



UNIVERSIDADE FEDERAL DE PERNAMBUCO  
CENTRO DE INFORMÁTICA  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

José Rafael de Santana

**Avaliação de risco em tempo real utilizando séries temporais:** Um estudo de caso de  
um vaso knockout

Recife

2024

José Rafael de Santana

**Avaliação de risco em tempo real utilizando séries temporais:** Um estudo de caso de um vaso knockout

Dissertação apresentada ao Programa de Pós-graduação em Ciência da Computação da Universidade Federal de Pernambuco, como requisito parcial para obtenção do grau de mestre em Ciência da Computação.

**Área de Concentração:** Engenharia da Computação

**Orientador (a):** Edna Natividade da Silva Barros

Recife

2024

Catálogo na fonte  
Bibliotecária: Luiza de Oliveira/CRB1316

S232a Santana, José Rafael de.

Avaliação de risco em tempo real utilizando séries temporais: um estudo de caso de um vaso knockout / José Rafael de Santana.– 2024.  
91 f.: il.

Orientadora: Edna Natividade da Silva Barros.  
Dissertação (Mestrado) – Universidade Federal de Pernambuco. Centro de Informática. Programa de Pós-graduação em Ciência da Computação, Recife, 2024.  
Inclui referências e apêndice.

1. Gêmeos digitais. 2. Análise de risco. 3. Séries temporais. 4. Aprendizagem de máquina. I. Barros, Edna Natividade da Silva. II. Título

621.39

CDD (23. ed.)

UFPE - CCEN 2024 – 65

José Rafael de Santana

**Avaliação de risco em tempo real utilizando séries temporais: Um estudo de caso de um vaso knockout**

Dissertação apresentada ao Programa de Pós Graduação em Ciência da Computação da Universidade Federal de Pernambuco, como requisito para a obtenção do título de Mestre em Ciência da Computação. Área de concentração: Engenharia da Computação.

Aprovado em: 20 de maio de 2024.

**BANCA EXAMINADORA**

---

Profª. Dra. Edna Natividade da Silva Barros (Orientadora)  
Universidade Federal de Pernambuco - UFPE

---

Prof. Dr. Cleber Zanchettin (Examinador Interno)  
Universidade Federal de Pernambuco - UFPE

---

Prof. Dr. Heleno Bispo da Silva Junior (Examinador Externo)  
Universidade Federal de Campina Grande - UFCG

## AGRADECIMENTOS

Agradeço a Deus por todas as oportunidades que Ele me tem dado, pela força durante os momentos difíceis, por toda a proteção e paciência nos momentos em que mais precisei. Sei que minhas orações foram atendidas e este momento é uma prova disso.

Agradeço também à minha família: minha mãe, Iolanda; meu pai, José Edson; e meu irmão, Edson Júnior, que me deram todo o suporte necessário para enfrentar mais esse desafio, mantendo-me motivado durante todo o percurso. À minha namorada, Amanda, pelo companheirismo, pelos conselhos valiosos e por sempre caminhar ao meu lado durante minha trajetória.

Agradeço à minha orientadora, Edna Natividade, e ao Professor Paulo Estevão, pesquisador visitante do PRH-ANP-FINEP-38.1, pelo tempo dedicado, e principalmente por me guiarem e estarem sempre à disposição para tirar dúvidas e dar sugestões. Também expresso minha gratidão ao Professor Heleno Bispo e à AVEVA por fornecerem licenças acadêmicas dos softwares, o que viabilizou a realização da pesquisa, além de oferecerem suporte na resolução de problemas.

Agradeço também a todos aqueles que, de forma direta ou indireta, me auxiliaram para que eu pudesse desenvolver os trabalhos relacionados a esta pesquisa.

## RESUMO

Com a ascensão da Internet Industrial das Coisas (IIoT), as indústrias estão cada vez mais conectadas. A coleta e armazenamento de dados relacionados ao funcionamento dos equipamentos e processos de produção tornaram-se requisitos indispensáveis, permitindo a realização de análises e tomadas de decisão para otimizar seu desempenho em tempo real. Simultaneamente, o desenvolvimento de gêmeos digitais possibilita a avaliação dessas otimizações em um ambiente virtual e de forma segura, visando analisar sua eficácia sem comprometer o ambiente de produção real. Podemos aplicar essas técnicas em conjunto com modelos de inteligência artificial para realizar a análise de risco de sistemas de produção cada vez mais complexos. Embora modelos probabilísticos sejam frequentemente utilizados para calcular a probabilidade de eventos indesejáveis, podem demandar conhecimento especializado e oferecer pouca flexibilidade no apoio à decisão. Por outro lado, modelos de aprendizado de máquina podem ser construídos utilizando dados históricos como base de treinamento, capturando as relações entre as variáveis e as características do contexto em que o equipamento está inserido. Assim, esses modelos auxiliam na prevenção de eventos indesejados por meio de inferências em tempo real, fornecendo informações aos operadores de forma oportuna para apoiar a tomada de decisões. Vasos knockout são dispositivos físicos de engenharia capazes de evitar a presença de líquido em sistemas projetados para trabalhar com produtos na fase gasosa. O presente trabalho tem como objetivo apresentar uma técnica para avaliação de risco através de séries temporais. Por meio de um estudo de caso de um vaso knockout no contexto de uma refinaria de petróleo, construímos um gêmeo digital e treinamos uma rede neural para inferir o comportamento futuro do nível de líquido nesse vaso. Dessa maneira, os operadores podem tomar decisões preventivas para evitar que o nível líquido atinja o máximo permitido, prevenindo eventos que comprometam a segurança da operação. Nossa técnica demonstrou resultados satisfatórios, sendo capaz de evitar a ocorrência de paradas não programadas do sistema de fluxo de gás natural nos casos analisados em nossos testes, além de mostrar robustez em cenários onde os sensores apresentam ruídos em suas leituras.

**Palavras-chaves:** gêmeos digitais; análise de risco; séries temporais; aprendizagem de máquina.

## ABSTRACT

Industries are increasingly connected with the rise of the Industrial Internet of Things (IIoT). The collection and storage of data related to the operation of the equipment and production processes have become indispensable requirements, allowing analyses and decision-making to optimize their performance in real-time. At the same time, the development of digital twins makes it possible to evaluate these optimizations in a virtual environment and a secure manner, aiming to analyze their effectiveness without compromising the real production environment. We can apply these techniques with artificial intelligence models to perform risk analysis of increasingly complex production systems. Although probabilistic models are often used to calculate the probability of undesirable events, they can require specialized knowledge and offer little flexibility in decision support. On the other hand, machine learning models can be built using historical data as a training base, capturing the relationships between variables and the characteristics of the context in which the equipment is inserted. Thus, these models can help prevent unwanted events through real-time inferences, providing information to operators to support decision-making. Knockout drums are physical engineering devices capable of avoiding the presence of liquid in systems designed to work with products in the gas phase. The present work aims to present a technique for risk assessment through time series. Through a case study of a knockout drum in the context of an oil refinery, we built a digital twin and trained a neural network to infer the future behavior of the liquid level in this drum. In this way, operators can make preventive decisions to prevent the fluid level from reaching the maximum allowed and, mainly, prevent events that compromise the safety of the operation. Our technique demonstrated satisfactory results, avoiding unscheduled stops in the natural gas flow system in the cases analyzed in our tests and showing robustness in scenarios where the sensors present noise in their readings.

**Keywords:** digital twins; risk analysis; time series; machine learning.

## LISTA DE FIGURAS

Figura 1 – Exemplo genérico de um diagrama bow-tie . . . . .	19
Figura 2 – Modelo do queijo suíço. . . . .	20
Figura 3 – Marketshare global dos gêmeos digitais em 2022 . . . . .	23
Figura 4 – Linha do tempo das revoluções industriais. . . . .	24
Figura 5 – Principais áreas de aplicação de gêmeos digitais na indústria de petróleo e gás . . . . .	26
Figura 6 – Diagrama geral de um gêmeo digital no refino de petróleo e gás . . . . .	27
Figura 7 – Framework proposto para o desenvolvimento de gêmeos digitais na indústria petroquímica . . . . .	28
Figura 8 – Exemplo de uma rede bayesiana genérica. . . . .	30
Figura 9 – Forma da função tangente hiperbólica. . . . .	32
Figura 10 – Comportamento da função ReLU. . . . .	33
Figura 11 – Exemplo de arquitetura de rede com camadas totalmente conectadas. . . . .	35
Figura 12 – Arquitetura interna de uma célula LSTM . . . . .	36
Figura 13 – Arquitetura interna de uma célula GRU . . . . .	38
Figura 14 – Em (a) um exemplo de um modelo de rede neural sem o uso do <i>dropout</i> . Em (b) o mesmo modelo, porém utilizando a técnica de <i>dropout</i> entre as camadas ocultas. . . . .	39
Figura 15 – Diagrama de Tubulação e Instrumentação de um sistema flare . . . . .	44
Figura 16 – Módulos para extração de dados de treinamento . . . . .	52
Figura 17 – Módulos para predição de riscos em tempo real . . . . .	52
Figura 18 – Diagrama simplificado do funcionamento de um vaso knockout . . . . .	54
Figura 19 – Diagrama bow-tie do vaso knockout . . . . .	55
Figura 20 – Modelo do vaso knockout no Aveva Dynamic Simulation . . . . .	58
Figura 21 – Diagrama de comunicação cliente-servidor do padrão OPC-DA . . . . .	60
Figura 22 – Ciclo de vida dos estágios da metodologia CRISP-DM. . . . .	62
Figura 23 – Arquitetura do modelo proposto. . . . .	66
Figura 24 – Gráficos dos valores da função de perda durante o treinamento. Em (a), a taxa de dropout foi configurada como 0.0, enquanto em (b) foi ajustada para 0.2. . . . .	69

Figura 25 – Interface de visualização do estado atual da simulação e dos valores inferidos pelo modelo . . . . .	72
Figura 26 – Captura de tela do gráfico de comportamento do nível do líquido durante os testes de prevenção do trip . . . . .	76
Figura 27 – Gráfico com o comportamento real e o inferido pelo modelo durante a simulação de vazamento . . . . .	77
Figura 28 – Comportamento do nível do líquido durante os testes de falha nos transmissores de nível . . . . .	77
Figura 29 – Comportamento do nível do líquido durante a inserção de ruídos na taxa de fluxo do tubo S6 . . . . .	78
Figura 30 – Comportamento do gráfico quando simuladas falhas nos transmissores e ruídos na taxa de fluxo do tubo S6 . . . . .	79

## LISTA DE TABELAS

Tabela 1 – Visão geral dos trabalhos relacionados . . . . .	49
Tabela 2 – Composição do gás natural proveniente dos processos de refino de petróleo	58
Tabela 3 – Análise dos valores de probabilidades para a geração das entradas do modelo virtual . . . . .	64
Tabela 4 – Análise dos hiperparâmetros avaliados . . . . .	68
Tabela 5 – Análise da dimensionalidade das séries temporais aplicadas no treinamento do modelo . . . . .	70
Tabela 6 – Resultado das análises das funções de ativação nas camadas LSTM . . . .	71
Tabela 7 – Resultados alcançados pelos modelos de RNNs após o treinamento em nosso conjunto de dados . . . . .	71
Tabela 8 – Visão geral do estado da arte . . . . .	82

## LISTA DE ABREVIATURAS E SIGLAS

<b>ADAM</b>	Adaptive Moment Estimation
<b>CRISP-DM</b>	Cross Industry Standard Process for Data Mining
<b>DT</b>	Digital Twin
<b>DTE</b>	Digital Twin Environment
<b>DTI</b>	Digital Twin Instance
<b>DTP</b>	Digital Twin Prototype
<b>ERP</b>	Sistemas Integrados de Gestão Empresarial
<b>FC</b>	Fully Connected Layers
<b>FFNN</b>	Rede Neural Feed-Forward
<b>GRU</b>	Gated Recurrent Unit
<b>IIoT</b>	Internet Industrial das Coisas
<b>LSTM</b>	Long Short-Term Memory
<b>MES</b>	Sistemas de Execução de Manufatura
<b>OPC-DA</b>	OLE for Process Control - Data Access
<b>PLM</b>	Gerenciamento do Ciclo de Vida do Produto
<b>ReLU</b>	Rectified Linear Unit
<b>RNAs</b>	Redes Neurais Artificiais
<b>RNNs</b>	Redes Neurais Recorrentes
<b>SCADA</b>	Sistemas de Supervisão e Aquisição de Dados
<b>Seq-2-Seq</b>	Sequence-to-Sequence
<b>SGD</b>	Stochastic Gradient Descent

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>13</b>
1.1	MOTIVAÇÃO	13
1.2	PROBLEMA DA PESQUISA	14
1.3	OBJETIVOS	16
1.4	ORGANIZAÇÃO DO TRABALHO	17
<b>2</b>	<b>REFERENCIAL TEÓRICO</b>	<b>18</b>
2.1	SEGURANÇA DOS PROCESSOS NA INDÚSTRIA DE REFINO DE PETRÓLEO	18
<b>2.1.1</b>	<b>Diagrama bow-tie</b>	<b>18</b>
<b>2.1.2</b>	<b>Modelo do queijo suíço</b>	<b>20</b>
2.2	GÊMEOS DIGITAIS	21
<b>2.2.1</b>	<b>Indústria 4.0</b>	<b>23</b>
<b>2.2.2</b>	<b>Gêmeos digitais na indústria de petróleo e gás</b>	<b>25</b>
<b>2.2.3</b>	<b>Frameworks para desenvolvimento de gêmeos digitais</b>	<b>27</b>
2.3	REDES BAYESIANAS	28
2.4	REDES NEURAIS ARTIFICIAIS	30
<b>2.4.1</b>	<b>Funções de ativação</b>	<b>31</b>
2.4.1.1	<i>Tangente Hiperbólica</i>	31
2.4.1.2	<i>ReLU</i>	32
<b>2.4.2</b>	<b>Normalização</b>	<b>33</b>
2.4.2.1	<i>MinMax</i>	34
<b>2.4.3</b>	<b>Camadas de aprendizagem profunda</b>	<b>34</b>
2.4.3.1	<i>Fully Connected Layers (FC)</i>	34
2.4.3.2	<i>Long Short-Term Memory (LSTM)</i>	36
2.4.3.3	<i>Gated Recurrent Unit (GRU)</i>	37
<b>2.4.4</b>	<b>Regularização</b>	<b>38</b>
2.4.4.1	<i>Dropout</i>	39
2.4.4.2	<i>Regularização L2</i>	39
2.4.4.3	<i>Early Stopping</i>	40
<b>2.4.5</b>	<b>Otimizadores</b>	<b>40</b>

2.4.5.1	<i>Stochastic Gradient Descent (SGD)</i> . . . . .	41
2.4.5.2	<i>Adaptive Moment Estimation (ADAM)</i> . . . . .	41
<b>3</b>	<b>TRABALHOS RELACIONADOS</b> . . . . .	<b>43</b>
3.1	MODELOS PROBABILÍSTICOS . . . . .	43
3.2	REDES NEURAS ARTIFICIAIS . . . . .	46
3.3	CONSIDERAÇÕES FINAIS . . . . .	48
<b>4</b>	<b>TÉCNICA DE ANÁLISE DE RISCO BASEADA EM SÉRIES TEM- PORAIS</b> . . . . .	<b>51</b>
4.1	METODOLOGIA . . . . .	51
4.2	GÊMEO DIGITAL DE UM VASO KNOCKOUT . . . . .	53
<b>4.2.1</b>	<b>Funcionamento de um vaso knockout</b> . . . . .	<b>53</b>
<b>4.2.2</b>	<b>Análise de riscos</b> . . . . .	<b>54</b>
<b>4.2.3</b>	<b>Modelagem do vaso no simulador dinâmico</b> . . . . .	<b>57</b>
4.3	COMUNICAÇÃO ENTRE O GÊMEO DIGITAL E OS MÓDULOS . . . . .	59
4.4	MODELO PARA PREDIÇÃO DE COMPORTAMENTO FUTURO . . . . .	61
<b>4.4.1</b>	<b>Extração dos dados de treinamento e validação</b> . . . . .	<b>62</b>
<b>4.4.2</b>	<b>Estrutura do modelo</b> . . . . .	<b>65</b>
<b>4.4.3</b>	<b>Treinamento e avaliação</b> . . . . .	<b>66</b>
4.5	INTERFACE DE VISUALIZAÇÃO . . . . .	71
<b>5</b>	<b>EXPERIMENTOS E RESULTADOS</b> . . . . .	<b>74</b>
5.1	ESTRATÉGIA DE VALIDAÇÃO . . . . .	74
5.2	CENÁRIOS DE RISCO . . . . .	75
5.3	AVALIAÇÃO . . . . .	75
<b>6</b>	<b>CONCLUSÃO</b> . . . . .	<b>80</b>
6.1	OBJETIVOS . . . . .	80
6.2	CONTRIBUIÇÕES . . . . .	81
6.3	LIMITAÇÕES . . . . .	83
6.4	TRABALHOS FUTUROS . . . . .	83
	<b>REFERÊNCIAS</b> . . . . .	<b>85</b>
	<b>APÊNDICE A – LISTA DE VARIÁVEIS MONITORADAS</b> . . . . .	<b>90</b>

# 1 INTRODUÇÃO

Com o advento da Indústria 4.0, o uso de Digital Twin (DT), ou gêmeos digitais, tem conquistado popularidade no setor industrial. Um DT consiste na replicação digital de um equipamento ou processo, abrangendo todas as informações relacionadas à engenharia e operação desse modelo em estado dinâmico de funcionamento. O propósito principal dessa tecnologia é oferecer uma representação precisa de um sistema real, possibilitando intervenções para testar hipóteses que servirão de base para a otimização do uso efetivo desse ativo.

