the piper alpha disaster. *Drilling Contractor;(United States)*, 49(4), 1993.

ABRACD Associação Brasileira de Ciências de Dados. Overfitting e underfitting em machine learning, 2020. URL <https://abracd.org/overfitting-e-underfitting-em-machine-learning/>. Disponível em: < <https://abracd.org/overfitting-e-underfitting-em-machine-learning/> >. Acesso em: 14 Julho de 2023.

SM de Gouveia, L de Abreu Corrêa, DB Teles, M Oliveira, and TGR Clarke. Emergency shutdown valve damage classification by machine learning using synthetic data. *Engineering Failure Analysis*, 156:107819, 2024.

Shaojiang Dong, Jiafeng Xiao, Xiaolin Hu, Nengwei Fang, Lanhui Liu, and Jinbao Yao. Deep transfer learning based on bi-lstm and attention for remaining useful life prediction of rolling bearing. *Reliability Engineering & System Safety*, 230:108914, 2023.

Edureka! Ai vs machine learning vs deep learning, 2024. URL <https://www.edureka.co/blog/ai-vs-machine-learning-vs-deep-learning/>. Disponível em: < <https://www.edureka.co/blog/ai-vs-machine-learning-vs-deep-learning/> >. Acesso em: 14 Julho de 2023.

Issam El Naqa and Martin J Murphy. *What is machine learning?* Springer, 2015.

Ahmed Elsheikh, Soumaya Yacout, and Mohamed-Salah Ouali. Bidirectional handshaking lstm for remaining useful life prediction. *Neurocomputing*, 323:148–156, 2019.

Offshore Energy. Petrobras poised to become world’s largest oil producer by 2030, 2023. URL <https://www.offshore-energy.biz/petrobras-poised-to-become-worlds-largest-oil-producer-by-2030-rystad-says/>. Disponível em: <https://www.offshore-energy.biz/petrobras-poised-to-become-worlds-largest-oil-producer-by-2030-rystad-says/>. Acesso em: 14 Julho de 2023.

Gunnar Eriksen, JO Bondevik, and Bernt Bergum. First emergency shutdown valve, norwegian sector. In *Offshore Technology Conference*, pages OTC–6917. OTC, 1992.

EJ Euthymiou. One company’s experience in subsea valve testing. In *Offshore Technology Conference*, pages OTC–14005. OTC, 2002.

Euthymios José Euthymíou. *Metodologia para modelagem da evolução da probabilidade de falha, decorrente da degradação funcional de válvulas*. PhD thesis, UFRJ, Rio de Janeiro, RJ, Brasil, 2013.

Euthymios José Euthymíou. *Metodologia para testes funcionais em válvulas submarinas*. Master’s thesis, UFRJ, Rio de Janeiro, RJ, Brasil, 2001.

Edberto Ferneda. Redes neurais e sua aplicação em sistemas de recuperação de informação. *Ciência da Informação*, 35:25–30, 2006.

Carlos Ferreira and Gil Gonçalves. Remaining useful life prediction and challenges: A literature review on the use of machine learning methods. *Journal of Manufacturing Systems*, 63:550–562, 2022.

D. Gasparetto. Projeto e validação de válvula industrial do tipo esfera com revestimento anticorrosivo orgânico interno. Master's thesis, UFRGS, Porto Alegre, RS, Brasil, 2014.

G e Gokilakrishnan, S Divya, R Rajesh, and V Selvakumar. Operating torque in ball valves: a review. *Int J Technol Res Eng*, 2(4):311–315, 2014.

Ian Goodfellow, Yoshua Bengio, and Aaron Courville. *Deep learning*. MIT press, 2016.

S. M. de Gouveia. Estudo sobre a assinatura de pressão (atuação hidráulica) de uma esdv através de um modelo matemático. Master's thesis, Universidade Federal do Rio Grande do Sul, Rio Grande do Sul., 2018.

Stephen Grossberg. Nonlinear neural networks: Principles, mechanisms, and architectures. *Neural networks*, 1(1):17–61, 1988.

James D Hamilton. *Time series analysis*. Princeton university press, 2020.

James V Hansen, James B McDonald, and Ray D Nelson. Time series prediction with genetic-algorithm designed neural networks: An empirical comparison with modern statistical models. *Computational Intelligence*, 15(3):171–184, 1999.

Jiangang Hao and Tin Kam Ho. Machine learning made easy: a review of scikit-learn package in python programming language. *Journal of Educational and Behavioral Statistics*, 44(3):348–361, 2019.

HartEnergy. All-electric subsea production system remains a work in progress. URL <https://www.hartenergy.com/exclusives/all-electric-subsea-production-system-remains-work-progress-29860>. Disponível em: < <https://www.hartenergy.com/exclusives/all-electric-subsea-production-system-remains-work-progress-29860> >. Acesso em: 17 Julho de 2023.

Simon Haykin. *Redes neurais: princípios e prática*. Bookman Editora, 2001.

Nick Hayward and Marta Portugal. Machine learning image analysis for asset inspection. In *SPE Offshore Europe Conference and Exhibition*, 09 2019. doi: 10.2118/195773-MS.

InstrumentationTools. What is shutdown valve? URL <https://instrumentationtools.com/shutdown-valve/>. Disponível em: < <https://instrumentationtools.com/shutdown-valve/> >. Acesso em: 29 Junho de 2022.

ISO 17292. Metal ball valves for petroleum, petrochemical and allied industries. Standard, International Organization for Standardization, Geneva, Switzerland, 2024.

B Kamaruddin, H Zabiri, AAA Mohd Amiruddin, WK Teh, M Ramasamy, and SS Jeremiah. A simple model-free butterfly shape-based detection (bsd) method integrated with deep learning cnn for valve stiction detection and quantification. *Journal of Process Control*, 87:1–16, 2020.

Ibrahim Kandel and Mauro Castelli. Transfer learning with convolutional neural networks for diabetic retinopathy image classification. a review. *Applied Sciences*, 10(6):2021, 2020.

DT Kemp, P Bray, L Alexander, and AM Brown. Acoustic emission cochleography—practical aspects. *Scandinavian audiology. Supplementum*, 25:71–95, 1986.

Jaydeep Khedkar, Ioan Negulescu, and Efstathios I Meletis. Sliding wear behavior of ptfе composites. *Wear*, 252(5-6):361–369, 2002.

Chia-Yen Lee and Zhao-Hong Dong. Hierarchical equipment health index framework. *IEEE Transactions on Semiconductor Manufacturing*, 32(3):267–276, 2019.

John A Lee, Michel Verleysen, et al. *Nonlinear dimensionality reduction*, volume 1. Springer, 2007.

Joon-Hyun Lee, Min-Rae Lee, Jung-Teak Kim, Vincent Luk, and Yoong-Ho Jung. A study of the characteristics of the acoustic emission signals for condition monitoring of check valves in nuclear power plants. *Nuclear Engineering and Design*, 236(13):1411–1421, 2006.

