



**UNIVERSIDADE FEDERAL DE UBERLÂNDIA
FACULDADE DE ENGENHARIA QUÍMICA**



IGOR ALMEIDA DE MORAIS

**DETECÇÃO DE VAZAMENTO DE FLUIDOS EM TUBULAÇÕES:
MÉTODOS EXTERNOS, INTERNOS E APLICAÇÃO DE
APRENDIZADO DE MÁQUINA**

Uberlândia

2023

IGOR ALMEIDA DE MORAIS

**DETECÇÃO DE VAZAMENTO DE FLUIDOS EM TUBULAÇÕES:
MÉTODOS EXTERNOS, INTERNOS E APLICAÇÃO DE
APRENDIZADO DE MÁQUINA**

Trabalho de conclusão de curso apresentado à Universidade Federal de Uberlândia como parte dos requisitos necessários para a aprovação na disciplina Trabalho de Conclusão de curso, do curso de Engenharia Química.

Orientador: Prof. Dr. Ubirajara Coutinho Filho

Uberlândia

2023

**DETECÇÃO DE VAZAMENTO DE FLUIDOS EM TUBULAÇÕES:
MÉTODOS EXTERNOS, INTERNOS E APLICAÇÃO DE
APRENDIZADO DE MÁQUINA**

Uberlândia, __ de _____ de 2023

Monografia aprovada para a disciplina Trabalho de Conclusão de Curso, do curso de Engenharia Química, da Universidade Federal de Uberlândia (MG) pela banca examinadora formada por:

Prof. Dr. Ubirajara Coutinho Filho, FEQUI/UFU

Prof. Dr. Rubens Gedraite, FEQUI/UFU

M.Sc. Heitor Otacílio Nogueira Altino, PPGEQ/UFU

DEDICATÓRIA

Dedico este trabalho a minha família, meus amigos e a todos que me apoiaram e foram fontes de motivação e inspiração.

AGRADECIMENTOS

Agradeço aos meus pais Ademar e Joteilde por todo apoio, incentivo, confiança e por me ensinarem desde cedo o valor dos estudos e da disciplina. Tenho muito a agradecer a minha irmã Taynara, por ser minha maior fonte de inspiração e o motivo pelo qual me sinto desafiado todos os dias a ser uma pessoa melhor em todos os aspectos, sem dúvida alguma ela possui uma contribuição imensa na minha vida pessoal e acadêmica.

Às amigas que tive oportunidade de fazer durante a graduação e no PET, por toda a cumplicidade e pelos momentos de diversão. Compartilhamos momentos e histórias maravilhosas que contribuíram para a minha construção intelectual e pessoal.

Aos professores da Faculdade de Engenharia Química por serem uma fonte tão abundante de conhecimento, pelos ensinamentos e pelo incentivo para que nos tornássemos ótimos profissionais e também ao Professor Ubirajara Coutinho Filho e a Professora Sarah Arvelos Altino que foram essenciais para a conclusão deste trabalho.

À oportunidade de participar do Programa de Educação Tutorial (PET) e conhecer pessoas incríveis que fizeram os meus dias mais felizes e me ensinaram tanto de forma tão acolhedora.

À Universidade Federal de Uberlândia por toda a estrutura fornecida durante a graduação e a Pró-Reitoria de Assistência Estudantil (PROAE) pelos auxílios indispensáveis para a minha permanência em Uberlândia durante todo esse período.

RESUMO

Vazamentos em tubulações responsáveis pelo transporte de fluidos como petróleo ou derivados podem causar grandes danos a natureza e impactos econômicos a empresas do ramo. O uso de variáveis da operação atreladas a equipamentos possibilitou o desenvolvimento de métodos internos e externos para a detecção e localização dos vazamentos e têm sido aperfeiçoados com o intuito de atenuar esses impactos e promover maior segurança às operações. O aprimoramento das tecnologias para armazenamento de dados culminou no surgimento de *big data* e no desenvolvimento de algoritmos para aprendizado de máquina, capazes de compreender padrões e possibilitou a criação de novos métodos para a detecção dessas falhas operacionais que podem ser mais econômicas e eficazes. O objetivo deste trabalho foi realizar uma revisão bibliográfica dos métodos já existentes e em seguida implementar um algoritmo capaz de identificar possíveis vazamentos. Foi realizada uma revisão a respeito dos métodos externos e internos, tradicionais para a detecção de vazamentos, além de uma abordagem sobre a Indústria 4.0 e os impactos dessa revolução na identificação de falhas em tubulações. No estudo de caso foram utilizados dados presentes no artigo de Eastevedt (2022) e um algoritmo de classificação para a predição de vazamentos, onde foram alcançados resultados com coeficiente de correlação superiores a 90%.

Palavras-chave: vazamento, tubulação, detecção, aprendizado de máquina

ABSTRACT

Leaks in pipelines responsible for transporting fluids such as oil or derivatives can cause great damage to nature and economic impacts to companies in the sector. The use of operating variables linked to equipments allowed the development of internal and external methods for detecting and locating leaks, which have been improved with the aim of mitigating these impacts and promoting greater safety in operations. The improvement of technologies for data storage culminated in the emergence of big data and the development of algorithms for machine learning, capable of understanding patterns and enabled the creation of new methods for detecting these operational failures that can be more economical and effective. The objective of this work was to carry out a bibliographic review of existing methods and then implement an algorithm capable of identifying possible leaks. A review was carried out regarding the traditional external and internal methods for detecting leaks, as well as an approach on Industry 4.0 and the impacts of this revolution in identifying faults in pipelines. In the case study, data present in the article by Eastevedt (2022) were use with a classification algorithm for leak prediction where results with a correlation coefficient greater than 90% were achieved.

Keywords: leak, pipelines, detection, machine learning

LISTA DE FIGURAS

Figura 1. Sensor de vazamento de gás da Hantech.	7
Figura 2. Exemplos de espectrômetros óticos.....	8
Figura 3. Exemplos de espectrômetros óticos.....	9
Figura 4. Exemplos de espectrômetros óticos.....	11
Figura 5. Representação do princípio de funcionamento do sistema de detecção de vazamento NPW.	12
Figura 6. Representação do princípio de funcionamento do sistema de detecção de vazamento NPW.	14
Figura 7. Gráfico de dispersão que relaciona a queda de pressão (Δp) com a velocidade de escoamento (U).....	22
Figura 8. Representação do furo na simulação.....	23
Figura 9. Coeficiente de determinação como função do número de k-vizinhos para a representação dos conjuntos de treino e teste do problema de diagnóstico de falha.	24

SUMÁRIO

1. INTRODUÇÃO	1
2. OBJETIVOS	3
3. REVISÃO DE LITERATURA.....	4
3.1. DEFINIÇÕES: TUBULAÇÕES, TRANSPORTE DE MATÉRIA E SEGURANÇA INDUSTRIAL	4
3.2. DETECÇÃO DE VAZAMENTOS	5
3.2.1. <i>MÉTODOS EXTERNOS</i>	6
3.2.1.1. INSPEÇÃO HUMANA	6
3.2.1.2. SENSORES QUÍMICOS DE VAPOR.....	6
3.2.1.3. DETECÇÃO ACÚSTICA	8
3.2.1.4. FIBRAS ÓTICAS	9
3.2.2. <i>MÉTODOS INTERNOS</i>	10
3.2.2.1. BALANÇO DE MASSA OU VOLUME	10
3.2.2.2. DETECÇÃO DE ONDAS DE PRESSÃO NEGATIVA.....	11
3.2.2.3. ANÁLISE ESTATÍSTICA	13
3.3. INDÚSTRIA 4.0: AQUISIÇÃO DE DADOS E CONTROLE	14
3.4. APRENDIZADO DE MÁQUINA E SUAS APLICAÇÕES PARA A DETECÇÃO DE VAZAMENTOS.....	15
4. ESTUDO DE CASO.....	17
4.1. DETALHES SOBRE A SIMULAÇÃO COMPUTACIONAL	18
4.2. OPERAÇÃO DE DUTOS EM CONDIÇÕES NORMAIS	20
4.3. OPERAÇÃO DE DUTOS EM CONDIÇÕES DE FALHA.....	23
5. CONSIDERAÇÕES FINAIS	25
6. REFERÊNCIAL BIBLIOGRÁFICO.....	26

1. INTRODUÇÃO

A maneira mais simples de realizar o transporte de grandes quantidades de fluidos derivados de petróleo a grandes distâncias é pelo uso de tubulações. Entretanto, ainda que exista regulamentação e esforços para o monitoramento contínuo desses escoamentos, sempre há a possibilidade de vazamentos **(MALEKPOUR; SHE, 2021)**. Um ponto importante a ser observado é o grande nível de perigo envolvido nesses acidentes. Assim, há um consenso a respeito da importância da rápida detecção e localização de danos em dutos, com o intuito de preservar vidas e prevenir perdas econômicas **(MANDAL et al., 2012)**.