O conceito de DT é amplo, oferecendo flexibilidade para ser aplicado em diversas finalidades. Uma aplicação notável desta tecnologia é a criação de modelos que simulam o comportamento de um equipamento diante de eventos raros, possibilitando a coleta de dados que seriam dificilmente capturados em condições de operação normais. Esses dados podem ser utilizados para impulsionar a produtividade e aprimorar a segurança da organização através do treinamento de algoritmos de aprendizagem de máquina capazes de auxiliar na prevenção de eventos indesejados.

De acordo com a Ericsson, aproximadamente 74% das organizações pretendem adotar o uso de DT até o ano de 2025 (SABBAGH, 2021). Na indústria de petróleo e gás, a adoção de DT auxiliou as operadoras a alcançarem economias entre 9% e 15% nos custos de projeto e manutenção (NAIR, 2016). Essa economia é de extrema importância, especialmente diante da volatilidade de alguns mercados no cenário de petróleo e gás.

## 1.1 MOTIVAÇÃO

A utilização de gêmeos digitais na indústria é um caminho natural, dado seu crescente processo de digitalização e aumento da captura de dados gerados pelos sensores dos equipamentos através de plataformas de Internet Industrial das Coisas (IIoT).

Um equipamento pertencente a um processo industrial está sujeito a uso intenso e a variadas condições de operação, desgastes e falhas operacionais que podem causar acidentes. A utilização de DT auxilia as empresas a diminuir seus custos através de estudos de otimização de produção, na prevenção de acidentes através da manutenção preditiva desses equipamentos e também no treinamento de operadores. Uma das principais importâncias do DT diz respeito à possibilidade de aprendizagem baseada no erro sem consequências significativas para as

organizações.

Essas organizações geram diariamente grandes volumes de dados por meio da leitura dos sensores dos equipamentos, que são armazenados em bancos de dados com informações temporais. No entanto, parte desses dados ainda não é agregada em ferramentas que possam auxiliar na tomada de decisão estratégica para as corporações.

As indústrias do setor de petróleo e gás operam com equipamentos em processos de alto risco, exigindo um elevado padrão de segurança e maturidade de processos. A utilização inadequada, a falta de manutenção ou a negligência por parte do setor de engenharia em relação aos alertas e aos mínimos sinais de desgaste nos equipamentos podem constituir elos críticos capazes de desencadear graves acidentes. Um exemplo emblemático é o Desastre da Refinaria de Feyzin em 1996, que resultou em 18 vítimas fatais e dezenas de feridos, destacando os perigos inerentes a essas operações (SARAVANAN, 2014).

Existem ferramentas de gestão de risco que possibilitam a identificação e avaliação de situações de risco, permitindo a definição de um plano de ação para mitigar os riscos e melhorar a segurança de processo pela sua capacidade de comunicação clara e objetiva das relações causais. Dentre essas ferramentas, destaca-se o diagrama bow-tie, que, de maneira esquemática, possibilita mapear a probabilidade de ocorrência de um evento, suas barreiras de mitigação e suas consequências, visando assegurar maior segurança à planta industrial. As barreiras de mitigação são essenciais para a segurança de processo, mas a ativação de algumas delas pode causar contratemplos além de impactos financeiros devido à interrupção temporária do funcionamento da indústria, assim como será apresentado em capítulos posteriores.

A criação de um DT para simulação de situações hipotéticas de um equipamento, juntamente com modelos de aprendizagem de máquina e todo o conhecimento extraído das análises de riscos provenientes dessas ferramentas, permite o estudo e desenvolvimento de abordagens inteligentes para monitorar todos os dados do processo industrial. Esse estudo tem como objetivo identificar, ainda em fase inicial, falhas potenciais, permitindo que os operadores tomem decisões antecipadas, evitando a necessidade de ativar barreiras de mitigação e prevenindo a ocorrência do evento de risco.

## 1.2 PROBLEMA DA PESQUISA

A indústria de petróleo e gás é composta por uma série de sistemas complexos e interligados, desde a exploração e produção até o refino e distribuição. Cada etapa engloba diversos

---

processos e equipamentos que operam em conjunto, assegurando o bom funcionamento da indústria.

A interdependência complexa entre os diversos sistemas da indústria de petróleo e gás demanda monitoramento e controle rigorosos para garantir a segurança, eficiência e confiabilidade das operações. A supervisão manual se torna inviável considerando a vasta quantidade de informações e métricas a serem analisadas. Isso se deve à necessidade de os operadores agregarem dados de diversas fontes para obter uma visão completa do estado atual dos equipamentos, o que muitas vezes leva à identificação tardia de falhas. Nesse contexto, o uso de algoritmos de inteligência artificial possibilita monitorar o processo como um todo, permitindo a detecção precoce de problemas, proporcionando tempo hábil para que os técnicos analisem a situação e tomem as medidas cabíveis para solucionar os problemas.

Modelos probabilísticos, como as redes bayesianas, são ferramentas valiosas para a identificação de riscos em sistemas industriais (WU et al., 2023; ALAUDDIN et al., 2020; ZHANG et al., 2018a). Eles lidam com a incerteza inerente a esses sistemas, calculando as probabilidades de um evento ocorrer com base na probabilidade de outros eventos relacionados. Em uma rede bayesiana tradicional, as probabilidades são definidas a priori por especialistas e permanecem constantes durante a inferência, sem ajustes à medida que novas informações são coletadas. No entanto, uma variação dessas redes, conhecida como Redes Bayesianas Dinâmicas (DBNs), permite que essas probabilidades sejam atualizadas dinamicamente à medida que novas informações se tornam disponíveis (HE et al., 2022).

Os modelos de redes neurais artificiais se tornaram uma opção atrativa para atividades de análise de risco, devido à sua capacidade de processar grandes volumes de dados em tempo real (LIU et al., 2023; GABHANE; KANIDARAPU, 2023; ZHANG et al., 2018b). Treinados com dados históricos, esses modelos auxiliam a encontrar padrões entre as variáveis, permitindo a detecção precoce de falhas nos processos. No entanto, o treinamento de tais modelos exige que uma grande quantidade de dados seja fornecida para que o modelo consiga aprender e generalizar padrões complexos. Isso representa um grande desafio para as atividades de análise de risco, devido à raridade da ocorrência de alguns eventos.

Os impactos da ocorrência de um evento podem ser reduzidos através de barreiras de mitigação. Elas são estratégias implementadas para minimizar os danos potenciais, limitando a gravidade do evento, o que pode incluir uma variedade de medidas, como a implementação de protocolos de segurança rigorosos, a construção de infraestruturas resilientes, ou a realização de treinamentos regulares. Ao antecipar e se preparar para eventos adversos, as barreiras

de mitigação podem efetivamente diminuir tanto a probabilidade quanto a gravidade dos impactos, contribuindo para uma maior resiliência e uma recuperação mais rápida.

O acúmulo de líquido em um vaso knockout é um exemplo de um evento que, ao ocorrer, pode causar danos físicos aos equipamentos, além de prejuízos financeiros devido à parada não programada da produção. Um vaso knockout é um equipamento amplamente utilizado na indústria de petróleo e gás. Ele é empregado para separar eficientemente as fases líquidas e gasosas de um fluxo de gás antes que este seja utilizado pelas caldeiras. Quando ocorre o acúmulo de líquido no vaso, o *trip* do vaso é acionado como uma barreira de mitigação. Essa barreira tem o objetivo de interromper temporariamente o fornecimento de gás para os processos subsequentes, a fim de mitigar o risco de explosão até que o nível do líquido seja normalizado. Dado que o próximo processo envolve a geração de vapor por meio da queima desse combustível gasoso, a presença de contaminantes líquidos no queimador do gerador de vapor pode resultar em explosões com impactos significativos (ZADAKBAR; KHAN; IMTIAZ, 2015).

Embora seja importante para mitigar riscos, a atuação dos sistemas de proteção pode causar grandes transtornos. Neste caso específico, pode levar à paralisação de um sistema crítico para os processos de produção. A previsão antecipada desse evento, ainda em fase inicial, permite que decisões sejam tomadas previamente para evitar a ocorrência do *trip*.

### 1.3 OBJETIVOS

Este trabalho propõe uma técnica para avaliação de risco de um vaso knockout em tempo real por meio de análises do comportamento temporal de várias variáveis de monitoramento do vaso. Essa técnica monitora informações de vários sensores do equipamento e realiza previsões sobre seu comportamento, com o objetivo de fornecer informações aos operadores para a tomada de decisões que evitem o acúmulo de líquido dentro do vaso, diminuindo os riscos de parada não programada da planta industrial.

Para isso, foi desenvolvido um modelo de rede neural para a inferência do nível do líquido. Este modelo é parte integrante de uma arquitetura desenhada para realizar as análises através da comunicação em tempo real com o modelo de simulação do vaso. Além disso, propomos uma metodologia de coleta de dados para viabilizar o treinamento, teste e avaliação da técnica em diversos cenários estabelecidos durante a etapa de análise de risco do processo.

Os objetivos desta pesquisa são:

- Apresentar uma solução para inferir comportamentos futuros do nível de líquido de um vaso knockout para prevenção de eventos indesejados.
- Desenvolver uma metodologia para coletar dados por meio de simulações, dispensando a dependência de especialistas.

Para atingir estes objetivos, este trabalho incluiu as seguintes atividades:

- Desenvolver a simulação do processo através de um software especializado com capacidade de simular diferentes cenários para validação de hipóteses.
- Propor um modelo de aprendizagem de máquina utilizando séries temporais para previsão de eventos.
- Desenvolver uma interface para apresentar informações aos operadores baseado no estado atual da simulação, fornecendo informações valiosas para auxiliar nas tomadas de decisões necessárias para que o evento não ocorra.

#### 1.4 ORGANIZAÇÃO DO TRABALHO

Esta seção tem como objetivo apresentar a organização do trabalho, fornecendo informações sobre os próximos capítulos. No Capítulo 2, apresentamos o conhecimento teórico utilizado para o desenvolvimento deste trabalho. No Capítulo 3, abordamos os trabalhos relacionados, realizando uma análise sobre suas contribuições e as desvantagens das abordagens apresentadas. No Capítulo 4, apresentamos nossa proposta de técnica. No Capítulo 5, apresentamos os resultados alcançados pelo nosso trabalho e realizamos uma análise sobre eles. Por fim, no Capítulo 6, discutimos sobre os objetivos alcançados, as contribuições, as limitações e as propostas de trabalhos futuros para esta pesquisa.

## 2 REFERENCIAL TEÓRICO

Neste capítulo, abordamos diversos tópicos essenciais para a compreensão do contexto do presente estudo. Inicialmente, tratamos da segurança dos processos na indústria de refino de petróleo, incluindo uma análise detalhada dos procedimentos essenciais para garantir um ambiente operacional seguro. Destacamos também a discussão sobre a aplicação de diagramas na análise de riscos. Em seguida, exploramos o conceito de Gêmeos Digitais, apresentando seus principais fundamentos e suas aplicações na indústria petroquímica. Posteriormente, discutimos o funcionamento das redes Bayesianas, que são amplamente empregadas no processo de análise de riscos. Concluimos esta seção com a apresentação de conceitos relevantes para as redes neurais artificiais, discorrendo sobre seu funcionamento e estratégias para o desenvolvimento de modelos robustos. Essa seção fornece uma base sólida para a compreensão da metodologia e o desenvolvimento deste trabalho.

### 2.1 SEGURANÇA DOS PROCESSOS NA INDÚSTRIA DE REFINO DE PETRÓLEO

A segurança do processo desempenha um papel crítico na indústria de petróleo e gás. A manutenção adequada, inspeções regulares e a identificação precoce de possíveis falhas são elementos-chave para a prevenção de acidentes. Neste contexto, a aplicação de algoritmos de inteligência artificial surge como uma ferramenta valiosa pois podem analisar dados operacionais em tempo real, detectar padrões anômalos e antecipar potenciais falhas nos equipamentos, proporcionando uma abordagem proativa para a segurança do processo.

#### 2.1.1 Diagrama bow-tie

O processo de análise de risco é uma etapa importante pela qual a empresa identifica pontos críticos, avalia a probabilidade de ocorrerem determinados eventos e define ações de mitigação para evitar impactos adversos. Durante este processo, é frequente a elaboração de diagramas que simplificam o acompanhamento e a compreensão dos riscos presentes com uma dada probabilidade da ocorrência do evento acidental.

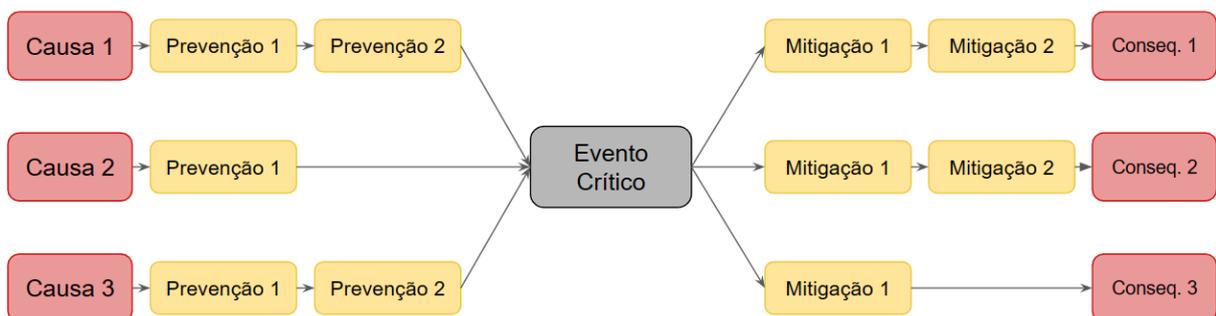
O diagrama bow-tie para análise de risco foi desenvolvido em meados de 1970 e a Shell foi a primeira companhia que incorporou oficialmente aos seus negócios (IACOB; APOSTOLOU, 2015).

Uma análise de risco é um processo complexo que deve ser desempenhado por um time de especialistas. De modo geral, essa análise é iniciada através da identificação de eventos críticos em uma atividade, as causas que podem iniciar esses eventos, suas possíveis consequências e a definição de barreiras de prevenção para tentar limitar os danos que esses eventos podem causar (MACHMOOD; SHEVTSHENKO, 2015). Os especialistas podem inferir essas informações através de observações ou através de dados históricos de eventos ocorridos no passado.

A Figura 1 expõe um exemplo genérico de um diagrama bow-tie para análise de risco. Um diagrama bow-tie é construído utilizando os seguintes elementos:

- Evento crítico: representa o evento principal do diagrama.
- Causas: são as principais causas que podem produzir um evento crítico. Cada evento crítico pode ser formado por uma ou mais causas.
- Prevenção: representa as barreiras físicas, tecnológicas ou por ações humanas como medidas que podem ser adotadas para evitar a ocorrência do evento crítico. Para cada causa, pode-se definir um conjunto de prevenções a fim de construir uma barreira eficaz de prevenção.
- Mitigação: similar ao elemento de prevenção, a mitigação é executada após a ocorrência do evento crítico e busca reduzir a severidade das consequências.
- Consequências: descreve as possíveis consequências após a ocorrência do evento crítico.