Tali Leibovich-Raveh, Daniel Jacob Lewis, Saja Al-Rubaiey Kadhim, and Daniel Ansari. A new method for calculating individual subitizing ranges. *Journal of Numerical Cognition*, 4(2):429–447, 2018.

Dario Leon, Sebastian Imle, and Markus Glaser. Wear-optimized partial stroke test for all-electric actuation systems. *Gas Science and Engineering*, 111:204875, 2023.

Guijie Liu, Yunqing Chen, Xiulong Zhang, Weixiong Jiang, Yingchun Xie, Xiaojie Tian, Dingxin Leng, and Zhixiong Li. A deep residual shrinkage network based on multi-scale attention module for subsea christmas tree valve leakage detection. *Measurement*, 198:110970, 2022.

Mingyang Liu, Xianming Lang, Shuaiyong Li, Lincan Deng, Bo Peng, Yipeng Wu, and Xiao Zhou. Improved machine learning leak fault recognition for low-pressure natural gas valve. *Process Safety and Environmental Protection*, 178:947–958, 2023.

Ziming Liu, Yixuan Wang, Sachin Vaidya, Fabian Ruehle, James Halverson, Marin Soljačić, Thomas Y Hou, and Max Tegmark. Kan: Kolmogorov-arnold networks. *arXiv preprint arXiv:2404.19756*, 2024.

- E. Lizé. *Détection d'endommagement sans état de référence et estimation de la température pour le contrôle santé intégré de structures composites par ondes guidées*. PhD thesis, Paris, ENSAM, 2018.
- Panagiotis Loukopoulos, George Zolkiewski, Ian Bennett, Suresh Sampath, Pericles Pilidis, X Li, and David Mba. Abrupt fault remaining useful life estimation using measurements from a reciprocating compressor valve failure. *Mechanical Systems and Signal Processing*, 121:359–372, 2019.
- Amalia Luque, Alejandro Carrasco, Alejandro Martín, and Ana de Las Heras. The impact of class imbalance in classification performance metrics based on the binary confusion matrix. *Pattern Recognition*, 91:216–231, 2019.
- Francois PS Luus, Brian P Salmon, Frans Van den Bergh, and Bodhaswar Tikanath Jugpershad Maharaj. Multiview deep learning for land-use classification. *IEEE Geoscience and Remote Sensing Letters*, 12(12):2448–2452, 2015.
- Meng Ma and Zhu Mao. Deep-convolution-based lstm network for remaining useful life prediction. *IEEE Transactions on Industrial Informatics*, 17(3):1658–1667, 2020.
- Batta Mahesh. Machine learning algorithms-a review. *International Journal of Science and Research (IJSR).[Internet]*, 9(1):381–386, 2020.
- H Mahgerefteh, P Saha, and IG Economou. A study of the dynamic response of emergency shutdown valves following full bore rupture of gas pipelines. *Process safety and environmental protection*, 75(4):201–209, 1997.
- M Mahmoodi and M Gorji Bandpy. The experimental study of effective characteristics on differential pressure value setting of quarter-turn actuator in gas transportation pipelines. *Amirkabir J. Mech. Eng*, 50(4):837–848, 2018.
- M. H. S. Mashiba. *A Influência dos Parâmetros de Operação e Projeto no Desempenho de Atuação Hidráulica de Válvulas Submarinas do Tipo Gaveta*. PhD thesis, Dissertação de Mestrado, Universidade Federal do Rio de Janeiro, Rio de . . . , 2011.
- Artur Cardozo Mathias. *Válvulas*-. São Paulo: Artliber, 2014.
- James R Matthews. *Acoustic emission*, volume 2. CRC Press, 1983.
- Dastan Maulud and Adnan M Abdulazeez. A review on linear regression comprehensive in machine learning. *Journal of Applied Science and Technology Trends*, 1(4):140–147, 2020.
- Hugh McIntyre. Review of subsea isolation valves installations in the uk north sea. *SUBTECH'91: Back to the Future*, pages 97–104, 1991.
- A. L. Mesquita. Previsão e detecção de falhas em capacitores eletrolíticos. Master's thesis, Universidade Federal do Ceara, Ceara, CE, Brasil, 2021.

Micromazza. Limites operacionais de pressão e temperatura para sedes, 2023. URL <https://micromazza.com.br/arquivos/produtos/d8xqvbrl6u0yg.pdf>. Disponível em: < <https://micromazza.com.br/arquivos/produtos/d8xqvbrl6u0yg.pdf> >. Acesso em: 19 Julho de 2023.

Stefan Mihai, Mahnoor Yaqoob, Dang V Hung, William Davis, Praveer Towakel, Mohsin Raza, Mehmet Karamanoglu, Balbir Barn, Dattaprasad Shetve, Raja V Prasad, et al. Digital twins: A survey on enabling technologies, challenges, trends and future prospects. *IEEE Communications Surveys & Tutorials*, 24(4):2255–2291, 2022.

Manish Mishra and Monika Srivastava. A view of artificial neural network. In *2014 international conference on advances in engineering & technology research (ICAETR-2014)*, pages 1–3. IEEE, 2014.

Ridha Mnif, Mourad Chokri Ben Jemaa, and Riadh Elleuch. Tribological failure analysis of ball valve seals. *International Journal of Microstructure and Materials Properties*, 8(4-5):385–396, 2013.

Songlin Nie, Qingtong Liu, Hui Ji, Ruidong Hong, and Shuang Nie. Integration of arima and lstm models for remaining useful life prediction of a water hydraulic high-speed on/off valve. *Applied Sciences*, 12(16):8071, 2022.

Alexandre Orth, Gottfried Hendrix, Markus Kubacki, Pedro Joao Duarte da Silva, and Juliano Victor De Negri. A novel subsea actuator to electrify small-bore valve. In *Offshore Technology Conference*, page D041S046R005. OTC, 2021.

L Ouchet. Reliability modelling of subsea gate valves. 1993.

André Pacheco. O modelo de predição linear, 2021. URL <https://computacaointeligente.com.br/algoritmos/modelo-de-predicao-linear/>. Disponível em: < <https://computacaointeligente.com.br/algoritmos/modelo-de-predicao-linear/> >. Acesso em: 23 Abril de 2024.

Seong Ho Park, Jin Mo Goo, and Chan-Hee Jo. Receiver operating characteristic (roc) curve: practical review for radiologists. *Korean journal of radiology*, 5(1):11, 2004.

M Elisabeth Paté-Cornell. Learning from the piper alpha accident: A postmortem analysis of technical and organizational factors. *Risk analysis*, 13(2):215–232, 1993.

John Peters. Assessment of valve failures in the offshore oil and gas sector. Glasgow, UK, 2003.

Eliane Petersohn. Pre-salt super play: leading brazil into the world's top 5 oil suppliers. In *AAPG Latin America and Caribbean Region Geoscience Technology Workshop*, volume 30625, 2019.