Diversos métodos para a criação de sistemas de detecção de vazamentos em tubulações de líquidos ou gases foram propostos, muitos deles baseados em variáveis de processo (pressão, vazão e temperatura) **(BELSITO, 1998)**. Para a detecção de vazamento de líquidos e gases em escoamentos existem basicamente dois métodos. Denominam-se como externos aqueles que estão associados às condições externas do tubo. Como exemplos, tem-se o uso de sensores acústicos, acelerômetros, fibras óticas, impedância e capacitância. Por outro lado, os métodos do tipo interno são os que utilizam de parâmetros hidráulicos e físicos do tubo e do fluido para estimar a taxa de vazamento e a localização. São exemplos: balanço de massa, ondas de pressão negativa, processamento de sinal e modelagem dinâmica **(KIM, 2021)**.

Em 2011 foi anunciado o conceito de Indústria 4.0, simbolizando uma nova era na revolução industrial. Essa nova proposta busca um modelo de produção mais eficiente, seguro, sustentável e mais econômico. Atrelado a este conceito estão a Internet das Coisas (*IoT - Internet of Things*), a inteligência artificial (*AI - Artificial Intelligence*), o *Big Data* e outras tecnologias mais avançadas **(MEHDIYEV; FATALIYEVA, 2020)**.

Considerando-se, portanto, o novo momento vivido pela sociedade pautado no uso de um grande volume de dados (*Big Data*), a modelagem de algoritmos de *Machine Learning* mostra-se como uma forma segura, de baixo custo e acurada de monitorar tubulações e, conseqüentemente, vazamentos **(EASTVEDT, 2022)**. Os algoritmos usados podem ser classificados em duas

categorias principais: supervisionados (preditivos) e não supervisionados (descritivos). O método de aprendizagem supervisionada utiliza variáveis para prever valores de outras variáveis, para isso são utilizados dados históricos para treinar o modelo criado. Como exemplos de aprendizagem supervisionada temos os modelos de classificação, regressão e detecção de anomalias. Por outro lado, o método de aprendizagem não supervisionada determina padrões que descrevem os dados e, a partir deles, descreve relações entre as variáveis de entrada e as de interesse. Modelos de clusterização e associação são exemplos de aprendizagem não supervisionada (**Eissa, 2020**).

O presente trabalho de conclusão de curso está subdividido em cinco capítulos, brevemente descritos a seguir. No Capítulo 2 são apresentados os objetivos gerais e específicos do trabalho. No Capítulo 3 são apresentadas algumas tecnologias já existentes na detecção de vazamentos, uma breve revisão de literatura sobre os conceitos fundamentais necessários para a compreensão da pesquisa bibliográfica realizada e identificada a metodologia empregada para que os objetivos fossem atingidos. No Capítulo 4 é apresentada uma revisão dos resultados alcançados no trabalho de **Eastvedt et al. (2022)** e em seguida um estudo de caso realizado a partir dos mesmos dados utilizados por aquele autor. Por fim no Capítulo 5 são apresentadas as considerações finais a respeito dos métodos de detecção de vazamento apontados e como o surgimento da Indústria 4.0 contribui para o aperfeiçoamento das técnicas já existentes.

2. OBJETIVOS

Em virtude do que foi apresentado, o objetivo geral do presente trabalho de conclusão de curso foi realizar uma revisão de literatura sobre os tópicos envolvendo o transporte de fluidos em tubulações industriais e as diversas formas de detecção de vazamento, além das inovações que envolvem a Indústria 4.0 e seus aspectos disruptivos.

Como objetivo específico, pretendeu-se ilustrar a aplicação de um modelo de aprendizado de máquina à detecção de vazamentos. Sendo assim, foi realizado um estudo de caso sobre a detecção de vazamento em tubulação submarina utilizando-se de informações geradas através de uma reavaliação dos dados apresentados por Eastvedt et al. (2022)

3. REVISÃO DE LITERATURA

3.1. DEFINIÇÕES: TUBULAÇÕES, TRANSPORTE DE MATÉRIA E SEGURANÇA INDUSTRIAL

Tubulações são um o meio pelo qual ocorre o transporte de fluidos entre dois pontos. A complexidade desse sistema está relacionada com os dispositivos que podem ser acoplados a ele, como bombas, válvulas e sensores, com o intuito de promover alguma ação (aumento de pressão ou controlar um fluxo) ou captar uma informação (temperatura, pressão, vazão). Qualquer tubulação possui uma entrada e uma saída e precisa de uma força motriz responsável por fornecer energia para que o fluido possa percorrê-la, sendo essa força promovida por uma bomba (no caso de líquidos) ou um compressor (no caso de gases) que podem ser controlados localmente ou remotamente (**Henrie, 2016**).

O desenvolvimento industrial de uma nação pressupõe o uso de uma rede de tubulações que possam garantir o transporte e a distribuição de *commodities* como água, gás, petróleo ou qualquer matéria prima necessária para o desenvolvimento de produtos derivados. Em especial, o transporte de hidrocarbonetos possui extrema importante, devido a sua relevância energética e, conseqüentemente, econômica para um país (**Henrie, 2016**).

O fluido presente em uma tubulação pode ser caracterizado pelas suas propriedades físicas e também pelo tipo de regime (estacionário e não estacionário) e escoamento. Considera-se, portanto, que fluidos em regime estacionário mantêm as suas propriedades constantes ao longo do tempo, como, por exemplo, velocidade, densidade e pressão em contraste com fluidos em regime não estacionário que podem ter suas condições alteradas ao longo do tempo, influenciando suas propriedades. O escoamento pode ser definido como laminar, de transição ou turbulento, e o número de Reynolds (**Equação 1**) é utilizado para fazer essa classificação, conforme descrito pela **Equação 2 (Brunetti, 2008)**, onde ρ é a massa específica do fluido, v a velocidade do fluido, μ a viscosidade fluido e D o diâmetro da tubulação.

$$Re = \frac{\rho v D}{\mu} \quad (1)$$

$Re < 2000$	Escoamento Laminar	
$2000 < Re < 2400$	Escoamento de Transição	(2)
$Re > 2400$	Escoamento Turbulento	

Os sistemas responsáveis pelo transporte de fluidos necessitam de manutenções periódicas e substituições que podem ocorrer frequentemente devido a corrosão ou devido a mudança em alguma variável de processo. Em outros casos pode ser necessário alterar a rota da tubulação e em algumas situações mais simples requerem a limpeza dos tubos. Além disso, é comum a troca ou reparo de válvulas de controle ou sensores. A ausência dessas rotinas de segurança pode promover graves acidentes relacionados a vazamentos, como a explosão da refinaria de Los Angeles devido a ruptura de uma tubulação contendo hidrocarbonetos e hidrogênio na década de 90 (**SANDERS, 2005**). Portanto, a identificação de vazamentos de maneira precisa e eficaz é de extrema importância para a segurança dos processos industriais.