Figura 1 – Exemplo genérico de um diagrama bow-tie



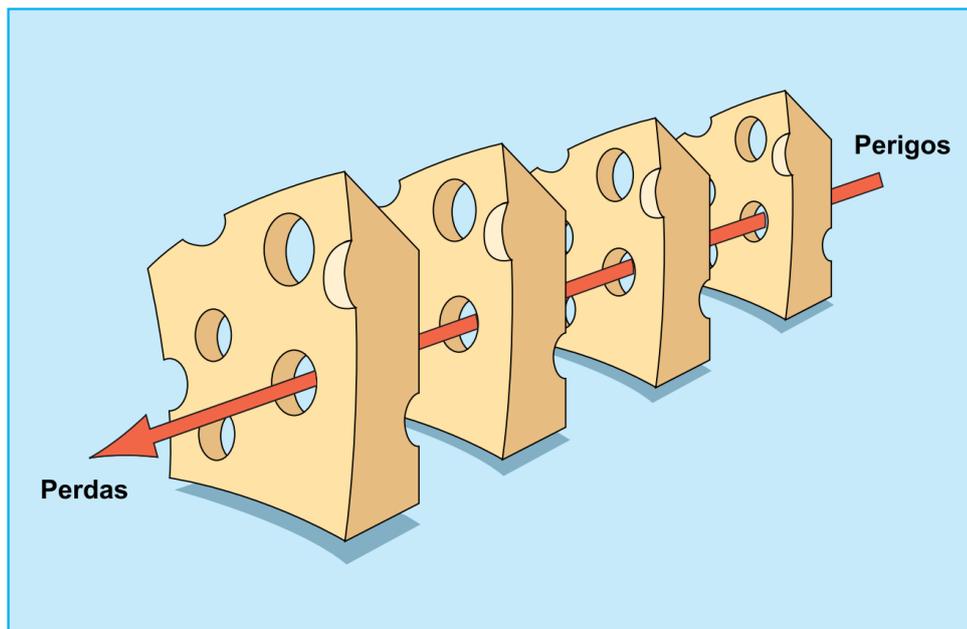
Fonte: O autor

O diagrama apresenta com clareza como um evento crítico ocorre e todas as condições possíveis, auxiliando nas tomadas de decisões protetivas. O diagrama bow-tie é bastante flexível e pode ser utilizado para análises qualitativas e quantitativas. O uso dessa ferramenta para a análise de risco é bastante efetivo e seu uso está cada vez mais presente na indústria.

### 2.1.2 Modelo do queijo suíço

Um diagrama bow-tie permite que os analistas incorporem outras técnicas para enriquecer e aprimorar a análise de riscos. O modelo do queijo suíço (REASON, 2000) é um modelo conceitual utilizado para analisar e compreender as falhas no sistema, principalmente em contextos complexos e de alto risco, como a indústria química e petroquímica, aviação e saúde. Esse modelo propõe uma abordagem holística na identificação e gestão de falhas, reconhecendo que a maioria dos eventos indesejados é resultado da combinação de múltiplos fatores que se complementam.

Figura 2 – Modelo do queijo suíço.



Fonte: Adaptação de REASON (2000)

O modelo visual apresentado na Figura 2 consiste em camadas representando diferentes elementos no sistema. Cada camada é concebida como um "bloco de queijo suíço", com vários furos que simbolizam potenciais falhas. Esses furos podem permitir a passagem de um evento indesejado caso estejam alinhados. As camadas incluem fatores organizacionais, condições pré-existent, falhas ativas, barreiras e consequências. O diagrama bow-tie, por sua vez, é frequentemente utilizado em conjunto com o modelo do queijo suíço para representar graficamente as relações entre os eventos precipitadores, as barreiras e as consequências.

O modelo do queijo suíço e o diagrama bow-tie podem ser utilizados em conjunto, formando uma abordagem integrada para compreender e mitigar os riscos em sistemas complexos. Essa

combinação fornece uma estrutura robusta para a análise de eventos adversos, promovendo a identificação de pontos fracos e a implementação de medidas preventivas e corretivas. Essas ferramentas são essenciais em ambientes críticos, onde a segurança e a eficácia do sistema são imperativos fundamentais.

## 2.2 GÊMEOS DIGITAIS

O primeiro conceito de gêmeo digital foi apresentado em 2002 por Michael Grieves na Universidade do Michigan durante sua apresentação sobre Gerenciamento do Ciclo de Vida do Produto (PLM) (GRIEVES, 2016). O modelo proposto por Grieves era formado por três elementos: espaço real, espaço virtual e um mecanismo de fluxo de dados entre os espaços. Sua premissa era de que cada sistema consiste em dois subsistemas: o sistema físico que sempre irá existir e o sistema virtual que contém todas as informações sobre o sistema físico. Isso significa que o sistema virtual é um espelhamento do sistema físico. O termo DT foi introduzido pela NASA em 2010 e foi descrito como:

Uma simulação probabilística, multifísica e multiescala integrada de um veículo ou sistema que usa os melhores modelos físicos disponíveis, atualizações de sensores, histórico de frota, etc., para espelhar a vida de seu gêmeo voador. (SHAFTO et al., 2010)

Esse conceito já havia sido utilizado durante o Programa Apollo, onde foi desenvolvido um gêmeo de um veículo espacial para treinamento preparatório através de simulações de situações críticas que poderiam ocorrer no espaço.

Desde sua primeira definição pela NASA, o conceito de DT ficou incerto, pois cada autor criava uma definição diferente baseada em suas aplicações. Para evitar possíveis confusões acerca deste conceito, foi proposta uma nova definição sobre DT que pode ser aplicado independentemente do tipo de indústria ou de aplicação.

Um gêmeo digital é um modelo digital/virtual dinâmico e auto evolutivo ou uma simulação de um sujeito ou objeto da vida real (peça, máquina, processo, humano, etc.) representando o estado exato de seu gêmeo físico em qualquer ponto do tempo através da troca de dados em tempo real, bem como mantendo os dados históricos. Não é apenas o gêmeo digital que imita seu gêmeo físico, mas quaisquer mudanças no gêmeo digital também são imitadas pelo gêmeo físico (SINGH et al., 2021).

Em seu artigo, o Dr. Michael Grieves define que um DT é um conjunto de construções das informações que descreve por completo um produto desde o nível micro-atômico ao nível

---

macro-geométrico e também estabelece dois tipos de gêmeos digitais:

- Digital Twin Prototype (DTP): é o modelo de gêmeo digital que contém as informações necessárias para produzir uma versão física que é uma cópia exata da versão virtual. Essas informações são relacionadas a especificações de engenharia e comportamento para a implementação da versão física.
- Digital Twin Instance (DTI): é o modelo que descreve um ativo físico e que é conectado ao ativo durante todo o ciclo de vida. Neste modelo são contidas as informações de engenharia e os dados gerados durante sua execução.

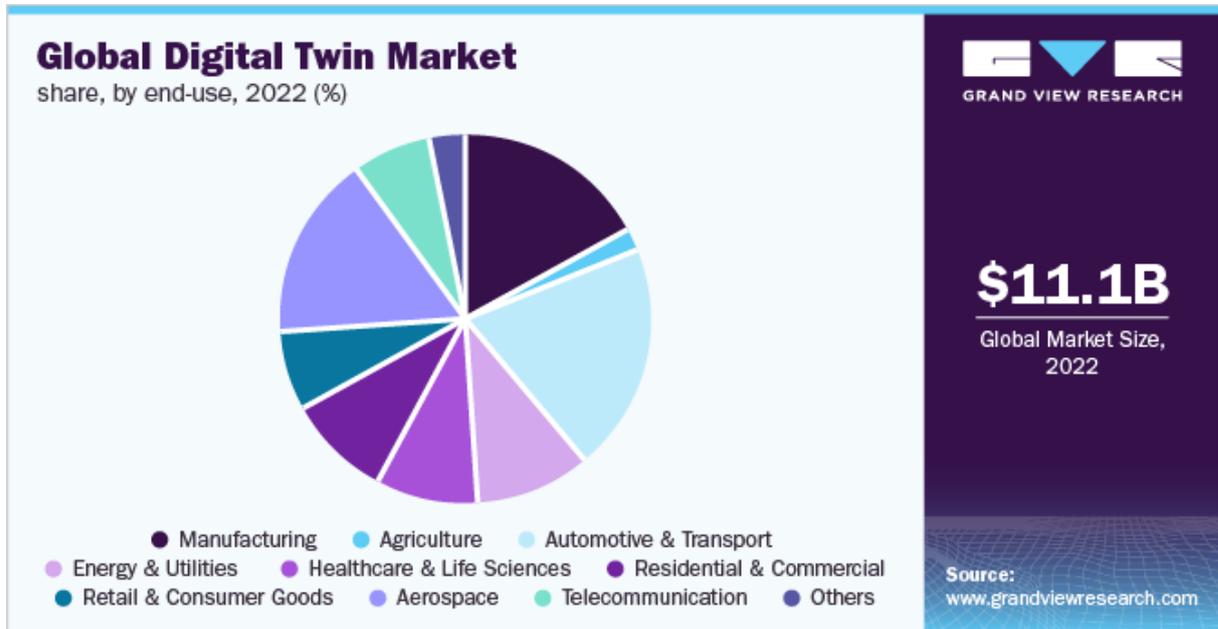
Alguns anos depois, Grieves e Vickers apresentam o conceito de Digital Twin Environment (DTE) como um ambiente onde os especialistas podem realizar simulações utilizando gêmeos digitais para diversas finalidades (GRIEVES; VICKERS, 2017). Essas finalidades podem ser:

- Preditiva: Um gêmeo digital pode ser utilizado para fazer previsões de performance ou comportamentos futuros.
- Interrogativa: Um gêmeo digital pode ser utilizado para analisar estados anteriores ou monitorar o estado atual.

O conceito de gêmeo digital tem atraído a atenção da indústria e da academia nos últimos anos. De acordo com um relatório publicado pela Grand View Research, o mercado global de gêmeo digital foi avaliado em aproximadamente 11 bilhões de dólares e está projetado um crescimento anual de 37,5% de 2023 até 2030 (Grand View Research, 2022). A Figura 3 mostra que grande parte deste mercado é atribuída à elevada demanda de desenvolvimento de gêmeos digitais para desenhar, projetar e desenvolver processos de manufatura, engenharia aeroespacial e equipamentos de uso da indústria de energia.

Muitas organizações estão concentradas em oferecer soluções comerciais para o desenvolvimento de gêmeos digitais, e dentre elas, podemos destacar a AVEVA, que possui uma longa trajetória no setor industrial de petróleo, gás, naval *offshore* e, recentemente, em energias renováveis.

Figura 3 – Marketshare global dos gêmeos digitais em 2022



Fonte: Grand View Research (2022)

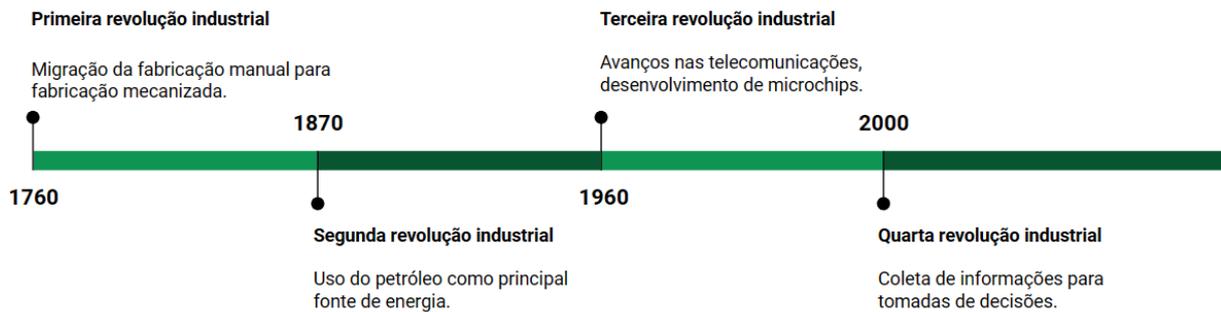
### 2.2.1 Indústria 4.0

Até alcançar o nível tecnológico necessário para o desenvolvimento e implementação de soluções baseadas em gêmeos digitais, a indústria precisou passar por várias revoluções, que marcaram períodos de grande avanço tecnológico. A primeira grande Revolução Industrial ocorreu em meados de 1760, na Inglaterra, e marcou um período de transição de um modelo de produção artesanal para um modelo mecanizado. A Segunda Revolução Industrial iniciou em 1870 e trouxe o uso de petróleo como fonte de energia, sendo utilizado em motores a combustão. A Terceira Revolução Industrial foi iniciada em 1960 e ficou conhecida como a Revolução Técnico-Científica-Informacional. Os avanços desse período não foram voltados apenas para o desenvolvimento de produtos, mas também ao avanço científico em todo mundo. Foram registrados avanços na área de telecomunicações, eletrônica e transportes.

Como pode ser visto na Figura 4, atualmente estamos na Quarta Revolução Industrial (Indústria 4.0). Essa revolução também pode ser entendida como uma extensão da Terceira Revolução Industrial, porém focada na informação.

A Internet Industrial das Coisas é uma das principais contribuições da Indústria 4.0, acelerando a implementação de gêmeos digitais. A IIoT representa uma revolução na maneira como as empresas operam e gerenciam processos de fabricação e produção. Este conceito refere-se à

Figura 4 – Linha do tempo das revoluções industriais.



Fonte: Autor

interconexão de dispositivos, sensores e sistemas em ambientes industriais, permitindo a coleta de dados em tempo real e a comunicação entre máquinas e sistemas de controle. A IIoT tem o potencial de otimizar a eficiência operacional, melhorar a manutenção preditiva e aumentar a produtividade. Ela cria um ecossistema digital no qual máquinas, produtos e pessoas estão conectadas, facilitando a tomada de decisões com base em análises avançadas de dados. O crescimento exponencial da IIoT está impulsionando a transformação digital nas indústrias e promovendo um novo paradigma de produção inteligente e sustentável.

Em virtude da demanda por armazenamento e processamento em larga escala dos dados gerados por esses dispositivos, surgiu o conceito de Big Data. Embora não exista uma definição universal para o termo, de acordo com um relatório da IDC, podemos caracterizar o Big Data da seguinte forma:

Nova geração de tecnologias e arquiteturas, planejadas para extrair valor de grandes volumes de uma ampla variedade de dados, permitindo captura, descoberta e/ou análise em alta velocidade. (GANTZ; REINSEL, 2012)

Em complemento a esta definição, as características de Big Data podem ser resumidas em 4Vs: Volume, Velocidade, Variedade e Valor (CHEBBI; BOULILA; FARAH, 2015).

- Volume: Não existe uma quantidade exata de dados para que seja qualificado como Big Data. Se existe o armazenamento de dados históricos e novos dados estão sendo constantemente adicionados, logo haverá uma dificuldade para gerenciá-los.
- Velocidade: Se refere à velocidade na qual os dados estão sendo armazenados e também à velocidade necessária para que esses dados sejam analisados e utilizados. Se um processo necessita de análises de dados em tempo real, haverá um desafio a ser enfrentado.

Atualmente, as empresas de computação em nuvem já fornecem soluções maduras para solucionar este problema.

- **Variedade:** Os dados podem ser estruturados, não-estruturados ou semi-estruturados e são provenientes de diversas fontes. Eles podem ser armazenados através da leitura de sensores, armazenamento de arquivos brutos e outros métodos.
- **Valor:** Os dados armazenados devem ser confiáveis, pois erros, redundância e dados corrompidos podem afetar o valor da informação.

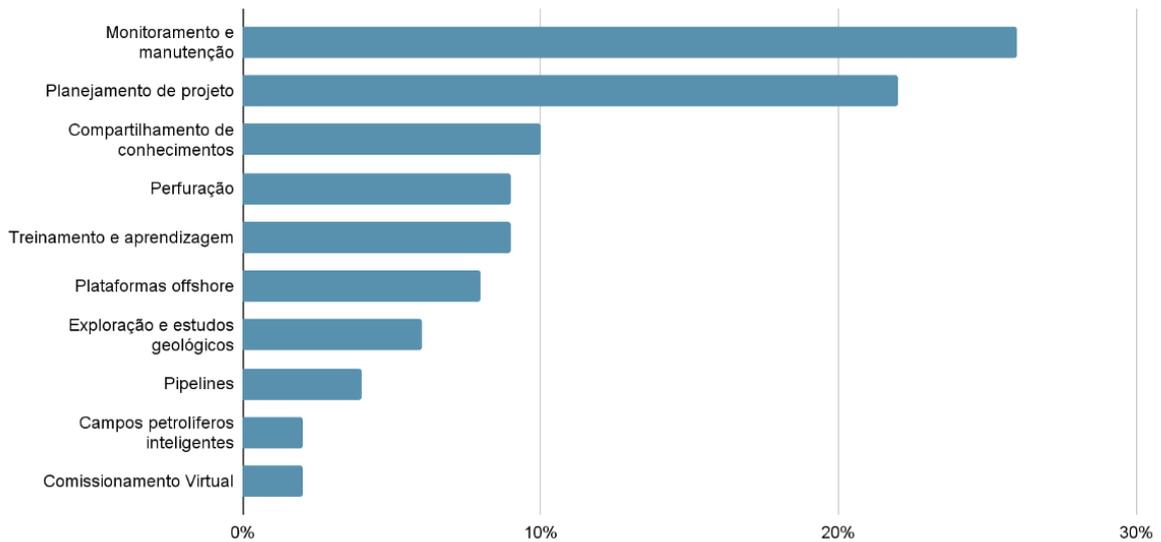
Na era da transformação digital, a capacidade de colaboração e o acesso à informação possibilitam que as empresas se ajustem com maior agilidade às dinâmicas do mercado (ROSEN et al., 2015). O avanço tecnológico na Indústria 4.0 é caracterizado por uma extensão, impacto e rapidez sem precedentes no lançamento de produtos no mercado. À medida que a tecnologia captura a atenção do mercado, é evidente que recursos como os gêmeos digitais desempenharão um papel significativo nesse cenário, conectando-se de maneira intrínseca à Revolução Industrial Digital.