Piping-World. Dbb or dib pipeline ball valve for scraper trap isolation, 2023. URL <https://www.piping-world.com/dbb-or-dib-pipeline-ball-valve-for-scraper-trap-isolation>. Disponível em: . Acesso em: 12 Julho de 2023.

Ashok Prajapati, James Bechtel, and Subramaniam Ganesan. Condition based maintenance: a survey. *Journal of Quality in Maintenance Engineering*, 18(4):384–400, 2012.

JVS Praveen, Mehboob Pathan, and Khalid Ansari. Hyperbaric pressure testing of a subsea valve to validate deep water condition. *International Journal of Mechanical and Production Engineering Research and Development (IJMPERD) ISSN (P)*, pages 2249–6890, 2018.

Programaria. Inteligência artificial: tudo que você precisa saber para começar a explorar esse universo, 2020. URL <https://www.programaria.org/inteligencia-artificial-tudo-que-voce-precisa-saber-para-comecar-a-explorar-esse-universo/>. Disponível em: < <https://www.programaria.org/inteligencia-artificial-tudo-que-voce-precisa-saber-para-comecar-a-explorar-esse-universo/> >. Acesso em: 23 Abril de 2024.

Luca Pugi, Emanuele Galardi, Giovanni Pallini, Libero Paolucci, and Nicola Lucchesi. Design and testing of a pulley and cable actuator for large ball valves. *Proceedings of the Institution of Mechanical Engineers, Part I: Journal of Systems and Control Engineering*, 230(7):622–639, 2016.

Yao Qin, Dongjin Song, Haifeng Chen, Wei Cheng, Guofei Jiang, and Garrison Cottrell. A dual-stage attention-based recurrent neural network for time series prediction. *arXiv preprint arXiv:1704.02971*, 2017.

Prajit Ramachandran, Barret Zoph, and Quoc V Le. Searching for activation functions. *arXiv preprint arXiv:1710.05941*, 2017a.

Prajit Ramachandran, Barret Zoph, and Quoc V Le. Searching for activation functions. *arXiv preprint arXiv:1710.05941*, 2017b.

Susmita Ray. A quick review of machine learning algorithms. In *2019 International conference on machine learning, big data, cloud and parallel computing (COMITCon)*, pages 35–39. IEEE, 2019.

Mayra Z Rodriguez, Cesar H Comin, Dalcimar Casanova, Odemir M Bruno, Diego R Amancio, Luciano da F Costa, and Francisco A Rodrigues. Clustering algorithms: A comparative approach. *PloS one*, 14(1):e0210236, 2019.

J. Roell. From fiction to reality: A beginner’s guide to artificial neural networks, 2017. URL <https://towardsdatascience.com/from-fiction-to-reality-a-beginners-guide-to-artificial-neural-networks-d0411777571b>. Disponível em: < <https://towardsdatascience.com/from-fiction-to-reality-a-beginners-guide-to-artificial-neural-networks-d0411777571b> >. Acesso em: 17 Julho de 2023.

Grzegorz Romanik, Przemysław Jaszak, and Janusz Rogula. Cooperation of the ptfe sealing ring with the steel ball of the valve subjected to durability test. *Open Engineering*, 9(1):321–328, 2019.

Frank Rosenblatt. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, 65(6):386, 1958.

- Diego Rizzotto Rossetto. *Avaliação da integridade estrutural de projetos de válvulas do tipo esfera trunnion e/ou gaveta utilizadas nas instalações de petróleo*. PhD thesis, UFRGS, Porto Alegre, RS, Brasil, 2016.
- Johannes Schmidt-Hieber. The kolmogorov–arnold representation theorem revisited. *Neural networks*, 137:119–126, 2021.
- Sagar Sharma, Simone Sharma, and Anidhya Athaiya. Activation functions in neural networks. *Towards Data Sci*, 6(12):310–316, 2017a.
- Sagar Sharma, Simone Sharma, and Anidhya Athaiya. Activation functions in neural networks. *Towards Data Sci*, 6(12):310–316, 2017b.
- Xiao-Sheng Si, Wenbin Wang, Chang-Hua Hu, and Dong-Hua Zhou. Remaining useful life estimation—a review on the statistical data driven approaches. *European journal of operational research*, 213(1):1–14, 2011.
- J. W. Silva. *Avaliação de métodos ultrassônicos para o monitoramento da degradação em fadiga de tubos de prfv*. Master's thesis, Dissertação de Mestrado, Universidade Federal do Rio Grande do Sul, Rio Grande do Sul., 2021.
- Leandro Alselmo da Silva. *Substituição de anéis de vedação de ptfe por anéis de bronze (cual) com adição de sn superficial*. Master's thesis, UniFOA, Volta Redonda, RJ, Brasil, 2016.
- Silva, 2008. *Deslizamento a seco do PEEK e PTFE contra aço-liga*, Porto de Galinhas, PE, Brasil, 2008.
- Karan Sotoodeh. *A practical guide to piping and valves for the oil and gas industry*. Gulf Professional Publishing, 2021a.
- Karan Sotoodeh. Subsea valves and actuators: a review of factory acceptance testing (fat) and recommended improvements to achieve higher reliability. *Life Cycle Reliability and Safety Engineering*, 10:183–196, 2021b.
- Karan Sotoodeh. Simulation of underwater conditions for subsea valves—a review of hyperbaric tests and validation. *International Journal of Pressure Vessels and Piping*, 191:104353, 2021c.
- Karan Sotoodeh. *Subsea valves and actuators for the oil and gas industry*. Gulf Professional Publishing, 2021d.
- Jefferson Rodrigo de Souza. *Modelagem dinâmica e avaliação do desempenho de atuação hidráulica de uma válvula submarina do tipo esfera visando o monitoramento da condição*. Master's thesis, UFRJ, Rio de Janeiro, RJ, Brasil, 2019.

Matos F. C. A. Dias H. O. T. Acionamento inteligente de válvula offshore por liga com memória de forma. Bachelor's thesis, Centro Federal de Educação Tecnológica Celso Suckow da Fonseca - CETEF, Rio de Janeiro, RJ, Brasil, 2018.

Offshore Technology. The world's worst offshore oil rig disasters, 2019. URL <https://www.offshore-technology.com/features/feature-the-worlds-deadliest-offshore-oil-rig-disasters-4149812/>. Disponível em: < <https://www.offshore-technology.com/features/feature-the-worlds-deadliest-offshore-oil-rig-disasters-4149812/> >. Acesso em: 11 Julho de 2023.

Diógenes B Teles, Sandro M Gouveia, and Thomas GR Clarke. Identification of leakage in ball valves by analysis of pressure and torque signatures in cyclical tests under critical operating conditions. *Engineering Failure Analysis*, 117:104828, 2020.