3.2. DETECÇÃO DE VAZAMENTOS

Derramamentos de dutos ocorrem, em geral, à medida que a infraestrutura do duto envelhece e transporta volumes maiores de produtos corrosivos. Não importa quão bons operadores gerenciem os dutos, forças externas além do controle do operador, como desastres naturais ou intervenções de terceiros, podem causar vazamentos. Alguns vazamentos são inevitáveis, mas o sistema de detecção rápida e a resposta eficiente minimizarão as consequências, garantindo menos danos ao meio ambiente, propriedades e pessoas (**MORGAN, 2016**).

As tecnologias de detecção de vazamentos se dividem em dois grupos principais: com base interna e com base externa. Na sequência, é apresentada uma visão geral dos métodos de detecção de vazamentos.

3.2.1. Métodos Externos

Os métodos externos, em geral, são baseados em *hardware* e, portanto, faz-se necessário o uso de equipamentos capazes de realizar a medição das variáveis de interesse e a partir delas identificar vazamentos. Os métodos de detecção de vazamento com base externa mais comuns incluem: a inspeção humana, os sensores químicos de vapor, a detecção acústica e o uso de fibras ópticas.

3.2.1.1. Inspeção Humana

Operadores treinados podem detectar os efeitos de um vazamento em uma tubulação. O produto que escapa de uma tubulação pode liberar odores ou fazer barulho ou alterar o ambiente ao redor do local do vazamento. Assim, a inspeção pessoal consiste em percorrer a tubulação em intervalos pré-estabelecidos para monitorar tais mudanças. Terceiros, como moradores ou terceiros de passagem, também podem detectar este tipo de vazamentos e denunciá-los. É uma boa política de prevenção educar a comunidade local, situada em torno de uma tubulação, sobre detecção de vazamentos e sobre como entrar em contato com a empresa responsável em caso de suspeita de vazamento. Uma pesquisa realizada em um banco de dados do PHMSA (*Pipeline and Hazardous Materials Safety Administration*)¹ sobre detecção de vazamentos mostra que muitos dos vazamentos foram detectados e relatados por terceiros.

3.2.1.2. Sensores químicos de vapor

O uso de sensores químicos tem crescido em número de aplicações devido ao uso de instrumentos portáteis. No caso de gases e vapores, equipamentos comumente utilizados no laboratório têm sido miniaturizados como espectrômetro de massas, cromatógrafos a gás e câmeras de infravermelho (Kingsborough, 2021).

Sensores de vapor podem detectar gases que escapam de uma tubulação. Essa tecnologia pode ser benéfica em dutos que transportam produtos altamente voláteis. A tecnologia pode ser propensa a falsos alarmes de vazamento se

¹ <https://www.phmsa.dot.gov/data-and-statistics/pipeline/data-and-statistics-overview>

outras fontes de vapor estiverem próximas à tubulação. Várias empresas comercializam sensores de gás em miniatura para sondar o ambiente local de um indivíduo para a saúde pessoal e monitoramento da qualidade do ar (Kingsborough, 2021). Em uma modalidade, tais sensores podem vir na forma de um dispositivo de *plug-in* de smartphone, enquanto em outras modalidades, o sensor é um componente separado conectado sem fio a um smartphone. Na **Figura 1**, é apresentado um exemplo de sensor de gás utilizado em salas de máquinas e compressores.

Figura 1. Sensor de vazamento de gás da empresa Hantech.



Fonte: Hantech (2022)

Uma forma interessante de se avaliar o vazamento de gases é através do uso de espectrômetros óticos. Segundo Crocombe (2018), este tipo de dispositivo portátil, mostrado na **Figura 2** começou a ter uma participação significativa no mercado com a destruição do World Trade Center, na cidade de Nova York, em 11 de setembro de 2001 e suas consequências, respondendo a demandas urgentes de instrumentação de triagem e detecção para detectar e identificar explosivos, ameaças químicas etc.

Figura 2. Exemplos de espectrômetros óticos



Fonte: **BWTeK e NCS (2022)**

3.2.1.3. Detecção acústica

A partir da década de 1960, diferentes métodos acústicos com dispositivos correspondentes foram desenvolvidos, como microfones de aterramento, correlacionadores de ruído de vazamento, registradores de ruído etc. Os métodos de emissão acústica são não-destrutivos, precisos e altamente eficientes. Portanto, eles são bastante utilizados para monitoramento em tempo real (**HARRIS, 2022**).

Industrialmente, o método acústico consiste no uso, em geral, de microfones instalados na superfície ou no interior de uma tubulação com o intuito de captar as ondas sonoras produzidas por um líquido quando ele flui por um vazamento. Podem ser utilizados vários microfones, buscando-se uma maior aproximação da localização e também dispositivos para filtrar possíveis ruídos. (**DURGIN; YOUNG, 1993**)

Os métodos de emissão acústica coletam sinais sonoros emitidos por um vazamento. O som é uma perturbação detectável que se propaga através de uma rede elástica que causa flutuação de pressão ou oscilação de suas partículas. O som é gerado pela interação entre a cavitação e a turbulência induzida por um vazamento. Essa interação também excita a parede do tubo para vibrar. Assim, a onda sonora pode ser transmitida através do líquido e da parede do tubo e pode ser medida por sensores acústicos. O vazamento é então detectado identificando o som induzido pelo vazamento. No entanto, a identificação depende das características do sinal. As características variam com

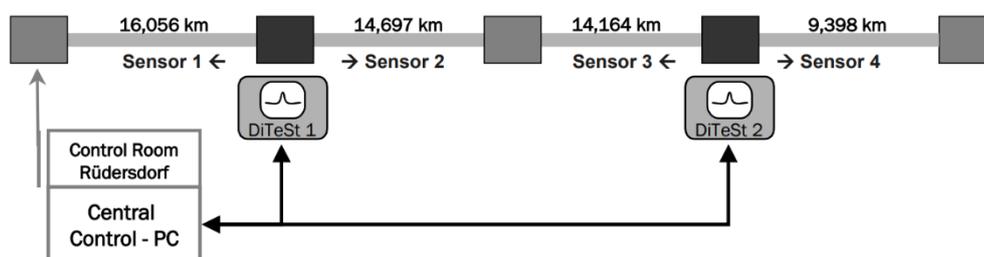
o tamanho do vazamento, a geometria do tubo, o material do tubo e o ambiente circundante. O sinal pode ser enfraquecido pela distância ou por quaisquer eventos ao longo da tubulação entre o sensor e o vazamento, por exemplo: juntas de tubos, curvas na tubulação, mudanças no diâmetro ou material da tubulação. Além disso, o ruído de outras fontes, chuva local, falhas ou válvulas parcialmente abertas, ou uma bomba em funcionamento ou um carro, também interferem no sinal. Portanto, muitos processamentos e classificações de sinais métodos precisam ser desenvolvidos para distinguir sinais de vazamento de outros sinais de ruído (**HARRIS, 2022**).

3.2.1.4. Fibras óticas

O uso de fibras óticas também tem se tornado bastante comum devido à sua versatilidade. O método é simples e consiste em mensurar as alterações em um cabo com um feixe de luz, essas perturbações podem ser resultado de variações na temperatura, vibrações ou tensões no cabo de fibra ótica (**Rejaili, 2015**).

No estudo de caso citado por **Nikles et al. (2004)**, a variação da temperatura é utilizada como métrica para a detecção de vazamento de salmoura. A tecnologia foi utilizada em uma tubulação de 55 km em Berlim, onde foram utilizados dois equipamentos (DiTeST) capazes de detectar a variação no comprimento de onda da fibra ótica. Este cabo foi instalado 10 cm abaixo da tubulação, para garantir que o vazamento seja detectado. Na **Figura 3** é mostrado o esquema da tubulação e dos equipamentos utilizados.