### **2.2.2 Gêmeos digitais na indústria de petróleo e gás**

Com o processo de modernização da indústria petroquímica, grandes sistemas de armazenamento de informações foram implementados, viabilizando o desenvolvimento de modelos virtuais. WANASINGHE et al. (2020) descreve em seu trabalho uma visão geral sobre os desafios, oportunidades e tendências de pesquisa de gêmeos digitais para a indústria de petróleo e gás. De acordo com o gráfico apresentado na Figura 5, o monitoramento, planejamento de projetos e compartilhamento de conhecimento são as principais áreas de aplicações dos gêmeos digitais.

Alguns componentes importantes para a implantação de gêmeos digitais não são novos para a indústria de petróleo e gás. Por exemplo, as empresas durante décadas coletam constantemente dados de sensores, constroem modelos dos equipamentos e/ou processos e simulam dados, facilitando o processo de adoção. Entretanto, apenas esses componentes não são suficientes para a adoção por completa do uso de gêmeos digitais, sendo necessário que sejam adotadas outras tecnologias. Os autores identificaram as tecnologias mais adotadas durante um processo de desenvolvimento e implementação, entre as quais podemos destacar: modelagem CAD (3D), IIoT, sensores inteligentes, big data, aprendizagem de máquina, automação,

Figura 5 – Principais áreas de aplicação de gêmeos digitais na indústria de petróleo e gás



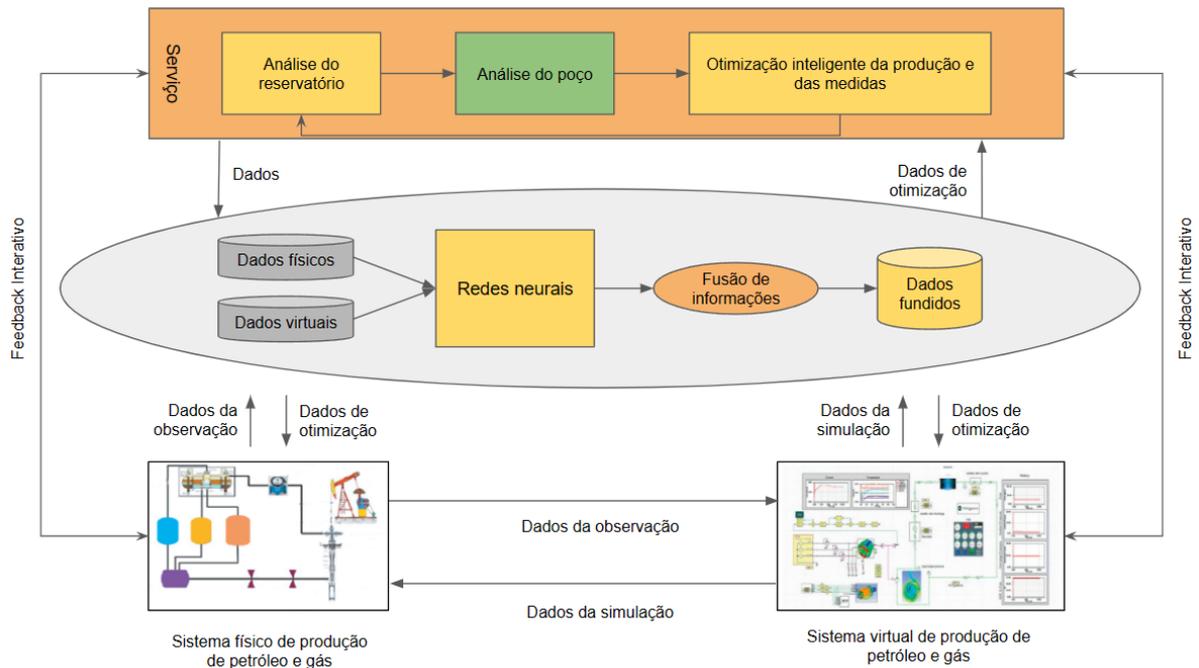
**Fonte:** Adaptação de WANASINGHE et al. (2020)

computação em nuvem, entre outros. Aproximadamente 68% dos trabalhos publicados na literatura são associadas a alguma companhia, sugerindo uma oportunidade de cooperação entre a indústria e as universidades.

SHEN et al. (2021) mostra que um gêmeo digital desenvolvido para a indústria de petróleo e gás não consiste apenas de um modelo tridimensional, o ativo físico, o ativo digital e suas conexões, mas envolve uma combinação de novas tecnologias, como mostrado pela Figura 6. O desenvolvimento de modelos para este tipo de indústria são complexos e devem ser adaptados de acordo com as necessidades do negócio, incorporando dados sobre seu comportamento, regras e restrições do ativo físico.

Os autores argumentam que um gêmeo digital deve conter todo o processo evolutivo, operações em tempo real e influência do ambiente externo. O sistema físico de produção deve ser integrado ao gêmeo digital utilizando vários dispositivos IIoT para a captura de dados importantes através da leitura de sensores. O armazenamento, transmissão e compartilhamento destes dados podem ser realizados através de uma arquitetura baseada em computação em nuvem, fornecendo alta resiliência para todo o sistema. A fusão de informações e tomadas de decisões são construídas através de algoritmos complexos de análise de dados, podendo ser tecnologias proprietárias ou adquiridas de empresas especializadas neste tipo de solução desde que sejam personalizáveis para abordar o tipo de problema proposto.

Figura 6 – Diagrama geral de um gêmeo digital no refino de petróleo e gás



Fonte: Adaptação de SHEN et al. (2021)

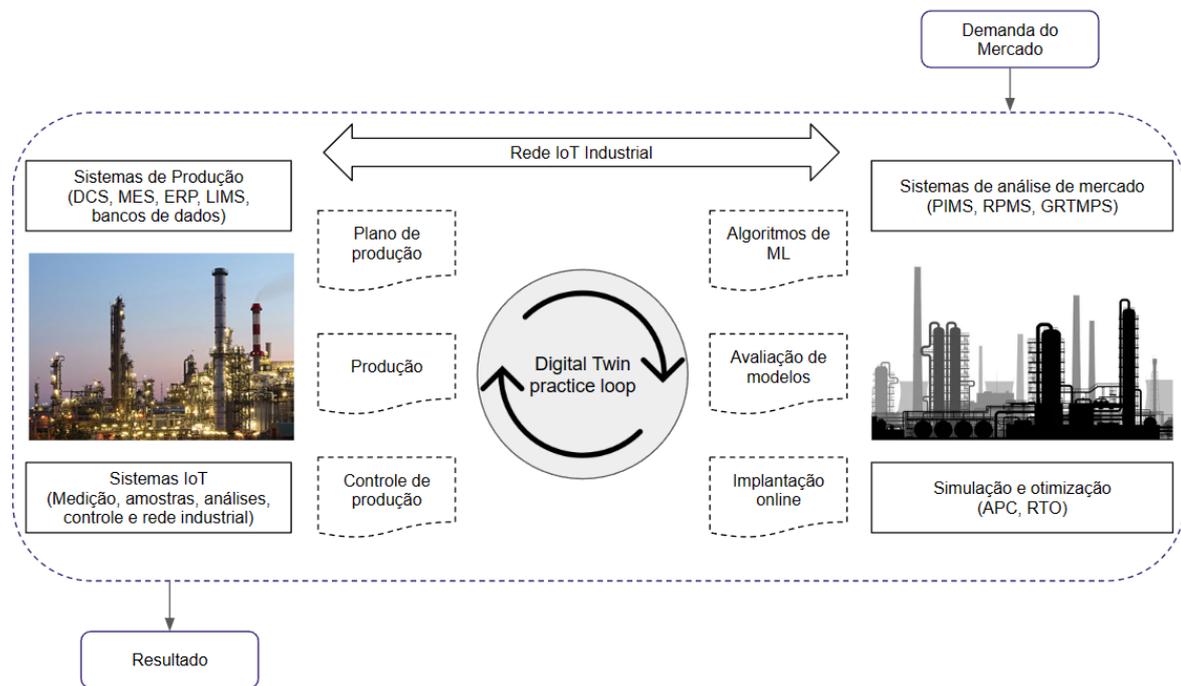
### 2.2.3 Frameworks para desenvolvimento de gêmeos digitais

Desenvolver gêmeos digitais pode ser bastante desafiador, exigindo a execução de diversas etapas até alcançar o modelo final. Para facilitar essa jornada, os frameworks guiam o processo com etapas e fluxos bem definidos. O trabalho de MIN et al. (2019) propõe o desenvolvimento de um framework e uma nova abordagem para construir soluções baseadas em gêmeos digitais na indústria petroquímica, através do uso de aprendizagem de máquina e big data para treinar e otimizar os modelos. O principal objetivo deste framework é reduzir a dependência do julgamento de especialistas para tomar decisões relacionadas ao gerenciamento da produção. A Figura 7 mostra uma visão geral do framework proposto.

Essa arquitetura inclui os principais elementos de um gêmeo digital, troca de informações entre o ativo físico e o modelo digital, o loop de treinamento e otimização dos modelos e informações acerca da produção. Na construção do gêmeo digital, é necessário aplicar os seguintes passos:

1. Construir a estrutura básica através da análise do processo de produção;
2. Treinar modelos utilizando os dados históricos dos sistemas industriais e algoritmos de aprendizagem de máquina;

Figura 7 – Framework proposto para o desenvolvimento de gêmeos digitais na indústria petroquímica



Fonte: Adaptação de MIN et al. (2019)

3. Estabelecer métricas de avaliação do modelo para estimar a eficiência do modelo final;
4. O modelo que obtiver o melhor desempenho nas métricas estabelecidas anteriormente devem ser disponibilizado online;
5. O modelo deve ser treinado iterativamente para se adaptar às mudanças do mercado e do ambiente industrial, criando um loop entre o ambiente virtual e o ativo físico que o autor chama de *practice loop*.

A partir da clara definição dessas etapas, a concepção, elaboração e testes dos modelos virtuais tornam-se mais acessíveis, elevando a probabilidade de êxito no projeto. Devido às especificidades de cada aplicação, é possível adaptar essas fases de modo a alinhá-las de maneira mais precisa aos objetivos específicos de cada projeto.

### 2.3 REDES BAYESIANAS

As redes Bayesianas, que se configuram como uma ferramenta poderosa na modelagem probabilística e análise de incerteza em sistemas complexos, permitem a modelagem de dependências complexas através de uma estrutura que representa relações probabilísticas entre

variáveis. Elas encontram aplicação em diversas áreas, como aprendizagem de máquina, medicina, finanças e engenharia. Sua relevância reside na sua capacidade de lidar com a incerteza inerente a muitos problemas do mundo real, oferecendo uma abordagem robusta para a tomada de decisão sob tais condições. Essas redes se destacam na análise de ambientes complexos e dinâmicos, tornando-se uma ferramenta fundamental para a análise de risco em processos industriais. Através da integração de dados históricos, conhecimento de especialistas e informações probabilísticas, as redes Bayesianas fornecem uma representação das relações causais entre os eventos de falha, permitindo uma avaliação mais precisa e eficaz dos riscos envolvidos.

Essas redes operam com base no Teorema de Bayes, uma equação matemática para calcular probabilidades condicionais. Este teorema é expresso pela Equação 2.1.

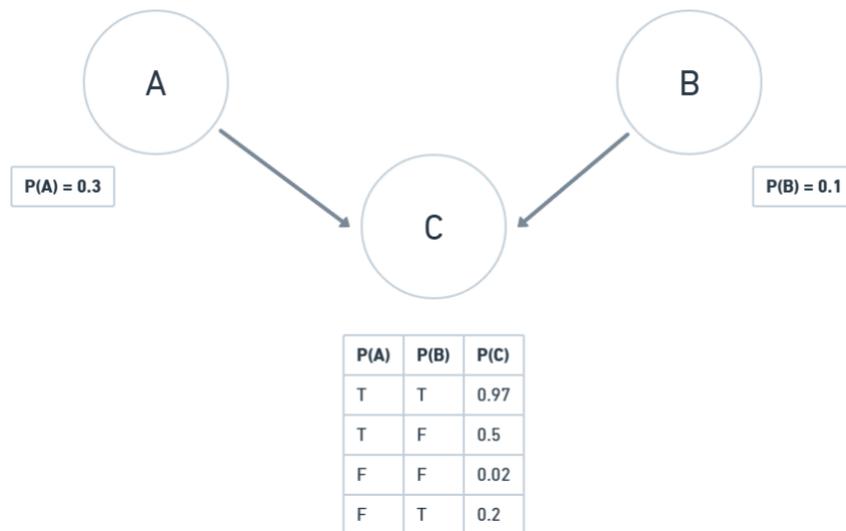
$$P(X|Y) = \frac{P(Y|X)P(X)}{P(Y)} \quad (2.1)$$

Nesta equação,  $P(X|Y)$  é a probabilidade de  $X$  ocorrer dado que  $Y$  ocorreu,  $P(Y|X)$  é a probabilidade de  $Y$  ocorrer dado que  $X$  ocorreu,  $P(X)$  é a probabilidade de  $X$  ocorrer e  $P(Y)$  é a probabilidade de  $Y$  ocorrer. As Redes Bayesianas utilizam este teorema para calcular a probabilidade de um evento, considerando o conhecimento prévio.

Em uma Rede Bayesiana, cada nó representa uma variável aleatória. As variáveis podem ser discretas (como "sim" ou "não") ou contínuas (como temperatura ou altura). Cada nó possui uma tabela de probabilidades que informa a probabilidade de cada valor possível da variável, considerando os valores das variáveis que a influenciam.

As Redes Bayesianas são construídas criando-se um grafo acíclico dirigido, como demonstrado na Figura 8, onde os círculos representam as variáveis aleatórias e as arestas representam as dependências condicionais entre as variáveis. As dependências são frequentemente expressas em termos de uma matriz de probabilidades condicionais que geralmente são fornecidas com base no conhecimento do domínio. Uma vez que a rede é construída, ela pode ser utilizada para responder a consultas probabilísticas sobre as variáveis através de inferências.

Figura 8 – Exemplo de uma rede bayesiana genérica.



Fonte: Autor

## 2.4 REDES NEURAIAS ARTIFICIAIS

As Redes Neurais Artificiais (RNAs) são um conjunto de modelos computacionais bastante populares dentro do campo da Aprendizagem de Máquina. Esses algoritmos modelam-se a partir do funcionamento do cérebro humano para processar dados e informações. Uma RNA é composta por unidades de processamento chamadas neurônios artificiais, que recebem, processam e transmitem informações. Existem vários modelos de neurônios artificiais, mas um dos mais simples e importantes é o Perceptron (ROSENBLATT, 1958).

O Perceptron é baseado no neurônio MP (MCCULLOCH; PITTS, 1943), que simula um neurônio biológico de forma simplificada. O neurônio MP recebe várias entradas e produz uma saída binária, que depende de um limiar (*threshold*). A saída é 1 se a soma das entradas for maior ou igual ao limiar, e 0 caso contrário. A equação 2.2 apresenta a fórmula matemática do neurônio MP.

$$y = \begin{cases} 1 & \text{se } \sum_{i=1}^n x_i \geq \theta \\ 0 & \text{se } \sum_{i=1}^n x_i < \theta \end{cases} \quad (2.2)$$

Onde  $x_i$  são as entradas,  $n$  é o número de entradas e  $\theta$  é o valor do limiar.