Diógenes Barbosa Teles. Projeto e validação de válvula industrial do tipo esfera para baixa emissão fugitiva. Master's thesis, UFRGS, Rio Grande do Sul, RS, Brasil, 2015.

Diógenes Barbosa Teles. *Execução de ensaios, análise de dados e detecção de falhas em válvula do tipo esfera trunnion utilizadas nas instalações de exploração, produção, refino e transporte de produtos de petróleo*. PhD thesis, UFRGS, Porto Alegre, RS, Brasil, 2020.

Diógenes Barbosa Teles, Gustavo da Silva Gehlen, Germano Lasch, Liu Yesukai de Barros, Yago Muniz Dias, Patric Daniel Neis, Ney Francisco Ferreira, and André João de Souza. Tribological investigation of contact pairs applied in metallic gate valve seals for onshore application. *Wear*, 523: 204750, 2023.

Diógenes Barbosa Teles, Victor Velho de Castro, Mariana dos Reis Tagliari, André João de Souza, and Célia de Fraga Malfatti. Effect of hvof spray coating on the tribological surface of onshore gate valves. *Wear*, 546:205322, 2024.

Niamat Ullah, Zahoor Ahmed, and Jong-Myon Kim. Pipeline leakage detection using acoustic emission and machine learning algorithms. *Sensors*, 23(6):3226, 2023.

G Unnikrishnan, Nihal A Siddiqui, et al. Analysis of independent protection layers and safety instrumented system for oil gas separator using bayesian methods. *Reliability: Theory & Applications*, 10(1 (36)):50–59, 2015.

Chenyang Wang, Wanlu Jiang, Yi Yue, and Shuqing Zhang. Research on prediction method of gear pump remaining useful life based on dcae and bi-lstm. *Symmetry*, 14(6):1111, 2022.

Hang Wang, Minjun Peng, Renyi Xu, Abiodun Ayodeji, and Hong Xia. Remaining useful life prediction based on improved temporal convolutional network for nuclear power plant valves. *Frontiers in Energy Research*, 8:584463, 2020.

Hang Wang, Min-jun Peng, Zhuang Miao, Yong-kuo Liu, Abiodun Ayodeji, and Chengming Hao. Remaining useful life prediction techniques for electric valves based on convolution auto encoder and long short term memory. *ISA transactions*, 108:333–342, 2021.

Qiyao Wang, Shuai Zheng, Ahmed Farahat, Susumu Serita, and Chetan Gupta. Remaining useful life estimation using functional data analysis. In *2019 IEEE International Conference on Prognostics and Health Management (ICPHM)*, pages 1–8. IEEE, 2019.

Rui Wang and Ke Tang. Feature selection for maximizing the area under the roc curve. In *2009 IEEE International Conference on Data Mining Workshops*, pages 400–405. IEEE, 2009.

Global Energy Group Westwood. Global subsea tree tracker, 2023. URL <https://www.westwoodenergy.com/news/infographics/global-subsea-tree-tracker>. Disponível em: < <https://www.westwoodenergy.com/news/infographics/global-subsea-tree-tracker> >. Acesso em: 17 Julho de 2023.

Lin Xie. Modified failure rates for safety instrumented systems based on operational experience from the oil and gas industry. Master’s thesis, NTNU, 2017.

Jianfeng Xu, Yuanjian Zhang, and Duoqian Miao. Three-way confusion matrix for classification: A measure driven view. *Information sciences*, 507:772–794, 2020.

Rui Xu and Donald Wunsch. Survey of clustering algorithms. *IEEE Transactions on neural networks*, 16(3):645–678, 2005.

Jin Yan, Yang Heng-hu, Yang Hong, Zhang Feng, Liu Zhen, Wang Ping, and Yang Yan. Nondestructive detection of valves using acoustic emission technique. *Advances in Materials Science and Engineering*, 2015, 2015.

Hao Wen Haowen Shu Lanting Feng Bo Liang Hua Wang Hailan Wang Yanjie Jia, Li Gu. Analysis and prevention of internal leakage of ball valve in oil and gas pipeline. *International Core Journal of Engineering*, 8(2), 2022.

Yaser Arbabi Yazdi, Heydar Toossian Shandiz, and Hosein Gholizadeh Narm. Stiction detection in control valves using a support vector machine with a generalized statistical variable. *ISA transactions*, 126:407–414, 2022.

Jianhao Yu, Jiahuan Yi, and Haroun Mahgerefteh. Optimal emergency shutdown valve configuration for pressurised pipelines. *Process Safety and Environmental Protection*, 159:768–778, 2022. ISSN 0957-5820. doi: <https://doi.org/10.1016/j.psep.2022.01.028>. URL <https://www.sciencedirect.com/science/article/pii/S0957582022000283>.

Yong Yu, Xiaosheng Si, Changhua Hu, and Jianxun Zhang. A review of recurrent neural networks: Lstm cells and network architectures. *Neural computation*, 31(7):1235–1270, 2019.

Huan Zhang, Tsui-Wei Weng, Pin-Yu Chen, Cho-Jui Hsieh, and Luca Daniel. Efficient neural network robustness certification with general activation functions. *Advances in neural information processing systems*, 31, 2018.

Jun Zhang and Kim-Fung Man. Time series prediction using rnn in multi-dimension embedding phase space. In *SMC'98 Conference Proceedings. 1998 IEEE International Conference on Systems, Man, and Cybernetics (Cat. No. 98CH36218)*, volume 2, pages 1868–1873. IEEE, 1998.

YongZhi Zhang, Rui Xiong, HongWen He, and Zhiru Liu. A lstm-rnn method for the lithium-ion battery remaining useful life prediction. In *2017 Prognostics and System Health Management Conference (PHM-Harbin)*, pages 1–4. IEEE, 2017.

Hanxue Zhao, Zhenlin Li, Shenbin Zhu, and Ying Yu. Valve internal leakage rate quantification based on factor analysis and wavelet-bp neural network using acoustic emission. *Applied Sciences*, 10(16): 5544, 2020.

Gengzhe Zheng, LiMing Wu, Tengteng Wen, Chuntao Zheng, Chunpeng Wang, and Gengxuan Lin. Research on predicting remaining useful life of equipment based on health index. In *2021 7th International Conference on Condition Monitoring of Machinery in Non-Stationary Operations (CMMNO)*, pages 145–149. IEEE, 2021.

Zhi-Hua Zhou. *Machine learning*. Springer Nature, 2021.

Pengyu Zhu, Jayantha P Liyanage, and Simon Jeeves. Condition and performance monitoring of emergency shutdown systems: Data visualization and analysis for decision support. In *Engineering Assets and Public Infrastructures in the Age of Digitalization: Proceedings of the 13th World Congress on Engineering Asset Management*, pages 376–386. Springer, 2020.