Figura 3. Exemplos de espectrômetros óticos



Fonte: **Nikles et al. (2004)**

Em operação normal, o escoamento acontece a uma temperatura de 8°C e a temperatura do solo onde a tubulação está instalada é aproximadamente 5°C, portanto, um aumento dessa temperatura estará associado a um

vazamento. Este projeto começou a operar em janeiro de 2003, e em julho do mesmo ano o sistema identificou o primeiro vazamento, oriundo de uma escavação que ocorria nas vizinhanças da tubulação.

3.2.2. MÉTODOS INTERNOS

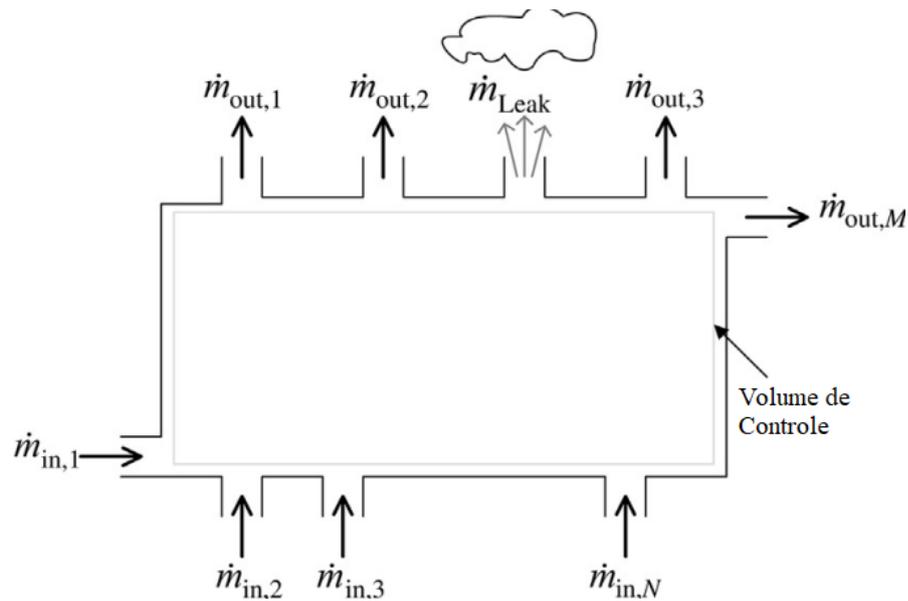
Os métodos internos são baseados em *software* e, portanto, faz-se necessário o uso de algoritmos, *softwares* e análises estatísticas para que a detecção do vazamento seja feita. Como exemplos tem-se o uso de balanço de massa ou volume, detecção de ondas de pressão negativa e análises estatísticas.

3.2.2.1. Balanço de massa ou volume

O princípio da conservação de massa é utilizado no método do balanço de massa ou volume. Através de variáveis de processo como vazão, pressão e temperatura a quantidade de matéria em uma tubulação pode ser calculada e caso a diferença entre as saídas e as entradas do sistema estiverem acima de um limite pré-determinado, um alarme pode ser acionado. (MURVAY; SILEA, 2012)

Segundo **Morgan (2016)**, o princípio de conservação de massa pode ser aplicável em qualquer tubulação ou porção dela, desde que seja possível determinar a quantidade de massa que entra e sai no volume de controle estudado, conforme mostrado na **Figura 4**. É importante ressaltar que para a maioria dos casos o fluxo de massa não é medido, mas sim, são realizadas medidas associadas a ele, tal como a vazão. Especificamente no caso de processos envolvendo petróleo, a unidade de medida mais frequentemente empregada é barris por hora ou dia, em condições padrão. Para casos em que há o escoamento de gases a medição em geral é feita utilizando-se unidades volumétricas, tal como pé cúbico por hora.

Ainda segundo **Morgan (2016)**, uma simples substituição dos termos de conservação de massa para variáveis de volume é útil para a maioria dos casos. Contudo, é de suma importância entender a validade dessa premissa e quando ela pode ser aplicada.

Figura 4. Volume de controle

Fonte: **Morgan (2016)**

Partindo do princípio da conservação da massa o somatório das vazões de entrada menos o somatório das vazões de saída (considerando o vazamento, caso exista) deve ser igual a variação da massa na tubulação, conforme **Equação 3** a seguir, onde \dot{m}_{in} caracteriza a taxa de massa que entra no sistema, \dot{m}_{out} a taxa de massa que sai do sistema e \dot{m}_{leak} a taxa mássica de vazamento:

$$\sum_{i=1}^N \dot{m}_{in,i} - \sum_{j=1}^M \dot{m}_{out,j} - \dot{m}_{leak,i} = \dot{m} \quad (3)$$

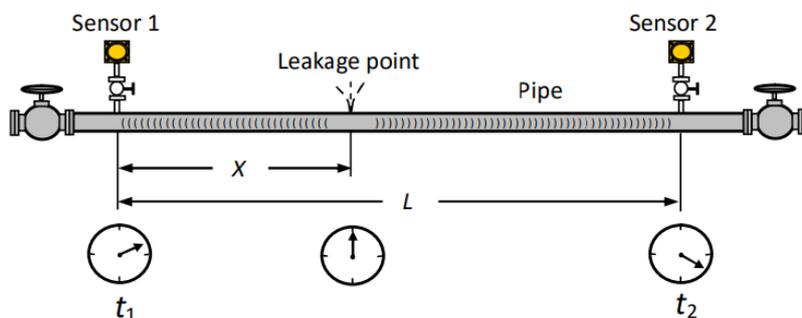
O autor também ressalta que este método consiste na contabilização de todo fluido que entra e sai no volume de controle pré-determinado. Na prática, em sistemas gasosos não há garantia de que todas as entradas e saídas são mensuradas e ainda que sejam, a aquisição dos dados pode não ocorrer em tempo real. Para líquidos também existem altos níveis de incerteza devido a imprecisão nas medidas. Dessa forma, essa metodologia está associada a incertezas que têm impacto na detecção de vazamentos.

3.2.2.2. Detecção de ondas de pressão negativa

A queda de pressão no local do vazamento também pode ser utilizada como forma de detecção, uma vez que uma onda é propagada em toda a tubulação. Através de um transdutor de pressão, instalado nas extremidades do tubo a onda de pressão negativa (*Negative Pressure Wave, NPW*) é gravada e algoritmos interpretam os sinais, sendo capazes de identificar o possível vazamento (**MURVAY; SILEA, 2012**).

Na **Figura 5** pode-se notar que em uma tubulação são utilizados dois sensores cuja distância entre eles é identificada por L . Um possível ponto de vazamento identificado encontra-se situado a uma distância X do sensor 1 e $(L - X)$ do sensor 2.

Figura 5. Representação do princípio de funcionamento do sistema de detecção de vazamento NPW.



Fonte: Wang et al. (2016).