O Perceptron aprimora o modelo MP ao introduzir pesos para as entradas, que representam a importância relativa de cada entrada para a saída. Além disso, o Perceptron usa uma função de ativação chamada função degrau, definida pela equação 2.3.

$$f(x) = \begin{cases} 1 & \text{se } x \geq 0 \\ 0 & \text{se } x < 0 \end{cases} \quad (2.3)$$

A fórmula matemática do Perceptron é apresentada pela equação 2.4, onde  $x_i$  são os valores recebidos na entrada do neurônio,  $w_i$  são os pesos,  $b$  é o viés (bias) e  $f$  é a função degrau. O *bias* é um termo constante que permite ajustar o limiar da função de ativação.

$$y = f\left(\sum_{i=1}^n w_i x_i + b\right) \quad (2.4)$$

O Perceptron pode ser usado para resolver problemas de classificação binária, ou seja, problemas em que se deseja separar duas classes de dados. No entanto, o Perceptron só consegue resolver problemas linearmente separáveis, ou seja, problemas em que existe uma reta que separa as duas classes. Se os dados não forem linearmente separáveis, o Perceptron não consegue convergir para uma solução. Essa limitação levou ao desenvolvimento de arquiteturas mais robustas, como as redes neurais multicamadas e o uso de funções de ativação não lineares, que permitem a modelagem de relações mais complexas e a resolução de problemas não linearmente separáveis.

### 2.4.1 Funções de ativação

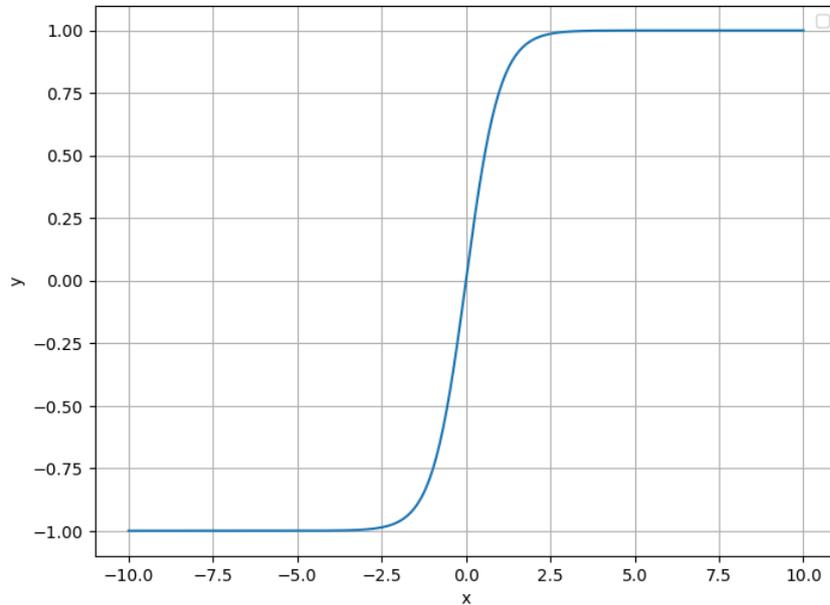
A escolha da função de ativação é um passo importante durante o desenvolvimento de uma rede neural artificial. Essas funções são responsáveis por decidir se determinado neurônio deve ser ou não ativado. Em outras palavras, se a informação que o neurônio está recebendo é relevante ou se deve ser ignorada. Essas funções também são responsáveis por introduzir a não-linearidade nas redes neurais, permitindo que elas aprendam funções mais complexas (SZANDAŁA, 2021). A escolha da função depende do problema e da arquitetura da rede neural, pois cada função tem suas características, vantagens e desvantagens.

#### 2.4.1.1 Tangente Hiperbólica

A função de ativação tangente hiperbólica (CHEN, 1990), também conhecida como *tanh*, é uma importante função matemática utilizada em redes neurais artificiais. Assim como mos-

trado na Figura 9, seu formato é muito semelhante à função tangente e pode ser descrita matematicamente pela equação 2.5.

Figura 9 – Forma da função tangente hiperbólica.



Fonte: Autor

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.5)$$

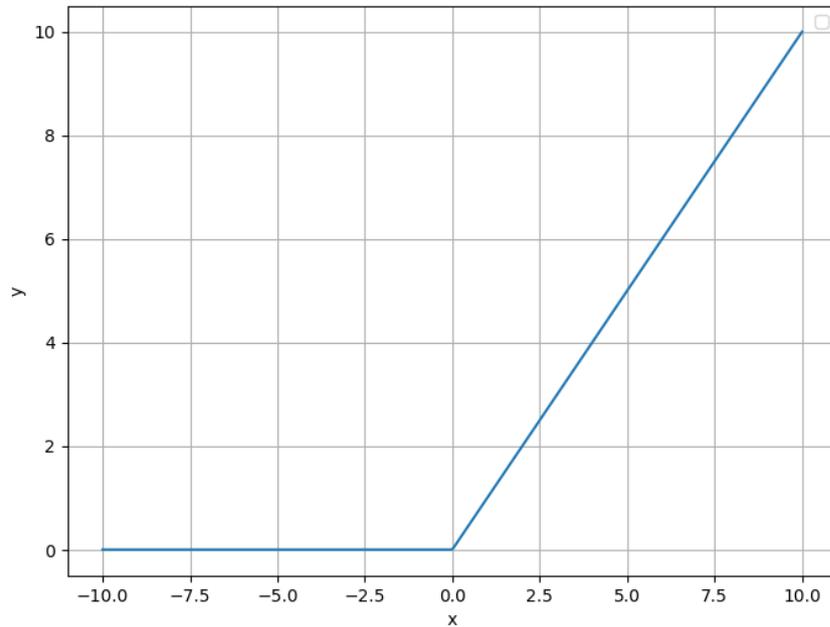
Onde  $e$  é a base do logaritmo natural. Essa função retorna valores no intervalo  $[-1, 1]$  e tem a característica de centrar os dados em torno do zero, facilitando o processo de treinamento de redes neurais. Entretanto, a tangente hiperbólica, assim como outras funções de ativação, pode enfrentar o problema do desaparecimento do gradiente. Nesse problema, os valores do gradiente tornam-se extremamente pequenos à medida que são propagados de volta pelas camadas da rede durante o processo de retropropagação. Isso pode resultar em um aprendizado mais lento e dificuldades em capturar dependências de longo prazo.

#### 2.4.1.2 ReLU

A Rectified Linear Unit (ReLU) é uma função de ativação bastante conhecida por sua simplicidade e velocidade. Sua forma matemática é dada por  $f(x) = \max(0, x)$ , o que significa que ela retorna zero para todos os valores negativos de  $x$  e retorna o próprio valor

de  $x$  para valores positivos (NAIR; HINTON, 2010). A Figura 10 representa graficamente este comportamento.

Figura 10 – Comportamento da função ReLU.



Fonte: Autor

Devido à estrutura da função, é possível notar que, quando as entradas são negativas, o processo de aprendizado da rede é interrompido. Isso significa que alguns neurônios não conseguem ser ativados por nenhuma entrada do conjunto de dados, e, por consequência não têm seus respectivos pesos atualizados, um fenômeno conhecido por *dying ReLU* (LU, 2020). Para mitigar esse problema, variações da função ReLU, como *Leaky ReLU* (MAAS et al., 2013) e *Parametric ReLU* (HE et al., 2015), foram propostas. A principal vantagem da função ReLU é sua simplicidade e eficácia computacional. Além disso, ela ajuda a superar o problema do desaparecimento do gradiente, que ocorre na tangente hiperbólica, melhorando o treinamento de redes neurais profundas.

#### 2.4.2 Normalização

A normalização de dados é uma prática essencial durante a etapa de pré-processamento, sendo comumente utilizada em processos de aprendizagem de máquina. O uso da normalização cria um ambiente onde todos os atributos do conjunto de dados influenciam de maneira proporcional. Esse processo é possível pois as técnicas de normalização trabalham na trans-

formação de dados que estão em diferentes escalas e têm magnitudes diversas, tornando-os comparáveis e facilitando a interpretação pelos modelos (JAIN; SHUKLA; WADHVANI, 2018).

#### 2.4.2.1 MinMax

O MinMax é uma técnica de normalização simples e amplamente utilizada durante o treinamento de algoritmos de aprendizagem de máquina. Ela ajusta os valores de uma variável para um intervalo específico, geralmente entre 0 e 1 (RAJU et al., 2020). A equação 2.6 demonstra a transformação realizada pelo MinMax.

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (2.6)$$

Onde  $X_{norm}$  é o valor normalizado,  $X$  é o valor original da variável,  $X_{min}$  é o menor valor da variável no conjunto de dados e  $X_{max}$  é o maior valor da variável no conjunto de dados.

Seu principal objetivo é converter todas as variáveis para uma escala comum, facilitando o aprendizado durante o treinamento de algoritmos de aprendizagem de máquina que são sensíveis à escala dos atributos. Algoritmos como regressão linear, máquinas de suporte vetorial e redes neurais, por exemplo, podem se beneficiar da normalização dos atributos, melhorando seu desempenho e atingindo a convergência mais rapidamente. No entanto, é importante observar que a normalização MinMax é sensível a *outliers*, pois ela depende dos valores máximos e mínimos de cada variável do conjunto de dados.

### 2.4.3 Camadas de aprendizagem profunda

Em redes de aprendizagem profunda, a escolha e organização das camadas desempenham um papel importante na capacidade da rede em aprender representações significativas dos dados. Compreender as definições e características intrínsecas de cada tipo de camada representa um passo essencial para atingir os objetivos desejados pela rede em desenvolvimento.

#### 2.4.3.1 Fully Connected Layers (FC)

As Fully Connected Layers (FC), também conhecidas como camadas densamente conectadas, são componentes essenciais de arquiteturas de redes neurais profundas. Elas desempenham

um papel importante na capacidade das redes neurais de aprender representações complexas de dados (KOCSIS et al., 2022).

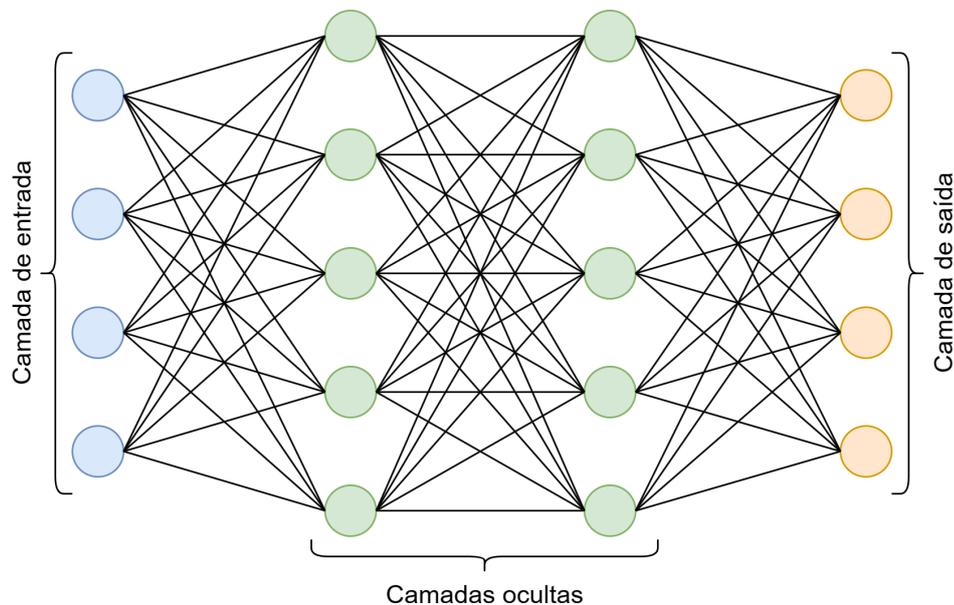
Em termos matemáticos, uma camada totalmente conectada mapeia cada unidade de entrada para cada unidade de saída, estabelecendo conexões entre todas as entradas e todas as saídas. Seja  $X$  o vetor de entrada de dimensão  $N$ , onde  $N$  é o número de unidades de entrada, e  $Y$  o vetor de saída de dimensão  $M$ , onde  $M$  é o número de unidades de saída, a operação realizada por uma camada totalmente conectada pode ser expressa como:

$$Y = \sigma(WX + b) \quad (2.7)$$

onde,  $W$  é a matriz de pesos de dimensão  $M \times N$ ,  $X$  é o vetor de entrada,  $b$  é o vetor de viés de dimensão  $M$  e  $\sigma$  é uma função de ativação aplicada elemento a elemento.

Essas camadas também são importantes durante o aprendizado de representações hierárquicas, permitindo que a rede capture padrões complexos e não lineares nos dados. Através do ajuste dos pesos durante o treinamento, a rede aprende a associar características específicas nas entradas com as saídas desejadas, permitindo a extração de características discriminativas.

Figura 11 – Exemplo de arquitetura de rede com camadas totalmente conectadas.



Fonte: Autor

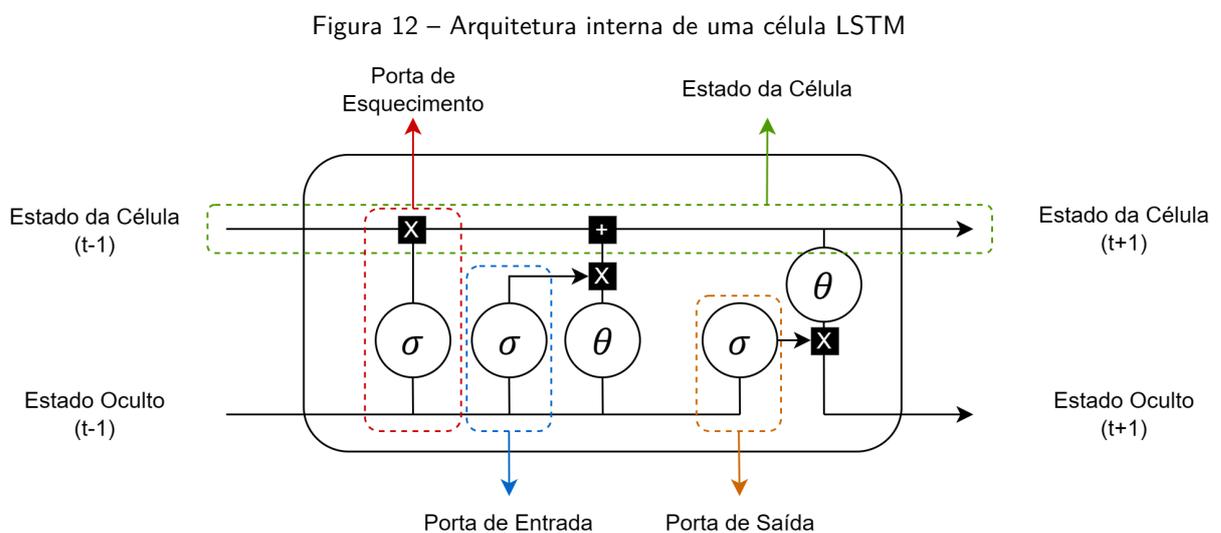
Conforme ilustrado na Figura 11, uma arquitetura de rede pode incluir várias camadas totalmente conectadas, as quais podem ser referidas como camadas ocultas. No entanto, o uso excessivo de camadas FC pode resultar em uma grande quantidade de parâmetros na

rede, aumentando o risco de *overfitting*. Esse risco é especialmente alto em conjuntos de dados pequenos, pois a rede pode se ajustar perfeitamente aos dados de treinamento, não conseguindo generalizar para novos dados. Portanto, é importante dimensionar a rede de forma apropriada, buscando um equilíbrio entre a capacidade de aprendizado e a generalização através do ajuste adequado do número de camadas e neurônios.

#### 2.4.3.2 Long Short-Term Memory (LSTM)

As Redes Neurais Recorrentes (RNNs) têm sido amplamente utilizadas em diversas aplicações de aprendizado de máquina, especialmente em tarefas que envolvem sequências temporais. No entanto, as RNNs tradicionais apresentam desafios ao lidar com dependências temporais de longo prazo, devido ao problema do gradiente (NOH, 2021), que pode dificultar o treinamento. Nesse contexto, a Long Short-Term Memory (LSTM) (HOCHREITER; SCHMIDHUBER, 1997) surgiu como uma solução eficaz para superar essas limitações.

Uma LSTM é projetada para capturar e guardar informações relevantes ao longo de sequências temporais. A arquitetura de uma LSTM incorpora unidades de memória com portas (*gates*), permitindo o controle do fluxo de informações, tornando-as úteis na modelagem de relações temporais de longo prazo. Ao contrário das RNNs convencionais, a LSTM possui mecanismos internos de esquecimento e atualização, tornando-as mais eficientes na captura de padrões complexos e na preservação de informações importantes.