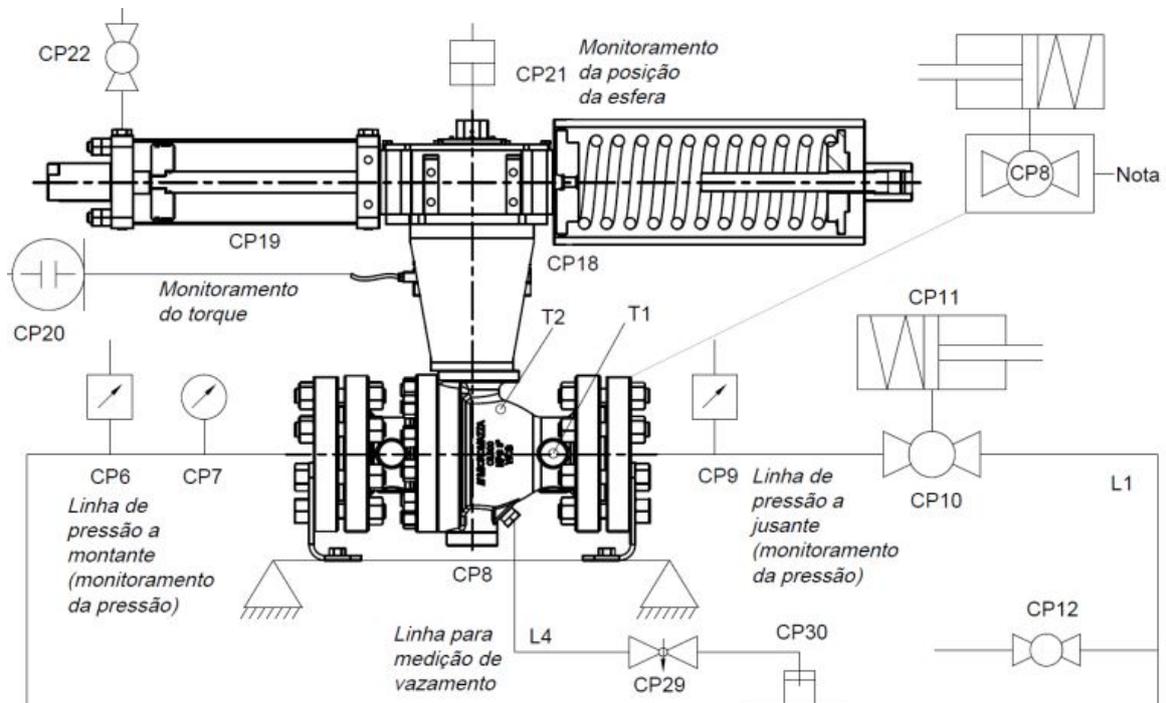
Shen-Bin Zhu, Zhen-Lin Li, Shi-Min Zhang, Le-Le Liang, and Hai-Feng Zhang. Natural gas pipeline valve leakage rate estimation via factor and cluster analysis of acoustic emissions. *Measurement*, 125: 48–55, 2018.

## APÊNDICE A PROCEDIMENTO PARA VERIFICAR VAZAMENTOS

Com o intuito de descrever o procedimento realizado para verificar se houve níveis de vazamento entre o lado montante e jusante e jusante-montante, esta seção irá sumarizar as atividades realizadas ao final dos testes de ciclagem utilizando a técnica de contagem de bolhas, descrita e padronizada segunda a norma API 598.

A medição do nível de vazamento, é realizada através da cavidade da válvula, onde uma tubulação é conectada a saída da cavidade, simbolizada pela linha L4 conforme Fig. 77. O tubo possui diâmetro externo de 6 mm com uma parede de 1 mm de espessura. A extremidade do tubo fica posicionada em um recipiente com água (CP 30), a uma profundidade de 5 até 10 mm, perpendicularmente a superfície da água. A válvula agulha (CP 29) é aberta, permitindo qualquer fluido na cavidade escoar pela linha L4, chegando ao recipiente, e em caso de vazamento, a verificação visual do número de bolhas. Resultando assim, em falha por vazamento no equipamento.

Figura 76: Configuração utilizada para realizar a contagem de bolhas, em caso de vazamento após o fim dos testes cíclicos.



Fonte: Adaptado de Teles (2020).

## APÊNDICE B ETAPAS PARA GERAR OS CICLOS

Todas as etapas foram conduzidas na dependência da empresa Micromazza, onde durante estes ensaios, a área foi completamente controlada e isolada.

O teste se inicia com o bombeamento do fluido de teste (ar comprimido), sendo bombeado pelo CP 14. Ao passar pela linha L1, o fluido chega a montante da válvula, onde os valores de pressão são registrados pelo CP6, a fim de garantir que o máximo diferencial de pressão é aplicado na válvula, com a diferença lida pelo CP9 (jusante).

O controlador, CP31, ao detectar que o diferencial de pressão de 92 bar, foi criado, inicial a pressurização do atuador da válvula de bloqueio, CP19, através da linha L3. Ao se iniciar a abertura da válvula de bloqueio, com a pressurização continua fornecida pelo CP28 através da linha L3, o obturador iniciara seu processo de rotação e abertura. Quando este atingir o momento de *crack-open*, o fluido pressurizado, passara para o lado jusante, provocando uma diminuição de pressão na linha L1. O compressor irá trabalhar no intuito de restaurar a pressão de 92 bar na linha L1, montante e jusante da válvula de bloqueio. Ao completar seu giro de 90°, as pressões, em ambos os lados, montante e jusante, estarão equalizados, conforme leitura do CP6 e CP9 processada no computador de processamento, CP32.

Para promover o fechamento da válvula de bloqueio, a válvula hidráulica CP26, é aberta, liberando o retorno do fluido pressurizado para o tanque CP28. A mola, que se encontrava comprimida, devido ao avanço do pistão, agora libera sua energia potencial elástica, provendo assim, o fechamento da válvula de bloqueio.