O tempo de transmissão da NPW até o sensor 1 e até o sensor 2, considerando u como a velocidade do escoamento e v a velocidade de propagação da NPW, é calculado respectivamente pelas **Equações 4 e 5**:

$$t_1 = \frac{X}{v - u} \quad (4)$$

$$t_2 = \frac{L - X}{v + u} \quad (5)$$

O local do vazamento pode então determinado a partir do valor de X , na **Equação 6**, onde $\Delta t = t_1 - t_2$.

$$X = \frac{1}{2v} [L(v - u) + \Delta t(v^2 - u^2)] \quad (6)$$

Segundo **Wang et al. (2016)** a velocidade do escoamento, em geral, está compreendida entre 1 m/s e 3 m/s, enquanto a propagação da NPW tem uma velocidade entre 900 m/s e 1.200 m/s para óleo e 1.000 m/s a 1.500 m/s para água. Portanto, torna-se razoável, simplificar a **Equação 6** dando origem à **Equação 7**.

$$X = \frac{1}{2} (L + v\Delta t) \quad (7)$$

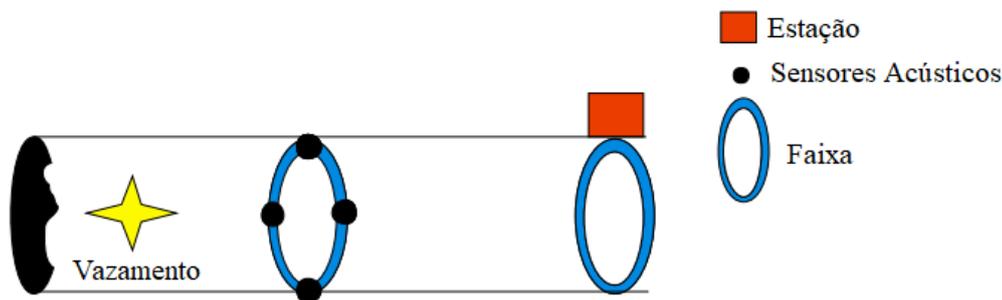
A partir da **Equação 7** é possível notar que a exatidão desse método está associada à distância entre os sensores, à velocidade da NPW e à diferença entre os tempos de trânsito entre os respectivos sensores. Tais fatores são importantes e na prática podem interferir no monitoramento dos vazamentos, pois o comprimento da tubulação (e, portanto, a distância entre os sensores) irá atenuar a propagação da NPW. Além disso, podem existir outras fontes de ondas de pressão, como bombas e alterações no processo.

3.2.2.3. Análise estatística

Outro método interno utilizado na detecção de vazamentos é a análise estatística. A tecnologia consiste na determinação de parâmetros como pressão e vazão em vários pontos da tubulação em diferentes estados de operação, a partir desses dados é gerado um padrão e se houver alterações significativas em uma dessas grandezas um alarme de vazamento é gerado. (**MURVAY; SILEA, 2012**).

Por exemplo, no trabalho de **Duru e Cosmas (2017)** são utilizados sensores acústicos em grupos fixados ao longo de uma tubulação, sendo que cada grupo possui 4 quatro destes sensores atrelados a uma faixa que também capta sinais acústicos. Além destes sensores, uma estação responsável por receber os sinais oriundos desses detectores é instalada no final da tubulação ou entre os grupos.

Figura 6. Representação do princípio de funcionamento do sistema de detecção de vazamento NPW utilizando em conjunto com método estatístico.



Fonte: **Duru e Cosmas (2017)**

Quando os sensores detectam que houve um vazamento, conforme mostrado na **Figura 6**, essa informação é enviada para a estação mais próxima que irá avaliar as informações recebidas. Essa avaliação consiste em analisar os sinais que se sobressaem aos ruídos, para isso é utilizado teste hipótese para avaliar a presença ou não de vazamento.

As seguintes hipóteses são adotadas:

- H_0 : ausência de sinais de vazamento no ruído captado;
- H_1 : presença de sinais de vazamento no ruído captado;

Para que a análise seja feita, uma modelagem dos sinais recebidos em operação normal é feita, com o intuito de captar ruídos da vizinhança e assim caracterizar o ambiente. Sob situações anômalas, haverá um distúrbio nessa modelagem, caracterizando um possível vazamento.

3.3. INDÚSTRIA 4.0

O conceito de Indústria 4.0 foi utilizado pela primeira vez em um artigo publicado em novembro de 2011 pelo governo alemão, como uma iniciativa estratégica. Também conhecido como quarta revolução industrial, esse movimento pressupõe mudanças disruptivas, que abrangem áreas de comunicação, manufatura, computação e automação, e estão atreladas ao desenvolvimento de novas tecnologias como *IoT*, *Big Data* e *Cloud Manufacturing* (**PEREIRA; ROMERO, 2017**).

Ainda segundo **Pereira & Romero (2017)**, a Indústria 4.0 ainda é um ponto de discussão entre acadêmicos e empresas, portanto não há um consenso sobre suas implicações e consequências. Diferente das outras revoluções industriais, essa 4ª revolução está sendo prevista e abre espaço para que as companhias se preparem e planejem formas de se adequar a esse novo paradigma.

Big Data é o termo em Tecnologia da Informação que trata sobre grandes conjuntos de dados que precisam ser processados e armazenados. *Big Data Analytics*, por outro lado, é a análise aprimorada de grandes quantidades de dados brutos para extrair informações e *insights* para um determinado negócio. O *Big Data Analytics*, um dos principais pilares da Indústria 4.0, é uma tecnologia relativamente nova na indústria energética, embora já seja utilizada em outras indústrias. Atualmente, grande parte dos investimentos no setor de óleo e gás estão direcionados para operações de baixo custo pautadas no uso de soluções envolvendo *Big Data* e *IoT*. Essas ferramentas possuem grande capacidade de transformação no setor energético, através delas é possível prever comportamentos operacionais e fundamentar tomadas de decisão (**EISSA, 2020**).

Segundo **Eissa (2020)**, a detecção de vazamentos em tubulações tem sido potencializada pelo uso das ferramentas citadas anteriormente. A localização precisa de um vazamento é crucial para uma operação segura, e métodos tradicionais de detecção podem gerar falsos alarmes, são afetados por condições ambientais e possuem alto custo de implementação. Por outro lado, o grande volume de dados captados durante um processo pode ser utilizado e através do aprendizado de máquina, prever vazamentos.

3.4. APRENDIZADO DE MÁQUINA E SUAS APLICAÇÕES PARA A DETECÇÃO DE VAZAMENTOS

Segundo **Lenz e colaboradores (2020)**, o aprendizado de máquina consiste na determinação de parâmetros e regras que relacionam as variáveis presentes em um conjunto de dados. A criação deste modelo é feita através da inserção de exemplos já validados de entrada e saída que, a partir de um

algoritmo criado pelo desenvolvedor, irão resultar em parâmetros que serão, juntamente com os novos atributos de entrada, utilizados para a previsão de atributos alvo. Por fim, espera-se que o algoritmo criado seja capaz de melhorar seu desempenho conforme novos dados são inseridos no sistema.

Em um modelo de aprendizado de máquina onde um determinado conjunto de atributos (variáveis de entrada) tenha sido previamente classificado (variável de saída) seja por um indivíduo ou por uma máquina, diz-se que esse modelo é do tipo supervisionado, uma vez que a aprendizagem do modelo pressupõe um conhecimento prévio que orienta as previsões. A previsão de preços de um determinado bem ou o diagnóstico de doenças são exemplos de aprendizado supervisionado (**LENZ et al., 2020**).

A aprendizagem de máquina pressupõe ainda a definição do tipo de tarefa a ser aprendida pelo algoritmo. Denomina-se problema de classificação quando a variável de saída representa um conjunto limitado de valores nominais e não ordenados. Entretanto, se a variável resposta consiste em um conjunto infinito de valores, caracteriza-se como um problema de regressão (**FACELI et al., 2011**).

Por fim, é necessário que o modelo criado possa ser de alguma forma treinado e avaliado. Para isso **Stevens et al. (2020)** sugere que os dados sejam separados em dois conjuntos, um para treino e outra para validação (também chamado conjunto de teste). Dessa forma, é possível utilizar métricas de avaliação em ambos os conjuntos e avaliar o melhor modelo a ser utilizado.