Fonte: Autor

A Figura 12 destaca as unidades de memória dotadas de portas que caracterizam as LSTMs,

onde  $\sigma$  é a função de ativação Sigmoid e o  $\theta$  é a função de ativação tangente hiperbólica. Cada célula LSTM possui três portas principais: a porta de esquecimento (*forget gate*), a porta de entrada (*input gate*) e a porta de saída (*output gate*). Essas portas são fundamentais para regular o fluxo de informações na célula, permitindo a filtragem e o armazenamento de dados importantes. A porta de esquecimento determina quais informações antigas da célula de memória devem ser excluídas, enquanto a porta de entrada decide quais novas informações devem ser armazenadas e a porta de saída controla a informação que será enviada para a próxima célula de tempo. O Estado Oculto, algumas vezes denotado por  $h_t$ , representa a informação armazenada pela célula até o instante  $t$ , sendo a principal saída da célula, e guarda a representação aprendida da sequência até o momento. O Estado da Célula é a memória interna da célula LSTM, armazenando informações ao longo do tempo e sendo modificada pelas operações das portas de esquecimento, entrada e saída.

Devido à sua capacidade de processar dados sequenciais, como séries temporais, a LSTM se tornou bastante conhecida para lidar com variáveis de processos industriais (JALAYER; ORSENIGO; VERCELLIS, 2021). Entretanto, as LSTMs podem sofrer *overfitting* em conjuntos de dados pequenos, além de ter alta complexidade computacional. Por isso, é necessário considerar as suas características, avaliando tanto as vantagens quanto as possíveis limitações associadas a essa arquitetura. Esses pontos serão explorados mais detalhadamente no decorrer deste trabalho.

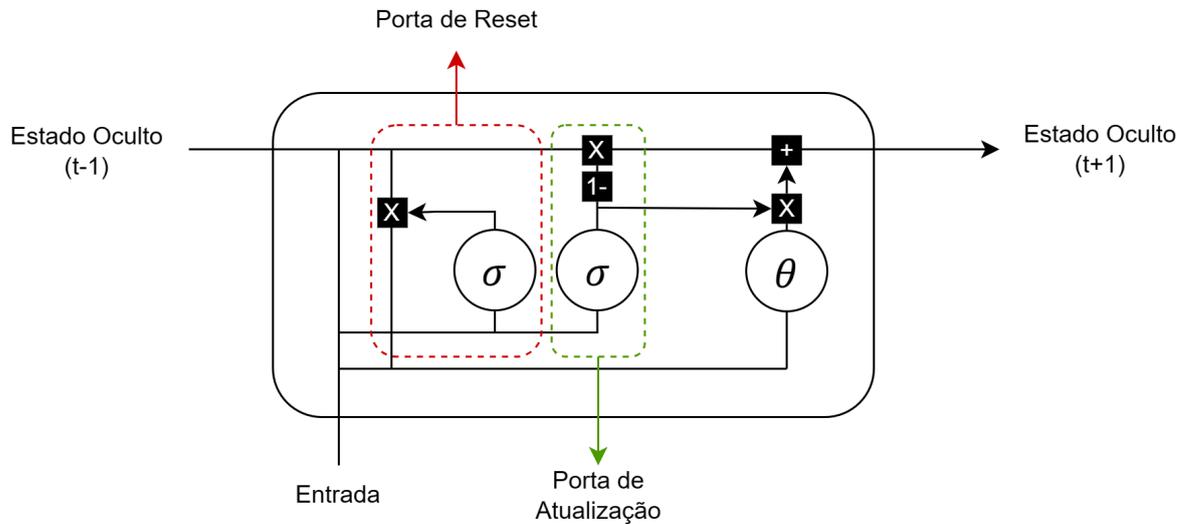
#### 2.4.3.3 Gated Recurrent Unit (GRU)

A Gated Recurrent Unit (GRU) (CHO et al., 2014) é uma alternativa eficaz às arquiteturas tradicionais de RNNs. Ela oferece uma abordagem mais simples e eficiente para modelar dependências temporais em dados sequenciais. Essa simplicidade pode ser útil em cenários nos quais a complexidade da solução final não pode ser alta, sem que isso comprometa o desempenho do resultado.

A Figura 13 destaca as principais operações que ocorrem em uma célula GRU, onde  $\sigma$  é a função de ativação Sigmoid e o  $\theta$  é a função de ativação tangente hiperbólica. Diferente da LSTM, a GRU combina o estado da célula com o estado oculto, simplificando a estrutura. Ao final, uma célula GRU é composta apenas pela porta de *reset* e a porta de atualização.

O Estado Oculto representa a informação acumulada até o instante  $t$ . A Porta de *Reset* controla a quantidade de informação do estado anterior que deve ser mantida ou esquecida,

Figura 13 – Arquitetura interna de uma célula GRU



Fonte: Autor

modulando a influência do estado anterior no cálculo do estado atual. A Porta de Atualização decide quanto da informação do estado anterior deve ser combinada com a nova informação proposta. Essa simplicidade permite uma computação mais eficiente em comparação com as LSTMs (YANG; YU; ZHOU, 2020), tornando-as uma boa escolha em determinadas situações.

#### 2.4.4 Regularização

[TODO]: Regularização L1

As técnicas de regularização são essenciais durante o treinamento de redes neurais. Seu destaque reside na capacidade de mitigar problemas relacionados ao sobreajuste (*overfitting*). Quando uma rede neural é treinada em um conjunto de dados específico, há o risco de ela se adaptar excessivamente aos padrões desse conjunto, prejudicando sua capacidade de generalização para dados não vistos.

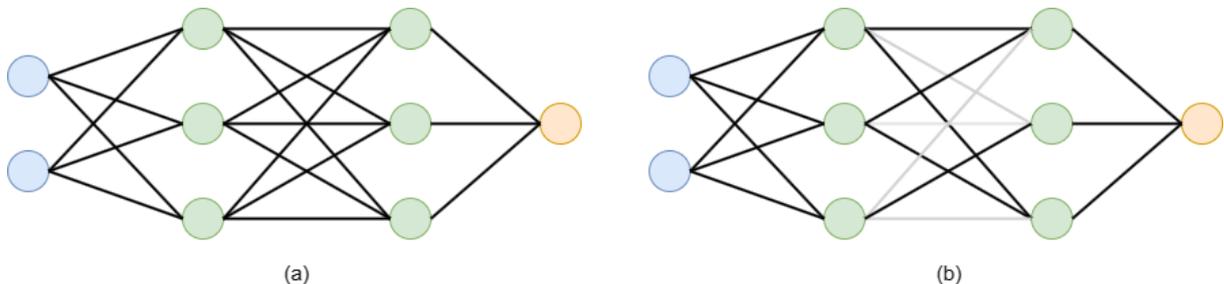
As técnicas de regularização, como *dropout*, L2 ou *early stopping*, atuam como mecanismos preventivos, modificando o processo de treinamento e a estrutura da rede para impedir que unidades neurais se tornem excessivamente dependentes entre si e, assim, promovendo uma aprendizagem mais robusta. Essas técnicas são essenciais na construção de modelos mais generalizáveis, robustos e eficazes, garantindo que as redes neurais não apenas memorizem padrões específicos de treinamento, mas também capturem de maneira mais precisa os princípios subjacentes dos dados, resultando em melhor desempenho em tarefas de classificação,

regressão e outras aplicações.

#### 2.4.4.1 Dropout

O *dropout* foi apresentado por HINTON et al. (2012) e é uma técnica de regularização que consiste em, durante o processo de treinamento de uma rede neural, desativar aleatoriamente uma parcela das unidades neurais assim como demonstrado na Figura 14. Essa técnica tem sido extensamente adotada para aprimorar o desempenho de redes neurais em diversas tarefas, abrangendo desde classificação e regressão até a detecção de objetos.

Figura 14 – Em (a) um exemplo de um modelo de rede neural sem o uso do *dropout*. Em (b) o mesmo modelo, porém utilizando a técnica de *dropout* entre as camadas ocultas.



Fonte: Autor

O *dropout* exerce um efeito de regularização por duas razões fundamentais: primeiramente, ele evita a formação de dependências excessivas entre as unidades neurais. Em segundo lugar, obriga a rede neural a desenvolver representações mais robustas, menos suscetíveis a pequenas variações nos dados de entrada. O uso do *dropout* no treinamento também demanda um aumento no tempo necessário, uma vez que em alguns casos notou-se que sua aplicação pode dobrar a quantidade de iterações exigidas para que o treinamento atinja a convergência (KRIZHEVSKY; SUTSKEVER; HINTON, 2012).

#### 2.4.4.2 Regularização L2

A regularização L2, também conhecida como regressão Ridge, baseia-se no princípio da Navalha de Occam. Esse princípio sugere que a explicação mais simples para um fenômeno é geralmente a melhor, pois ela tende a capturar os conceitos fundamentais do problema (ROUGHGARDEN; VALIANT, 2016). A técnica de regularização L2 introduz um termo de penalização na função de custo do modelo, representado pelo parâmetro  $\lambda$ , que penaliza parâmetros

excessivamente grandes. Ajustando o valor de  $\lambda$ , podemos equilibrar a complexidade do modelo com sua capacidade de generalização. A função de custo original é modificada conforme mostrado na Equação 2.8

$$E(\vec{w}) = \text{Custo}(\vec{w}) + \lambda \|\vec{w}\|^2 \quad (2.8)$$

Onde, *Custo* representa a função de custo original,  $\|\vec{w}\|$  é a distância euclidiana dos componentes  $w_i$ , e  $\lambda$  é uma constante que controla a intensidade da regularização. Como resultado, os pesos  $\vec{w}$  tendem a valores próximos de 0, gerando modelos mais simples.

#### 2.4.4.3 *Early Stopping*

A técnica de *early stopping*, ou parada antecipada, representa uma estratégia importante durante o treinamento de redes neurais, visando evitar o *overfitting* do modelo. Essa abordagem consiste em monitorar o desempenho da rede neural durante o treinamento e interromper o processo assim que a performance de validação deixar de melhorar. Ao identificar o momento e impedir que o modelo comece a memorizar os dados de treinamento em vez de generalizar padrões, o *early stopping* contribui significativamente para a prevenção da perda de capacidade de generalização da rede.

O *early stopping* também oferece benefícios adicionais, como a redução do tempo de treinamento e a eficiência no uso dos recursos computacionais. Ao interromper o treinamento assim que a performance estabiliza, evita-se a continuação desnecessária do processo, economizando tempo e recursos computacionais. Essa técnica demonstra-se essencial na busca por modelos mais eficazes e eficientes, contribuindo para a obtenção de redes neurais bem ajustadas e capazes de generalizar de forma mais assertiva para dados não vistos.

#### 2.4.5 Otimizadores

O processo de otimização refere-se ao reajuste dos pesos de um modelo para que este possa realizar previsões mais precisas e generalizadas. Os otimizadores são algoritmos que direcionam a atualização iterativa dos pesos, utilizando informações do gradiente da função de perda em relação aos parâmetros do modelo. Eles desempenham um papel muito importante no treinamento de redes neurais, influenciando a velocidade e a estabilidade do processo de

treinamento. Compreender os diferentes algoritmos de otimização, como o SGD e o ADAM, é fundamental para aprimorar a eficiência e o desempenho das redes neurais em diversas tarefas de aprendizado de máquina.

#### 2.4.5.1 *Stochastic Gradient Descent (SGD)*

O Stochastic Gradient Descent (SGD) (ROBBINS, 1951) é um otimizador bastante utilizado para o treinamento de modelos de aprendizado de máquina. O seu cerne é a atualização iterativa dos pesos do modelo baseada na derivada parcial do erro em relação a cada parâmetro. Essa abordagem tem o objetivo de minimizar a função de perda ao longo do tempo, ajustando os pesos do modelo na direção oposta ao gradiente. O SGD apresenta algumas limitações. Em particular, a sua natureza estocástica pode resultar em oscilações durante o processo de convergência, levando a um processo de otimização mais demorado e, em alguns casos, a uma convergência apenas para um mínimo local.

Outro grande desafio é a taxa de aprendizado constante no otimizador SGD, pois encontrar um valor adequado para todo o processo de treinamento pode ser uma tarefa complexa. O uso de taxas de aprendizado muito altas pode resultar em oscilações, enquanto taxas muito baixas podem tornar o treinamento bastante lento. Essas limitações motivaram a pesquisa e desenvolvimento de otimizadores mais avançados, como o ADAM, que busca superar esses desafios.

#### 2.4.5.2 *Adaptive Moment Estimation (ADAM)*

O Adaptive Moment Estimation (ADAM) (KINGMA; BA, 2014) é um otimizador que combina conceitos do SGD com técnicas adaptativas de ajuste de taxa de aprendizado. O ADAM mantém dois momentos para cada parâmetro do modelo, sendo o primeiro momento uma média móvel do gradiente e o segundo momento uma média móvel dos gradientes ao quadrado. Esses momentos adaptativos permitem que o ADAM ajuste automaticamente a taxa de aprendizado para cada parâmetro, proporcionando um processo de treinamento mais estável e eficiente.

Uma das principais vantagens do ADAM é a sua capacidade de trabalhar com diferentes taxas de aprendizado para cada parâmetro. Isso permite que o otimizador se adapte dinamicamente às características específicas de cada peso no modelo, superando as limitações do SGD

em termos de velocidade de convergência e evitando mínimos locais. Além disso, o ADAM integra uma correção de viés, tornando-o particularmente eficaz em problemas de otimização com grandes conjuntos de dados e alta dimensionalidade.

### 3 TRABALHOS RELACIONADOS

O propósito deste trabalho consiste em aprimorar o processo de avaliação dos riscos associados aos equipamentos da indústria de petróleo e gás por meio da implementação de um algoritmo de previsão baseado em séries temporais. Nesse contexto, este capítulo introduz e discute soluções previamente abordadas na literatura, com o intuito de identificar suas limitações e extrair percepções que contribuíram para o refinamento da técnica construída nesta pesquisa.

Na literatura, é possível encontrar diversos trabalhos que empregaram algoritmos para a análise de riscos em equipamentos industriais. Esta seção organiza esses trabalhos em duas categorias distintas: aqueles que empregaram modelos probabilísticos para calcular as probabilidades de um determinado evento e aqueles que utilizaram redes neurais artificiais para reconhecer padrões e construir modelos de inferência.

#### 3.1 MODELOS PROBABILÍSTICOS

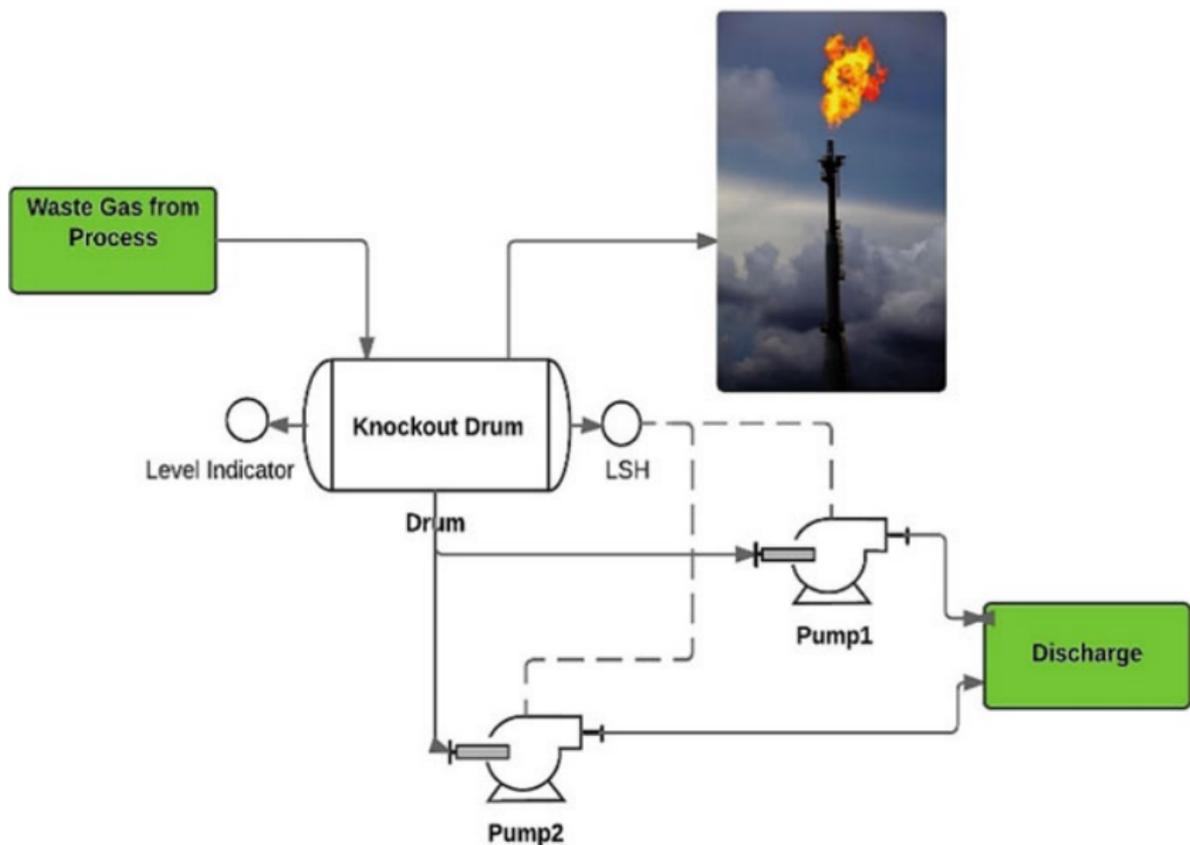
Os modelos probabilísticos são frequentemente utilizados durante a análise de risco em equipamentos industriais. Esses modelos são essenciais para quantificar e compreender os diversos fatores que influenciam a segurança e confiabilidade desses equipamentos. Ao concentrar-se na aplicação de redes bayesianas, especificamente, os modelos probabilísticos revelam-se eficazes na representação das relações de dependência condicional entre as variáveis observadas. A capacidade das redes bayesianas de lidar com incertezas as torna uma escolha promissora para a avaliação de riscos, além de sua natureza gráfica, que permite uma visualização intuitiva das ligações entre os elementos do sistema, facilitando a identificação de pontos críticos e a tomada de decisões fundamentadas.