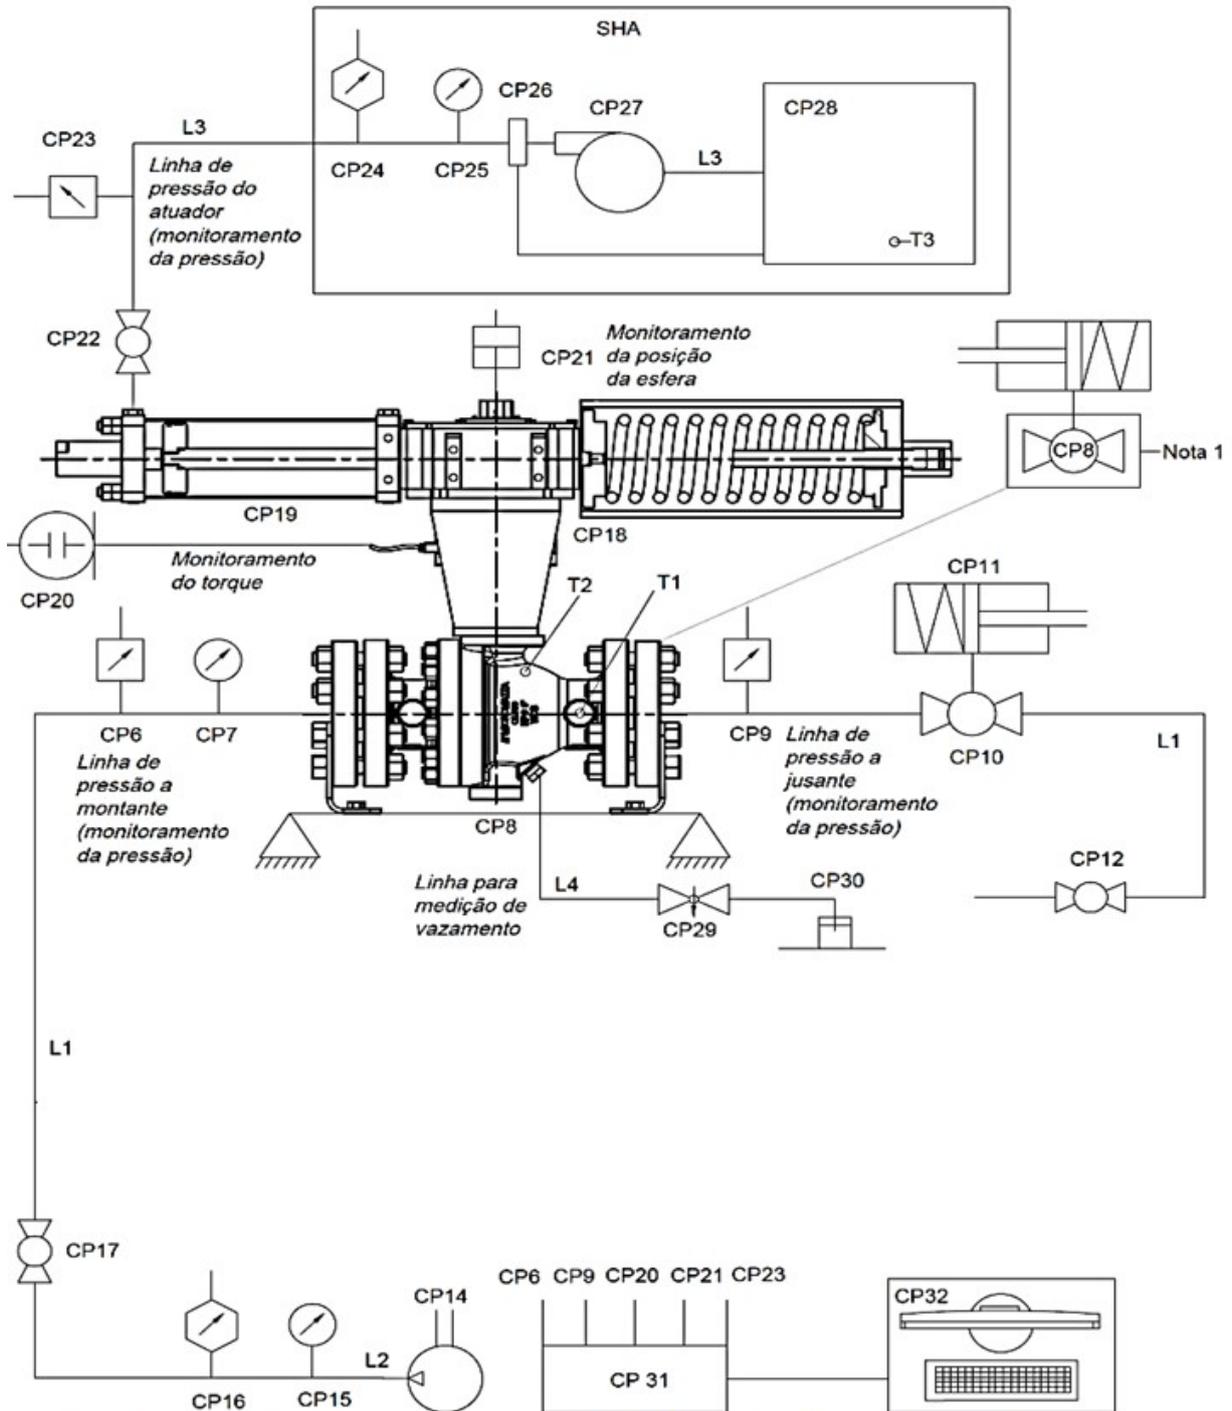
Durante o fechamento, o CP11, é aberta no momento exato de *crack-open*, a fim de despressurizar o lado jusante da válvula, para gerar o mesmo diferencial de pressão no fechamento. O CP12 também é aberto e o fluido pressurizado é descartado para a atmosfera.

Com o completo recuo do atuador, CP19, o obturador se encontra na posição de 0°. Neste momento, o CP11 é fechado.

O CP31, ao detectar o completo fechamento da válvula, através da leitura da posição angular do obturador, CP21, irá iniciar o bombeamento do fluido na linha L3, pela bomba hidráulica CP27, iniciando-se assim o 2º ciclo.

O processo se repete a cada novo ciclo.

Figura 77: Configuração utilizada para realizar os ensaios cíclicos.