Um estudo realizado por **da Cruz et al. (2020)** na Universidade Estadual de Campinas utilizou algoritmos de *machine learning* combinados com sensores acústicos para identificar e localizar vazamentos em tubulações de baixa pressão. Um aparato experimental foi utilizado para a captação de dados que foram posteriormente tratados e utilizados para treinamento dos algoritmos. Foram utilizadas técnicas baseadas em árvores de decisão (*AdaBoost*, *Extreme Gradient Boost* e *Random Forest*) e também de classificação (*KNN* e regressão logística) cujo principal objetivo era detectar pequenos vazamentos e reduzir alarmes falsos na presença de perturbações. Os resultados mostraram que 99,6% dos vazamentos foram identificados e a taxa de alarmes falsos foi de

0,3%, indicando, portanto, uma forma eficiente e confiável de monitorar linhas de baixa pressão.

Em alguns casos, a obtenção de dados reais ou experimentais pode não ser tão simples. **Kim et al. (2021)** propuseram o desenvolvimento de um modelo de detecção de vazamento para tubulações submarinas a partir de uma modelagem dinâmica. O conjunto de dados foi gerado através de diversas simulações feitas e utilizado em um modelo de *deep neural network* para treinamento e otimização. O algoritmo apresentou excelentes resultados, com erros de detecção menores que 50 metros.

4. ESTUDO DE CASO

Para ilustrar uma aplicação de uso de algoritmos de aprendizado de máquina para detecção de vazamentos. Este trabalho de conclusão de curso apresentará uma reavaliação dos dados apresentados por **Eastvedt e colaboradores (2022)**. No referencial citado as relações entre as mudanças de pressão, velocidade e temperatura do petróleo bruto através de um oleoduto foi estudada através de técnicas de regressão.

No artigo citado, dados representativos da vazão de petróleo bruto foram gerados via simulações do tipo fluidodinâmica computacional (CFD). Estes dados foram utilizados para treinar um algoritmo visando ao desenvolver um modelo de comportamento do fluido sob tubulação. Foram simuladas tanto condições de fluxo normal, quanto condições de fluxo atípicas, supondo vazamentos.

Os dados de CFD contendo vazamentos foram coletados sob várias condições de falha simuladas: vazamentos de 10% e 20% da vazão volumétrica, e restrição de vazão de 50%, pela área nominal da seção transversal da tubulação. O estudo demonstrou que algoritmos de aprendizado de máquina podem ser treinados para modelar o sistema tanto sob condições normais quanto em falha. Ou seja, métodos de aprendizado de máquina podem ser seguros, de baixo custo e precisos para o monitoramento de uma tubulação submarina para desempenho ideal e detecção de falhas sem a necessidade de introduzir

equipamentos especiais para uma rede de dutos submarinos, proporcionando uma via para maior segurança do processo e proteção dos ambientes oceânicos.

4.1. Detalhes sobre a simulação computacional

Para realização da análise de dados e regressão com modelo de aprendizado de máquina foi empregado o *software* online **Google Colaboratory** em ambiente de programação com linguagem Python (versão 3.7.13). As principais bibliotecas de uso foram `numpy`², `matplotlib`³, `seaborn`⁴ e `pandas`⁵.

Neste trabalho, biblioteca `scikit-learn`⁶ foi empregada para implementação dos algoritmos de aprendizado de máquina, a saber:

- Regressão múltipla e polinomial;
- K-vizinhos mais próximos (KNN).

Segundo **Walpole et al. (2011)**, a regressão linear consiste em encontrar a melhor relação entre duas variáveis x e y de forma que o erro entre a variável real (y) e a variável predita (\hat{y}) seja mínimo. Na **Equação 8** é apresentada um modelo de regressão linear simples, onde β_0 e β_1 são os coeficientes de regressão.

$$\hat{y} = \beta_0 + \beta_1 x_1 \quad (8)$$

Freqüentemente os mecanismos científicos estudados apresentam certa complexidade e, portanto, um modelo de regressão linear múltipla é necessário. Neste caso, o valor predito de y será expresso pela **Equação 9**, onde \hat{y} é o valor predito, β são os coeficientes de regressão das k variáveis x que representam o modelo.

$$\hat{y} = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k \quad (9)$$

² <https://numpy.org/>

³ <https://matplotlib.org/>

⁴ <https://seaborn.pydata.org/>

⁵ <https://pandas.pydata.org/>

⁶ <https://scikit-learn.org/stable/>

Estimar o modelo de regressão múltipla consiste então na determinação dos parâmetros β , para isso o conceito de residual (expresso por $y - \hat{y}$) é aplicado no método dos mínimos quadrados visando minimizar o resíduo e assim otimizar os coeficientes de regressão.

Existem ainda situações em que, mesmo que só exista uma variável dependente, uma reta não represente de forma adequada o fenômeno estudado. Nesse caso, o método dos mínimos quadrados também pode ser utilizado para a determinação dos coeficientes de regressão do modelo expresso pela **Equação 10**, onde r determina o grau da regressão polinomial.

$$\hat{y} = \beta_0 + \beta_1 x_1 + \beta_2 x^2 + \dots + \beta_r x^r \quad (10)$$

- Classificação com os k-vizinhos mais próximos (KNN):

O algoritmo KNN (*K Nearest Neighbor*) é baseado em instâncias e a partir dos dados de treinamento armazenados, busca classificar um novo elemento. O procedimento consiste no cálculo dos K vizinhos mais próximos através de seus atributos utilizando-se da distância Euclidiana para as n características de um determinado evento. A nova instância será categorizada de acordo com a classificação mais comum entre os vizinhos mais próximos a ela (**COPPIN, 2013**).

Na **Equação 11**, proposta por **Faceli e colaboradores (2011)** é apresentado o cálculo da distância entre instâncias, onde x_i e x_j são os dois objetos, com d atributos, cuja distância será calculada.

$$d(x_i, x_j) = \sqrt{\sum_{L=1}^d (x_i^L - x_j^L)^2} \quad (11)$$

Segundo **Faceli e colaboradores (2011)**, o algoritmo apresenta pontos positivos, devido ao fato de ser de fácil treinamento, é aplicável para problemas complexos, é incremental, ou seja, quando novos exemplos surgem, basta acrescentá-los ao conjunto de treinamento. Entretanto, há também aspectos

negativos como o esforço computacional durante a predição, uma vez que é necessário calcular a distância a todos as instâncias treinadas, outro ponto a ser observado é a dimensionalidade de cada objeto, pois o número de atributos é proporcional a dimensão (n). O aumento da dimensionalidade, segundo **Beyer et al (1997)**, faz com que a distância do vizinho próximo se aproxime da distância de um vizinho afastado.

Os algoritmos de regressão foram empregados para avaliação das condições normais de operação dos dutos e os de classificação para as atípicas. Detalhes sobre os procedimentos empregados, bem como os diferenciais em relação ao procedimento original empregado por **Eastvedt e colaboradores (2022)** são apresentados nos itens 4.2 e 4.3.

Para o uso do modelo de aprendizado de máquina supervisionado, 20% do banco de dados foi separado para o conjunto de teste e 80% para o conjunto de treino. Esta proporção é amplamente aceita pela comunidade científica (**Zhao et al. 2021**) e foi calibrada por meio de testes preliminares realizados

4.2. Operação de dutos em condições normais

Com o intuito de simular a operação em condições normais, **Eastvedt e colaboradores (2022)** realizaram uma simulação de escoamento de petróleo bruto com temperaturas em uma faixa entre 11 °C e 51°C e velocidades entre 0 m/s e 1,85 m/s, e coletaram os valores de pressão e temperatura observados em dois pontos arbitrários, um a 50 metros do início da tubulação (ponto 1) e outro a 200 metros (ponto 2), fixos e distantes suficientes da entrada para garantir um regime de escoamento plenamente desenvolvido.