Para o desenvolvimento de uma rede bayesiana destinada à análise de risco, é necessário identificar todos os possíveis riscos associados ao equipamento, bem como as variáveis relevantes que podem influenciar esses riscos. Esse processo exige amplo conhecimento do funcionamento do equipamento em análise. No entanto, é possível encontrar na literatura alguns trabalhos que buscam auxiliar nesse processo de mapeamento. WU et al. (2023) apresenta uma técnica de mapeamento a partir de um diagrama bow-tie, que permite a sua conversão em uma rede bayesiana. Essa abordagem ajuda a identificar quais barreiras de segurança são

críticas e a explorar possíveis cenários de acidentes.

ALAUDDIN et al. (2020) explora a criação de uma rede bayesiana para o evento de transbordamento de líquidos em um sistema de queima *offshore*. A Figura 15 mostra o diagrama de tubulação e instrumentação do sistema em estudo. O vaso knockout é equipado com um indicador de nível que tem o objetivo de controlar o sistema de bombeamento para regular a vazão volumétrica. A falha do sistema de bombeamento pode ocasionar o excesso de líquido no vaso, levando a transbordamentos e a situações mais graves como incêndio e explosão.

Figura 15 – Diagrama de Tubulação e Instrumentação de um sistema flare



Fonte: ALAUDDIN et al. (2020)

Conhecendo os fatores de risco do sistema, os autores esquematizaram o diagrama bow-tie do processo, identificando as causas, as barreiras de segurança, as consequências e seus impactos, tendo o transbordamento de líquido considerado como o evento topo do diagrama. Para este estudo, os autores consideraram como barreiras os indicadores de nível, a inspeção em campo pelos operadores e a central de monitoramento. Foram rastreados 6 níveis de consequências, sendo eles: C1 - transbordamento sem perdas (controlado); C2, C5 - transbordamento de líquido inflamável com pouco ou moderado dano; C3, C6 - transbordamento de

líquido inflamável, incêndio em poça e alto dano; C4 - transbordamento de líquido inflamável com baixo dano.

As probabilidades dos eventos básicos que serviram como base para o cálculo das probabilidades das barreiras de segurança foram extraídas dos trabalhos TALEBBERROUANE; KHAN; LOUNIS (2016) e OREDA (2002). Após a construção de uma tabela de probabilidade condicional, as taxas de probabilidade de falhas das barreiras de indicador de nível, inspeção em campo e central de monitoramento foram de 0.02, 0.2 e 0.05, respectivamente.

A rede bayesiana demonstrou que, em caso de transbordamento em condições normais de operação, existem 91% de chances da consequência ser apenas um transbordamento controlado (C1). Entretanto, a probabilidade das consequências mais graves (C4, C5 e C6) aumentam significativamente à medida que ocorrem mais falhas, principalmente após a ocorrência do transbordamento. Este trabalho mostrou que as redes bayesianas são ferramentas robustas para o cálculo de probabilidades na análise de riscos. No entanto, a técnica utilizada neste trabalho exigiu o conhecimento de especialistas para calcular as probabilidades, além de considerar que estes valores são estáticos, não se ajustando em tempo real. Deste modo, este trabalho apresentou uma abordagem interessante para rastrear quais barreiras de segurança têm um papel chave para evitar acidentes, porém não pode ser utilizada como um sistema de monitoramento ativo.

Com o avanço do processo da digitalização da indústria, as técnicas de avaliação probabilística de risco (PRA) tendem a se tornar cada vez mais dinâmicas. HE et al. (2022) apresentam um método de avaliação de risco probabilístico em tempo real para a indústria petroquímica, baseado no monitoramento de dados. O método combinou a análise de risco probabilístico com a rede bayesiana dinâmica (DBN) para integrar o conhecimento prévio e os dados online na estimativa do risco de eventos básicos e acidentes. O método também utilizou o modelo de mistura gaussiana (GMM) e o filtro de partículas (PF) para construir um modelo não linear para os nós de processo, que são afetados pelas condições operacionais variáveis. O método não requer dados históricos de acidentes ou conhecimento de especialistas para definir a relação condicional entre o monitoramento de dados e o risco prévio.

O método é composto por quatro etapas principais: (1) determinar o tipo de evento para cada evento básico na árvore de falhas (FT); (2) estimar a probabilidade de cada evento dinâmico exceder o limiar do alarme; (3) integrar a probabilidade do alarme com a probabilidade prévia de cada evento dinâmico usando um modelo de DBN; (4) atualizar o risco de cada evento básico e do evento topo em tempo real e estimar o índice de risco posterior para identificar

---

os eventos críticos. O método foi aplicado em dois casos de estudo, sendo o primeiro caso um sistema que controla o nível de um tanque e o segundo caso um sistema de controle em operações de perfuração em águas profundas.

Os experimentos mostraram que este método foi capaz de capturar as variações no risco dos eventos básicos em tempo real. As soluções desenvolvidas com redes bayesianas dinâmicas são robustas e flexíveis, pois podem lidar com diferentes tipos de eventos e dados. Por não utilizar dados históricos, esse método exige a configuração de um valor de limiar para ativar ou desativar os alarmes, o que pode ocasionar falsos alertas em caso de má configuração dos alarmes ou se houver sensores com leituras defeituosas.

Os modelos probabilísticos, em geral, são facilmente interpretáveis devido à possibilidade de sua representação em formato gráfico, o que simplifica o processo de tomada de decisão. No entanto, ao lidar com uma quantidade extensa de informações, estabelecer relações entre as variáveis do sistema pode tornar-se uma tarefa complexa. Nesses casos, a complexidade do modelo pode aumentar, exigindo uma análise mais aprofundada e o emprego de técnicas mais avançadas para lidar com a dimensionalidade dos dados. Estratégias como a redução de dimensionalidade e técnicas de seleção de variáveis podem ser implementadas para facilitar a interpretação e a compreensão das interações complexas entre os elementos do modelo.

### 3.2 REDES NEURAIIS ARTIFICIAIS

As técnicas que utilizam redes neurais artificiais representam uma abordagem robusta no campo da inteligência artificial. Esses modelos são projetados para aprender padrões complexos e representações hierárquicas a partir de grandes conjuntos de dados. A capacidade de generalização desses modelos é uma característica importante para a avaliação de riscos em processos industriais, pois permite lidar com cenários inéditos baseados em comportamentos anteriores. No entanto, a eficácia desses modelos é dependente da qualidade e quantidade dos dados de treinamento, bem como de técnicas adequadas de otimização e regularização, dificultando o processo de desenvolvimento e aprendizado desses modelos.

Estratégias que incorporam a análise histórica por meio de séries temporais destacam-se como opções eficazes para a avaliação de riscos em tempo real, pois possibilitam a compreensão das variações e tendências presentes nos dados históricos, permitindo a projeção de cenários futuros com base em diversos fatores. Assim, ao aproveitar as informações registradas anteriormente pelos sensores, torna-se viável estimar as condições operacionais para um

período futuro específico.

YOLCHUYEV (2023) apresentam um modelo para previsão de falhas em equipamentos de poços de petróleo utilizando Rede Neural Feed-Forward (FFNN). Em geral, esses equipamentos podem apresentar problemas devido ao acúmulo de areia, corrosão, variação de pressão e outros fatores. Logo, para garantir o desempenho dos equipamentos e evitar grandes custos com perdas, é imprescindível identificar a origem dessas falhas ainda na fase inicial. A FFNN é uma técnica de rede neural artificial caracterizada por seu fluxo unidirecional, onde a informação flui sempre da camada de entrada para a camada de saída.

O conjunto de dados ConocoPhillips<sup>1</sup>, utilizado neste trabalho, é composto por 172 *features*, que incluem Id, variável alvo e dados dos sensores. Desses, 107 *features* são dados de leituras de sensores, mas somente 7 são séries temporais. Devido à natureza deste trabalho, os autores realizaram uma limpeza deste conjunto, se limitando a treinar o modelo apenas com essas 7 *features*.

Para avaliar o desempenho do modelo, este estudo empregou métricas como a pontuação F1, precisão, revocação e probabilidade de confiabilidade. A comparação dos resultados foi realizada com outros dois modelos distintos que utilizam classificadores Random Forest e árvore de decisão. O modelo proposto demonstrou precisão e pontuação F1 altamente competitivas em relação aos resultados previamente alcançados pelo estado da arte, superando esses modelos com uma acurácia de 97%. Esses resultados indicam que redes neurais do tipo FFNN podem representar uma escolha eficaz na análise de séries temporais. A eficácia observada pode ser atribuída à natureza unidimensional do conjunto de dados, uma vez que tanto as árvores de decisão quanto as redes neurais tendem a destacar-se em conjuntos de dados unidimensionais. No entanto, é importante notar que isso pode não ser válido em conjuntos de dados multidimensionais.

Alguns tipos de redes neurais recorrentes também ganharam destaque devido à sua eficiência em lidar com séries temporais. ZHANG et al. (2018b) apresentam um método para a previsão do status de funcionamento de um equipamento de uma estação de energia através de dados históricos, utilizando camadas LSTM. Este método alcança um erro quadrático médio menor quando comparado ao modelo ARIMA, mostrando a capacidade das redes LSTM em lidar com tarefas de análise em séries temporais.

Dependendo dos requisitos do desafio e da natureza dos dados, as redes que utilizam camadas LSTM também podem ser combinadas com outras camadas, como as GRU. Essa

<sup>1</sup> Disponível em: <<https://www.kaggle.com/c/equipfails/data>>

---

estratégia pode aumentar a capacidade de generalização do modelo, resultando em previsões mais robustas. LIU et al. (2023) propõem um método de previsão de condições anormais de operação, combinando conhecimentos físicos em um modelo de rede neural. Este método consiste em determinar qual deve ser a variável chave responsável pela condição anormal com base em um diagrama construído a partir do conhecimento físico do processo. Em seguida, utiliza-se o coeficiente de correlação de Spearman para extrair as *features* relacionadas à variável chave, reduzindo a dimensionalidade dos dados de entrada. Dessa forma, apenas as variáveis que são realmente importantes para a previsão são enviadas para a rede, diminuindo a taxa de erro devido à interferência de outras variáveis.

O método proposto para previsão utiliza um modelo baseado em LSTM-GRU para séries temporais multivariadas. Essa abordagem integra duas redes neurais recorrentes profundas, permitindo prever a tendência futura dos dados da variável chave. No estudo de caso, o modelo foi aplicado a uma condição anormal de óleo bruto com água em uma unidade de craqueamento catalítico. Os resultados indicam um desempenho de previsão superior em comparação com outros modelos. Além disso, a incorporação de conhecimento físico aos dados melhora a generalização e a interpretabilidade do modelo.

### 3.3 CONSIDERAÇÕES FINAIS

Estes estudos fornecem contribuições valiosas para a aplicação de algoritmos de inteligência artificial na avaliação de riscos em equipamentos e processos industriais. Na Tabela 1, é apresentado uma visão geral das características mais importantes de cada trabalho.

Tabela 1 – Visão geral dos trabalhos relacionados

Autores e ano de publicação	Modelo	Base de dados	Tempo Real?	Técnica	Vantagens	Desvantagens
ALAUDDIN et al. (2020)	Probabilístico	TALEBBEROUANE; KHAN; LOUNIS (2016); OREDA (2002)	Não	Rede bayesiana	(1) A rede calcula a probabilidade de falhas em cada etapa do processo. (2) Explora a interdependência entre os eventos básicos e as consequências no sistema.	(1) Os valores de probabilidades são estáticos. (2) Exige conhecimento de especialistas para definir os valores de probabilidades.
HE et al. (2022)	Probabilístico	OREDA (2002)	Sim	Rede bayesiana dinâmica	(1) Não requer conhecimento adicional de especialistas.	(1) Exige que seja informado um valor de limiar para ativar os alarmes. A má configuração pode gerar falsos alertas.
YOLCHUYEV (2023)	Rede neural artificial	ConocoPhillips	Sim	FC (FFNN)	(1) Modelo de alta precisão, alcançando 97% de acurácia. (2) Modelo simples que pode ser utilizado em IoT.	(1) Não prevê problemas nos estágios iniciais.
ZHANG et al. (2018b)	Rede neural artificial	Privado	Sim	LSTM (RNN)	(1) Obteve erro quadrático menor quando comparado ao ARIMA.	(1) O modelo não realiza previsões de várias unidades de tempo futuras.
LIU et al. (2023)	Rede neural artificial	Privado	Sim	LSTM-GRU (RNN)	(1) Combinação de conhecimento físico e o modelo baseado em dados, melhorando a generalização e a interpretabilidade da previsão.	(1) Desempenho pouco maior se comparado ao modelo GRU, porém modelo final mais complexo.

**Fonte:** Autor

Em termos gerais, abordagens que empregam modelos probabilísticos são preferíveis quando a fácil compreensão dos resultados for um requisito essencial. As redes bayesianas já encontram aplicação nos estudos de riscos de equipamentos, permitindo assim que todo o conhecimento acumulado ao longo dos anos e a documentação existente sejam reaproveitados para a criação de redes bayesianas dinâmicas, especialmente úteis em análises em tempo real.

Com o surgimento da IIoT, as indústrias começaram a armazenar anos de dados provenientes da leitura de sensores em seus bancos de dados. Assim, técnicas de rede neural artificial ganham destaque devido à sua habilidade em compreender padrões complexos e identificar relações entre as variáveis do processo. Essas técnicas oferecem previsões com boa taxa de assertividade, sendo capazes de auxiliar os operadores nas tomadas de decisões por meio da inferência de comportamentos futuros com base em informações passadas.

## 4 TÉCNICA DE ANÁLISE DE RISCO BASEADA EM SÉRIES TEMPORAIS

Este capítulo apresenta a técnica proposta para a análise de risco em equipamentos industriais, fundamentada na avaliação de séries temporais. Para o desenvolvimento deste estudo, elaboramos uma simulação de um vaso knockout em um simulador dinâmico, visando a coleta de dados de treinamento e a simulação de situações de risco. Nosso modelo emprega camadas LSTM, conforme sugerido por ZHANG et al. (2018b), para analisar os dados provenientes dos sensores e efetuar previsões sobre o comportamento do nível de líquido. Este enfoque visa diminuir o risco de *trips* na planta industrial, evitando a parada de equipamentos essenciais. A análise do risco acontece em tempo real, e as informações geradas pelo modelo de previsão são apresentadas por meio de uma interface gráfica simples, visando aprimorar a capacidade de tomada de decisões por parte dos operadores.