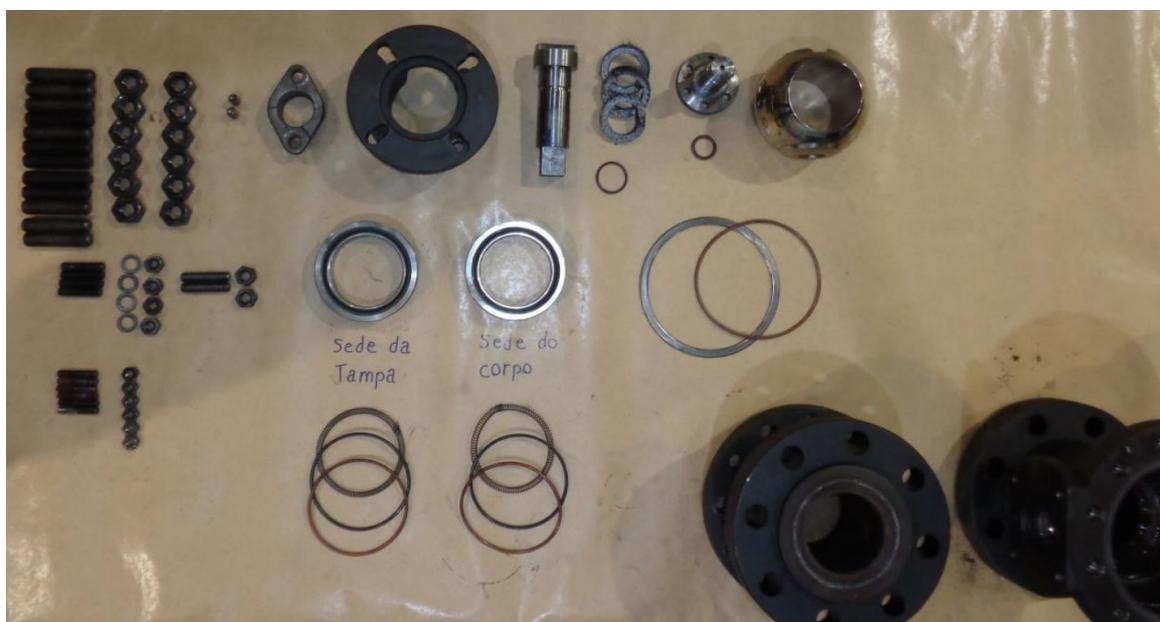
- CP1 - Tanque para fluido de teste  
 CP2 - Bomba hidráulica  
 CP3 - Manômetro  
 CP4 - Regulador de pressão hidrostática  
 CP5 - Válvula esfera NPS 1/2" CL800  
 CP6 - Transdutor de pressão a montante  
 CP7 - Manômetro  
 CP8 - Válvula protótipo NPS 3" CL600  
 CP9 - Transdutor de pressão a jusante  
 CP10 - Válvula esfera NPS 1/2" CL800  
 CP11 - Atuador pneumático retorno mola  
 CP12 - Válvula esfera NPS 1/2" CL800  
 L1 - Linha de pressão hidrostática  
 L2 - Linha de pressão pneumática  
 Nota 1: Para ensaios em temperatura máxima 120 °C, utiliza-se sistema de aquecimento por meio de resistências elétricas. Para os ensaios em temperatura mínima -18 °C, utiliza-se câmara de resfriamento.
- CP13 - Válvula esfera NPS 1/2" CL800  
 CP14 - Compressor de alta pressão  
 CP15 - Manômetro  
 CP16 - Regulador de pressão pneumática  
 CP17 - Válvula esfera NPS 1/2" CL800  
 CP18 - Câmara da mola do atuador  
 CP19 - Cilindro hidráulico do atuador  
 CP20 - Transdutor de torque  
 CP21 - Monitor de posição angular  
 CP22 - Válvula de controle  
 CP23 - Transdutor de pressão  
 CP24 - Regulador de pressão  
 CP25 - Manômetro  
 CP26 - Válvula hidráulica  
 CP27 - Bomba hidráulica  
 CP28 - Tanque do fluido hidráulico  
 CP29 - Válvula agulha  
 CP30 - Medição de vazamento  
 CP31 - Controlador  
 CP32 - Computador processador
- P1 - Painel de controle da pressão  
 SHA - Sistema hidráulico do atuador  
 T1 - Sensor de temperatura  
 T2 - Sensor de temperatura  
 T3 - Sensor de temperatura

Fonte: Adaptado de Teles (2020).

## APÊNDICE C DESMONTAGEM E MEDIÇÃO DOS COMPONENTES

Após o fim dos testes de ciclagem, todo o equipamento foi desmontado e analisado por inspeção visual para, então, se correlacionar os sinais de monitoramento com as degradações ocorridas que levaram a possíveis falhas. A Fig. 78 mostra a etapa de desmontagem e os componentes posicionados para inspeção.

Figura 78: Desmontagem da válvula após os testes cíclicos.

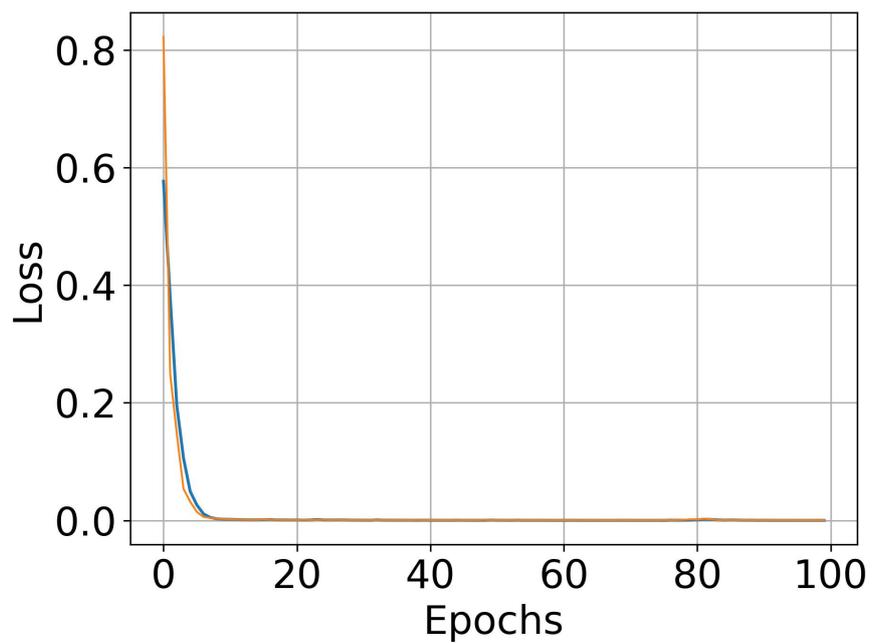


Fonte: Adaptado de Teles (2020).

## APÊNDICE D LOSS DA LSTM

Apresentação do *Loss* da LSTM.

Figura 79: Loss da LSTM em função das Épocas.



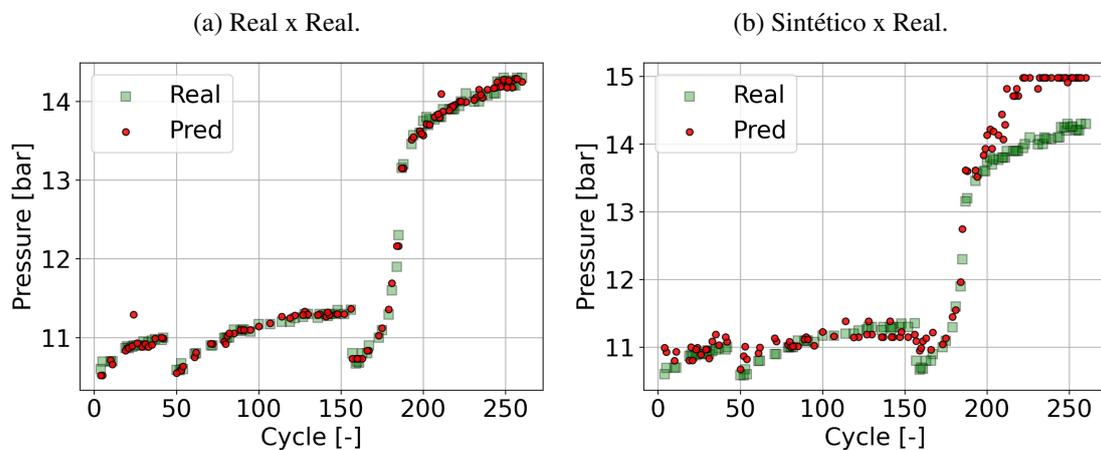
Fonte: Próprio Autor.