Eastvedt e colaboradores (2022) utilizaram o conjunto de dados gerado em um algoritmo de aprendizado de máquina. Foram gerados modelos de regressão dos valores de pressão (p) em função da temperatura (T) e velocidade (U) e também de ΔU em função de Δp , conforme **Equação 12** e **13**, respectivamente, onde R^2 é o coeficiente de determinação para os dados de treino:

$$\Delta p = 2,301T^{0,0893}U^2 + 37,677T^{1,0744}U, R^2 = 0,998 \quad (12)$$

$$\Delta U = 0.000009224\Delta P + 0.00007615, R^2 = 0,97 \quad (13)$$

Os dados utilizados por **Eastvedt e colaboradores (2022)** foram analisados neste trabalho com o intuito de compreender a dependência entre as variáveis do processo e então obter um modelo de queda de pressão a partir do processo de regressão múltipla. O coeficiente de determinação demonstra um ajuste muito forte do modelo aos dados de treinamento. Este resultado indica que o modelo previu com precisão os valores Δp no conjunto de teste dadas as respectivas temperaturas e velocidades do ponto 1.

Para exemplificar como pode-se encontrar novas equações, o presente trabalho de conclusão de curso avaliou a relação linear entre as variáveis de interesse. A partir da função *corr* da biblioteca *pandas*⁷ foi possível obter a correlação de Pearson entre as variáveis, conforme **Tabela 1**.

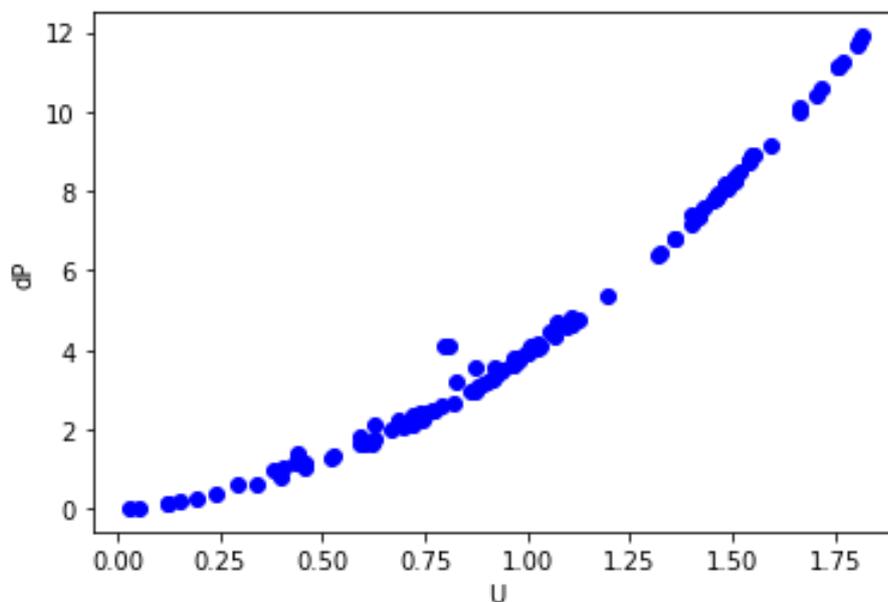
Tabela 1. Correlação entre as variáveis temperatura (*T*), velocidade (*U*) e pressão (*p*).

	U	T	Δp
U	1,000	0,495	0,974
T	0,495	1,000	0,411
Δp	0,974	0,411	1,000

Observa-se uma clara dependência linear entre as variáveis de pressão e velocidade, que também pode ser observada através do gráfico de dispersão na **Figura 7**.

⁷ <https://pandas.pydata.org/pandas-docs/stable/reference/api/pandas.DataFrame.corr.html>

Figura 7. Gráfico de dispersão que relaciona a queda de pressão (Δp) com a velocidade de escoamento (U).



Fonte: Eastvedt et al. (2020).

Utilizando-se o método de regressão múltipla linear é possível obter a **Equação 14**, onde p é pressão em função da temperatura (T), velocidade (U) e R^2 é o coeficiente de determinação para os dados de treino.

$$\Delta p = -1,248 - 0,038T + 7,325U, R^2 = 0,955 \quad (14)$$

Obviamente, o ajuste acompanha maiores imprecisões que o modelo original, uma vez que Δp e T não variam linearmente como apresentado na **Tabela 1**. Além disso, a modelagem mostrou-se sobreajuste, pois para o conjunto de teste o coeficiente de determinação foi de 0,908.

Uma alternativa seria aplicar uma regressão polinomial⁸ aos dados, conforme **Equação 15**. Uma aplicação de polinômio de segundo grau permite incrementar o ajuste dos dados, como apresentado na **Equação 15** e eliminar o sobreajuste obtendo para o conjunto de teste R^2 igual a 0,9996.

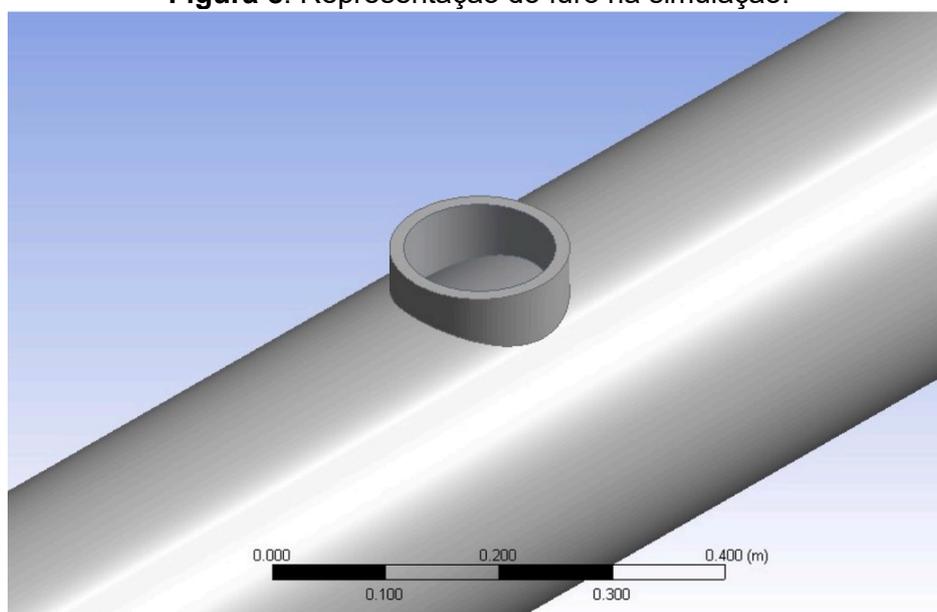
$$\Delta p = 0,768T^2 + 3,1087U^2, R^2 = 0,9996 \quad (15)$$

⁸ <https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.PolynomialFeatures.html>

4.3. Operação de dutos em condições de falha

No estudo de **Eastvedt e colaboradores (2022)**, as condições de falha na operação foram simuladas através da modelagem de um furo, apresentado na **Figura 8**, de 0,134 m, que representa 20% da área da seção transversal do tubo e também equidistante dos pontos 1 e 2 citados anteriormente. As velocidades e temperaturas foram mantidas no intervalo de operação normal e três condições de pressão externa (-500 Pa, 0 Pa e 500 Pa) foram implementadas à simulação com a finalidade de observar os efeitos dessa variável no escoamento.

Figura 8. Representação do furo na simulação.



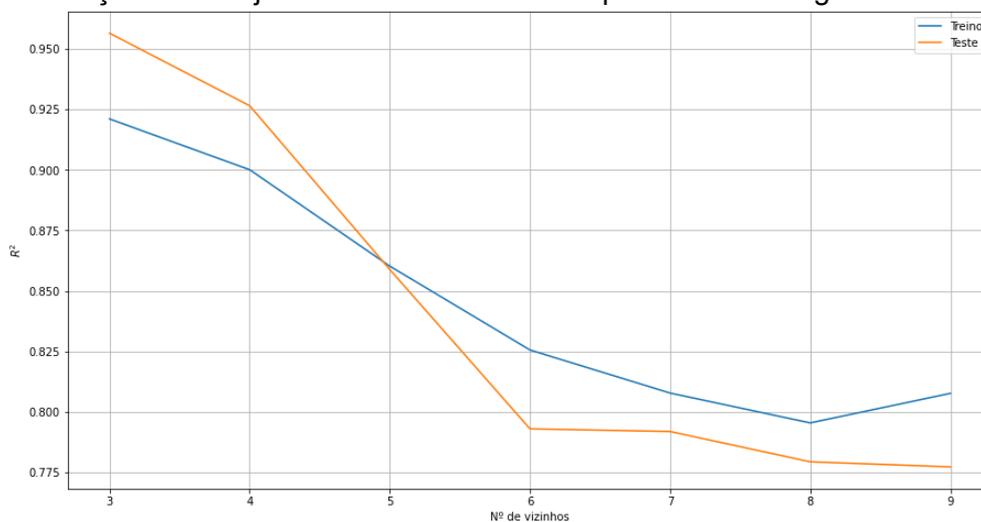
Fonte: **Eastvedt et al (2022)**

Durante a simulação da operação em condições de falha os valores de ΔU foram coletados e em caso de não conformidade com a **Equação 13** existe a possibilidade de vazamento.

A **Equação 13** foi suficiente para detectar comportamentos atípicos da velocidade devido as variações de pressão impostas. Observa-se que os autores optaram pela aplicação de um algoritmo de aprendizagem por regressão para verificar o desvio da velocidade desejada. Uma alternativa seria criar um algoritmo de aprendizagem por classificação. Na classificação binária, um algoritmo poderia indicar a operação conforme (saída igual a 0) e não-conforme (saída igual a 1).

Nesse sentido, os dados consultados no artigo de **Eastvedt e colaboradores (2022)** foram coletados (relacionando pressão e velocidade de escoamento), sendo 69 dados reportando condições de operação normal e 28 em condições de falha (com vazamentos). Foi aplicado o algoritmo KNN aplicando-se a distância euclidiana como metodologia de cálculo das distâncias entre os k-vizinhos. O gráfico que relaciona o número de k-vizinhos e o coeficiente de correlação obtido para os conjuntos de treino e teste é apresentado na **Figura 9**. Nota-se que k-vizinhos = 3 representa a melhor configuração para o modelo.

Figura 3. Coeficiente de determinação como função do número de k-vizinhos para a representação dos conjuntos de treino e teste do problema de diagnóstico de falha.



Fonte: Autoria própria (2023).

5. CONSIDERAÇÕES FINAIS

Este trabalho de conclusão de curso apresentou uma revisão sobre os métodos de detecção de vazamento de líquidos em tubulações. Foram revisados os métodos externos e internos de detecção, bem como também se discorreu sobre as formas de se avaliar vazamentos através de algoritmos de aprendizado de máquina.

Na quarta revolução industrial, também conhecida como Indústria 4.0, todos estes métodos podem ser utilizados de forma sinérgica. Uma vez que sensores são necessários para obtenção de dados sobre o funcionamento do processo e auxiliam no monitoramento dos parâmetros operacionais alvo. Estes dados, por sua vez, são a base para os chamados algoritmos de aprendizado de máquina, aos quais são indicados para identificar correlação complexas entre as variáveis de processo.

6. REFERÊNCIA BIBLIOGRÁFICA

BELSITO Salvatore. et al. **Leak Detection in Liquefied Gas Pipelines by Artificial Neural Networks**. 1998

Beyer, Kevin. et al. **When is "nearest neighbor" meaningful?** 1997

BRUNETTI, Franco. **Mecânica dos Fluidos**. 2 ed. Pearson, 2008

BWTEK A METROHM GROUP COMPANY. **NanoRam® 1064 – BWT-840000953**. Disponível em: <https://bwtek.com/products/nanoram-1064/>. Acesso em: 15 out. 2022.

CROCOMBE, Richard A. **Portable Spectroscopy**. 2018

DURGIN, Philip B.; YOUNG, Thomas M. **Leak detection for underground storage tanks**. ASTM, 1993

EASTVEDT, Daniel. et al. **Detection of faults in subsea pipelines by flow monitoring with regression supervised machine learning**. 2022. Elsevier: Process Safety and Environmental Protection.

EISSA, Haidy. **Unleashing Industry 4.0 Opportunities: Big Data Analytics in the Midstream Oil & Gas Sector**. 2020

da Cruz, Rodolfo P. et al. **Machine learning and acoustic method applied to leak detection and location in low-pressure gas pipelines**. 2020. Clean Technologies and Environmental Policy.

DURU, Chinedu; COSMAS, Ani. **A statistical analysis on the leak detection performance of underground and overground pipelines with wireless sensor networks through the maximum likelihood ratio test**. 2017

FACELI, Katti. et al. **Inteligência Artificial: Uma Abordagem de Aprendizagem de Máquina**. LTC, 2011

HARRIS, Fan. et al. **Acoustic leak detection approaches for water pipelines**. 2022. Elsevier: Automation in Construction.

HENRIE, Morgan. et al. **Pipeline Leak Detection Handbook**. Elsevier, 2016.

HOSMER, David W. et al. **Applied Logistic Regression**. 3 ed. John Wiley & Sons, 2013

HT CONTROLS COLLING & HEATING. **Detector de gases**. Disponível em: <<https://www.hantechbrasil.com.br/detector-de-gases.php>>. Acesso em: 15 out. 2022.

KIM, Juhyun. et al. **The development of leak detection model in subsea gas pipeline using machine learning**. 2021. Elsevier: Journal of Natural Gas Science and Engineering.

KINGSBOROUGH, Richard P. et al. **Colourimetry for the sensitive detection of vapour-phase chemicals: State of the art and future trends**. 2021. Elsevier: Trends in Analytical Chemistry.

MALEKPOUR, Ahmad; SHE Yuntong. **Real-time leak detection in oil pipelines using an Inverse Transient Analysis model**. 2021

MANDAL, Santosh K. et al. **Leak detection of pipeline: An integrated approach of rough set theory and artificial bee colony trained SVM**. 2012. Elsevier: Expert Systems with Applications.

MEHDIYEV, Shakir; FATALIYEVA, Tahmasib. **Industry 4.0: The Oil and Gas Sector Security and Personal Data Protection**. 2020

MURVAY, Pal-Stefan; SILEA, Ioan. **A survey on gas leak detection and localization techniques**. 2012

NCS TESTING INSTRUMENTS. **Portable xrf spectrometer**. Disponível em <http://english.ncs-instrument.com/products-114.html>. Acesso em: 15 out. 2022.

NIKLES, Marc. et al. **Leakage detection using fiber optics distributed temperature monitoring**. 2004

PEREIRA, A.C.; ROMERO, F. **A review of the meanings and the implications of the Industry 4.0 concept**. 2017

REJAILI, Rodrigo. **Análise de métodos de detecção de vazamento com foco em operações de offloading**. 2015

SANDERS, Roy E. **Chemical Process Safety. Learning from Case Histories.** 3 ed. Elsevier, 2005.

STEVENS, Eli. et al. **Deep Learning with PyTorch.** Manning, 2020

WALPOLE, Ronald E. et al. **Probability & Statistics for Engineers & Scientists.** 9 ed. Pearson, 2011

WANG, Jiqiang. et al. **Novel Negative Pressure Wave-based Pipeline Leak Detection System Using Fiber Bragg Grating-based Pressure Sensors.** 2016. Journal of Lightwave Technology

WEI, Liang. et al. **Gas pipeline leakage detection based on acoustic technology.** 2013. Elsevier: Engineering Failure Analysis

Zhao, Jake. et al. **A critical look at the current train/test split in machine learning.** 2021