## APÊNDICE E DISPOSIÇÃO TEMPORAL DAS REGRESSÕES

Resultados da regressão do KP A3, utilizando-se as assinaturas de pressão como entrada para cada modelo, abaixo, os resultados para os modelos kNN e LR, que em suma, apresentaram resultados menores que o GB (vide 4.2.3).

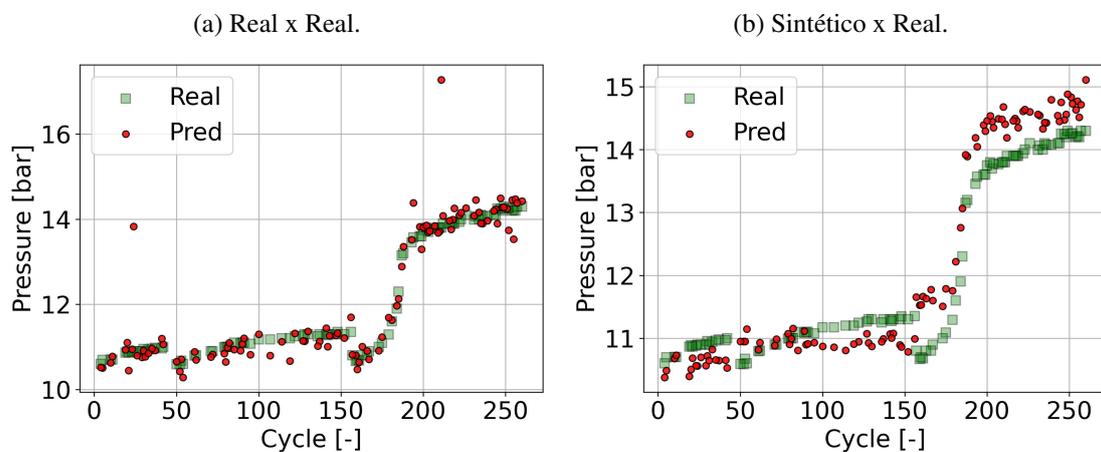
Os resultados foram dispostos temporalmente, em função do número de ciclos, a fim de mostrar a aderência dos dados reais e preditos.

Figura 80: Resultado da regressão utilizando o algoritmo kNN. Com o treinamento ocorrendo com os dados reais. Os dados de entrada foram o *Key Point A3*.



Fonte: Próprio Autor.

Figura 81: Resultado da regressão utilizando o algoritmo LR. Com o treinamento ocorrendo com os dados reais. Os dados de entrada foram o *Key Point A3*.

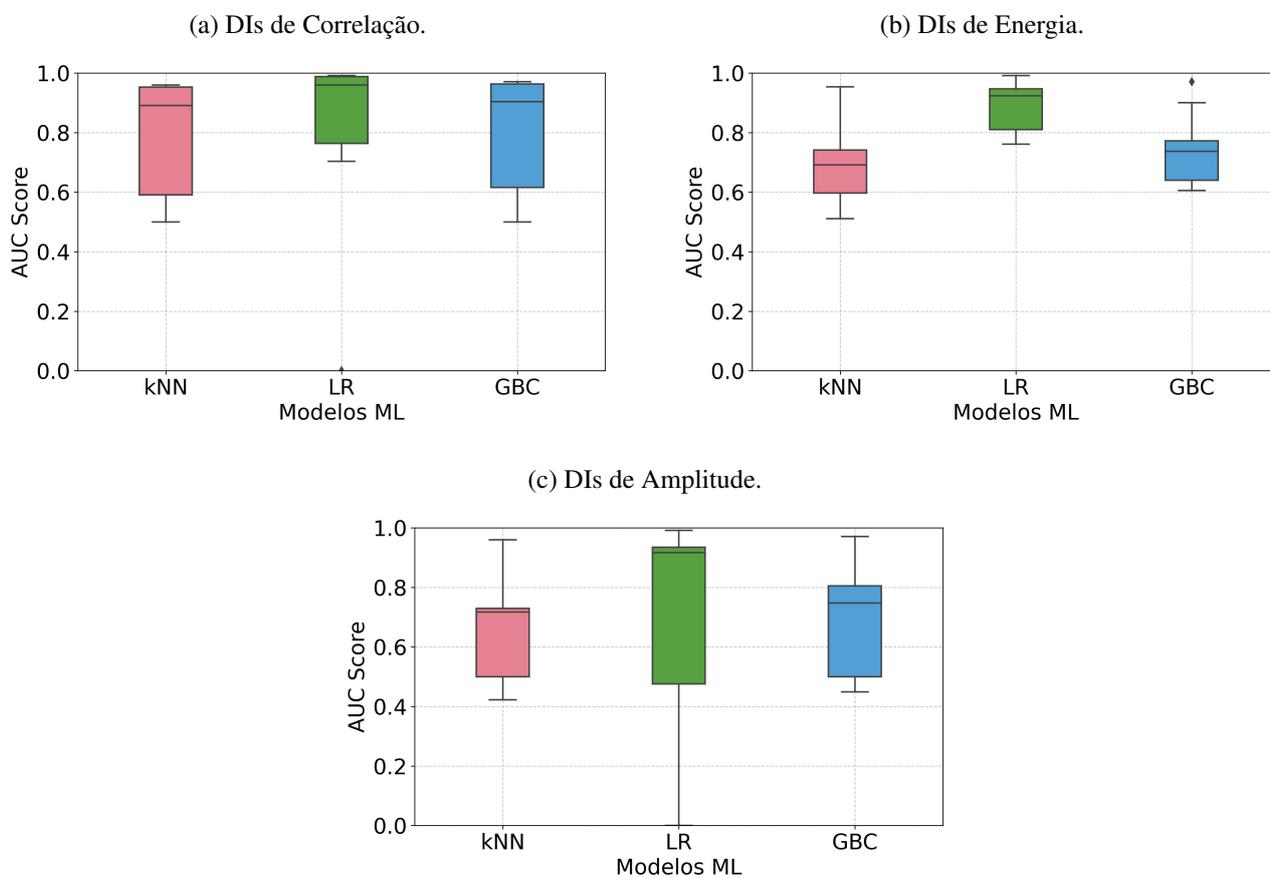


Fonte: Próprio Autor.

## APÊNDICE F BOXPLOT DAS FAMILIAS DE DIS - SINTÉTICO X REAL

Resultado das classificações, utilizando-se os dados sintéticos durante a fase de treinamento, para cada família de DI.

Figura 82: Resultado da classificação usando os *Damage Index* como entrada. O treino foi realizado com os dados sintéticos.



Fonte: Próprio Autor.