### 4.1 METODOLOGIA

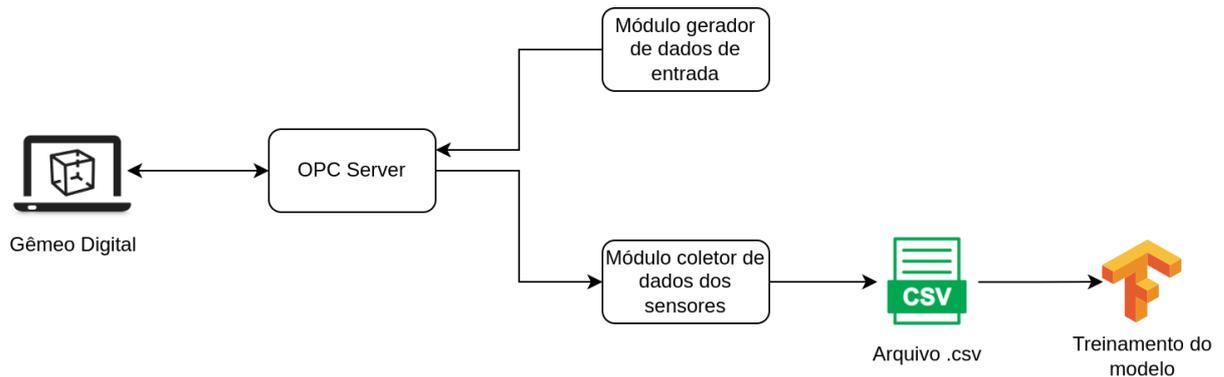
Realizar a análise de risco por meio de algoritmos baseados em dados é um desafio, principalmente devido à dificuldade em obter um conjunto de dados que contenha informações sobre o estado dos sensores diante de situações de risco. Além disso, a análise em tempo real torna-se um desafio significativo devido à constante geração de dados por um grande número de sensores. Isso demanda que tais soluções sejam cuidadosamente arquitetadas para enfrentar os desafios cotidianos de um ambiente de produção real.

Para conduzir nosso estudo, desenvolvemos um DTE de um vaso knockout no software AVEVA Dynamic Simulation<sup>1</sup>, que permitiu simular diversos comportamentos para coletarmos os dados necessários para o treinamento e também avaliar o modelo e técnica de análise. O simulador possibilita o envio dos valores de leitura dos sensores para softwares externos, assim como receber comandos enviados por outros softwares, a fim de controlar componentes do sistema. Essa comunicação é efetuada por meio do padrão OPC, apresentado na seção 4.3.

A Figura 16 apresenta um diagrama que ilustra os módulos desenvolvidos para a coleta do conjunto de dados de treinamento. Esses módulos estabelecem comunicação com o gêmeo digital por meio de um servidor OPC, transmitindo dados para a simulação e armazenando os resultados. O objetivo é gerar situações aleatórias, de risco ou não, para capturar informações sobre o comportamento do vaso durante essas situações. Essas informações são posteriormente

<sup>1</sup> Disponível em: <<https://www.aveva.com/en/products/dynamic-simulation/>>

Figura 16 – Módulos para extração de dados de treinamento



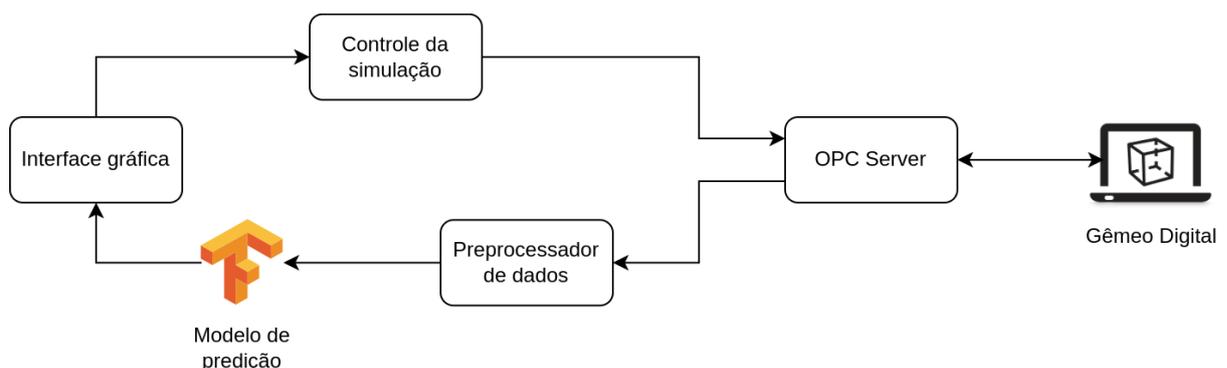
Fonte: Autor

utilizadas no treinamento do modelo de rede neural.

Para a predição do risco em tempo real, a arquitetura da solução pode ser visualizada no diagrama apresentado na Figura 17. O gêmeo digital envia, por meio de um servidor OPC, os valores coletados pelos sensores. Esses valores passam por uma etapa de pré-processamento, na qual são preenchidos os valores ausentes através da interpolação, normalizados e selecionadas apenas as variáveis esperadas pelo modelo. Em seguida, esses valores são direcionados para o modelo preditivo, que realiza previsões com o objetivo de exibir o comportamento futuro esperado. Essas previsões são apresentadas por meio de uma interface gráfica simples, onde o operador pode acompanhá-las por meio de um gráfico e decidir pelo controle automático da fonte de gás que alimenta o vaso.

Esse controle pode optar por desligar a entrada de gás contaminado da refinaria e ligar a entrada de gás da concessionária, fornecendo gás livre de contaminantes assim que o risco de *trip* for detectado. Dessa forma, a ativação do *trip* é evitada, pois o líquido presente no vaso se estabiliza enquanto o gás continua alimentando os processos subsequentes.

Figura 17 – Módulos para predição de riscos em tempo real



Fonte: Autor

Nossa técnica de análise de risco em tempo real foi dividida em módulos com o objetivo principal de facilitar o desenvolvimento. Essa modularização permite que melhorias e atualizações possam ser implementadas com um esforço consideravelmente reduzido, otimizando o processo de aprimoramento contínuo. Além disso, a comunicação assíncrona entre os componentes é um elemento essencial para as aplicações em ambientes industriais reais. Isso se deve à grande quantidade de dados gerados constantemente nesses ambientes, tornando-a essencial para o gerenciamento eficiente desses dados. Portanto, a combinação de modularização e comunicação assíncrona contribui significativamente para a eficácia e eficiência da técnica de análise de risco proposta.

## 4.2 GÊMEO DIGITAL DE UM VASO KNOCKOUT

O vaso knockout é um componente muito importante em alguns processos industriais. Embora sua operação seja simples, exige atenção especial devido à possibilidade de ocorrência de falhas que, se não forem mitigadas corretamente, podem resultar na interrupção das atividades na planta industrial.

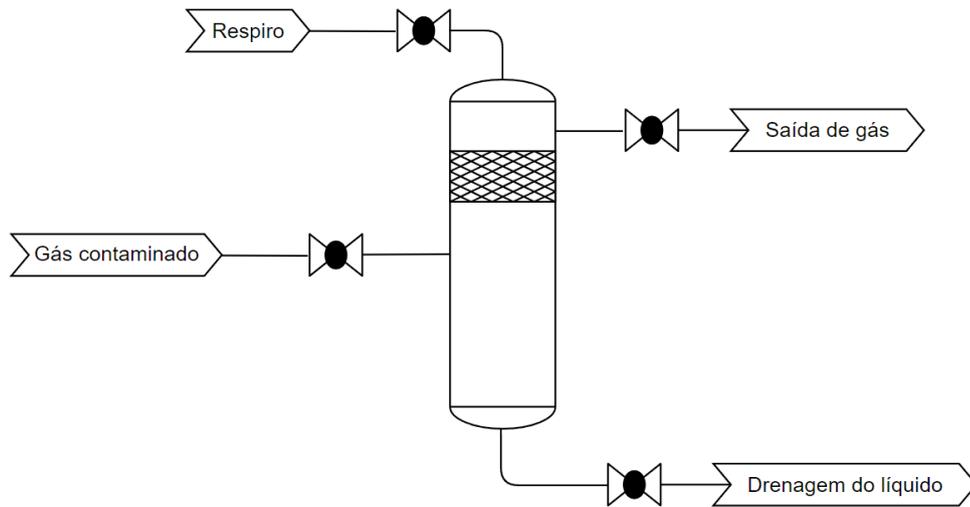
### 4.2.1 Funcionamento de um vaso knockout

Um vaso knockout é projetado para separar de maneira eficiente as fases gasosas e líquidas presentes em um fluxo de gás contaminado, sendo essencial para garantir a pureza deste gás, que será direcionado para outros processos subsequentes.

Ao entrar no vaso knockout, o gás contaminado tem sua velocidade drasticamente reduzida, facilitando a separação das partículas líquidas presentes no fluxo através da ação da gravidade. As impurezas se acumulam no fundo do recipiente, formando uma camada, enquanto o gás purificado migra para a parte superior do vaso. A Figura 18 apresenta um diagrama de exemplo do funcionamento de um vaso knockout.

Enquanto isso, a retirada do líquido acumulado é realizada por meio de um sistema de drenagem localizado na parte inferior do vaso. Esse líquido geralmente provém de falhas em processos anteriores que podem causar a contaminação do gás. O gás purificado, agora livre das partículas indesejadas, é encaminhado para outros estágios do processo industrial, garantindo que os próximos equipamentos operem com mais segurança.

Figura 18 – Diagrama simplificado do funcionamento de um vaso knockout



Fonte: Autor

#### 4.2.2 Análise de riscos

O mau funcionamento de um vaso knockout pode resultar tanto em danos aos equipamentos quanto em prejuízos financeiros. Isso ocorre porque tal falha pode interromper a operação de equipamentos que dependem do gás processado por esse dispositivo. Se o vaso knockout não conseguir realizar uma separação eficaz entre as fases gasosas e líquidas, as contaminações podem continuar a persistir no fluxo de gás. Isso, por sua vez, pode comprometer a integridade do processo e aumentar o risco devido à severidade decorrente de uma explosão em um ambiente confinado, como um gerador de vapor.

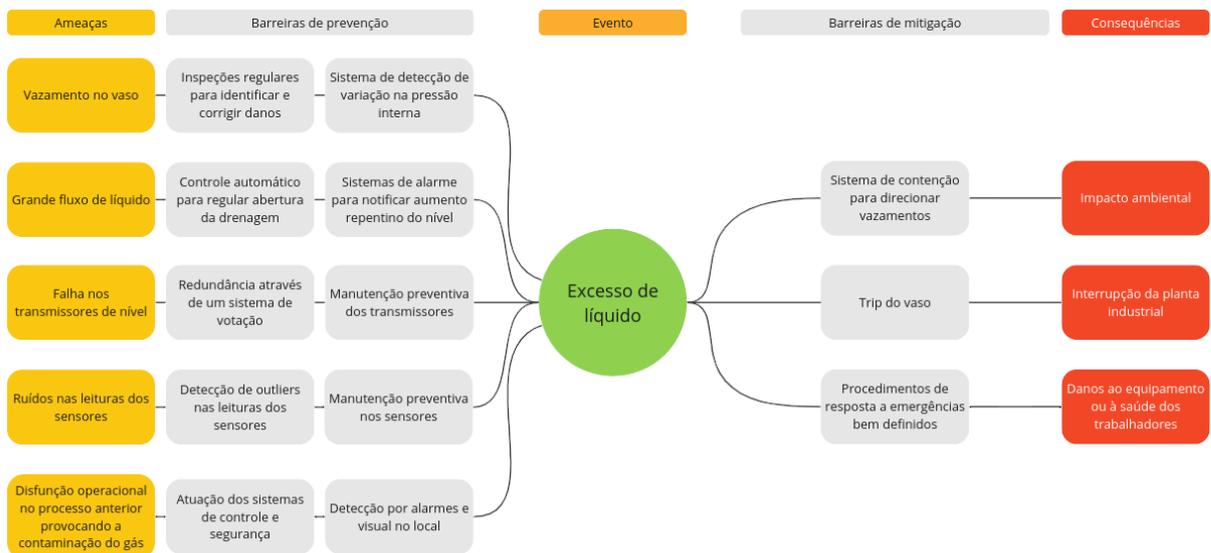
Falhas operacionais ou de manutenção podem impedir o escoamento adequado do líquido, resultando em seu acúmulo no interior do recipiente. Esse cenário representa um risco para a estabilidade do processo, pois o acúmulo de líquido pode resultar na ativação do trip como uma barreira de mitigação. O trip é uma medida destinada a interromper o fluxo de gás para evitar que o líquido ultrapasse um nível que possa entrar nas tubulações de saída de gás, potencialmente extinguindo as chamas dos equipamentos subsequentes alimentados pela saída do vaso. Se as chamas forem extintas, pode ocorrer o acúmulo de gás no interior do equipamento, resultando em uma explosão sem necessariamente haver uma fonte de ignição, pois neste ambiente há energia térmica suficiente para causar a ativação.

Dadas as possíveis consequências, torna-se essencial a realização de análises de risco dos equipamentos e dos processos, a fim de desenvolver planos de ação eficazes na prevenção e mitigação dos riscos. Essas análises também são fundamentais para que outras iniciativas

possam ser realizadas com o objetivo de aprimorar o processo. Por exemplo, as documentações criadas durante as análises podem ser utilizadas durante o desenvolvimento de modelos virtuais, possibilitando que os cenários de risco, as barreiras de segurança e as medidas de mitigação sejam implementadas no modelo, tornando-o fiel ao ambiente real.

Dentre outras abordagens amplamente adotadas para análises de risco, destaca-se a elaboração de um diagrama bow-tie. Esse diagrama identifica as ameaças, as barreiras de prevenção, as barreiras de mitigação e as consequências de um evento específico. A Figura 19 apresenta um diagrama bow-tie elaborado com o objetivo de rastrear as ameaças que podem levar ao excesso de líquido interno no vaso. Esse diagrama contempla apenas um subconjunto dos riscos presentes na operação de um vaso.

Figura 19 – Diagrama bow-tie do vaso knockout



Fonte: Autor

Essa análise é essencial para identificar e evitar ameaças que possam desencadear o evento indesejável. Como primeira ameaça, identificamos um possível vazamento no vaso que representa uma ameaça significativa, pois pode perturbar o equilíbrio da pressão interna do vaso, comprometendo a assertividade das decisões tomadas pelos controladores. Para prevenir essa situação, recomenda-se realizar inspeções regulares para detectar e corrigir danos, além de implementar um sistema de detecção de variações incomuns na pressão interna, que alerte os operadores para que as medidas apropriadas sejam tomadas.

Outra ameaça detectada é o excesso de líquido entrando pela tubulação de gás, que pode resultar em seu acúmulo dentro do vaso. Para prevenir o avanço desse risco, é fundamental controlar automaticamente a drenagem, ajustando-a de acordo com o fluxo de entrada, e

---

utilizar sistemas de alarme capazes de identificar aumentos repentinos no nível, para que os operadores sejam informados da ameaça.

Além disso, a ocorrência de falhas nos transmissores de nível representa outra possível ameaça: esses transmissores são essenciais para o correto funcionamento do sistema. Portanto, é essencial que eles operem em um sistema de redundância através de votação, onde o transmissor com leitura diferente dos demais tem seu valor descartado. A manutenção preventiva desses transmissores também é uma barreira de prevenção que pode evitar a ocorrência dessa ameaça.

A presença de ruídos nas leituras dos sensores e falhas diversas nos sistemas de comunicação com a sala de controle, que pode estar a distâncias que variam de metros a quilômetros, são condições que também podem afetar o funcionamento seguro do processo. As informações capturadas por esses sensores são amplamente utilizadas pelos controladores para ajustar o funcionamento do sistema e tomar algumas decisões, como o controle de abertura ou fechamento de válvulas, entre outros. A detecção da leitura incorreta desses valores pode ser realizada através do reconhecimento de *outliers*, uma vez que os ruídos podem fazer com que esses sensores registrem valores muito diferentes do seu histórico. A manutenção preventiva desses sensores também é essencial para garantir o pleno funcionamento do sistema.

Por fim, a disfunção operacional no processo anterior ao vaso pode causar a contaminação do gás. Para mitigar os impactos dessa ameaça, a atuação dos sistemas de controle e segurança se faz necessária, bem como a detecção através de alarmes ou inspeções visuais no local. Evitar essa contaminação impede que o acúmulo de líquido ocorra, prevenindo a ocorrência do evento principal.

Cada barreira possui suas próprias limitações e falhas potenciais, sendo estas análogas às camadas do modelo do queijo suíço apresentado na Seção 2.1.2. Caso as falhas das barreiras de prevenção se alinhem, o evento principal pode ocorrer, gerando transtornos. Portanto, a análise contínua, revisão e melhoria dessas barreiras são fundamentais para fortalecer a resiliência do sistema e prevenir acidentes.

É de suma importância identificar as consequências a fim de desenvolver barreiras de mitigação que possam impedir ou suavizar os danos causados pela ocorrência de eventos. Em nossa análise, as ameaças identificadas apresentam consequências graves, exigindo a implementação de medidas de mitigação eficientes. O impacto ambiental decorrente de um vazamento no vaso pode ser reduzido por meio da implementação de um sistema de contenção capaz de direcionar os vazamentos, minimizando assim os danos ao meio ambiente. Outra consequência

crítica é a interrupção da planta industrial em condição de emergência, que pode ser causada pela ativação do trip, um dispositivo de segurança que visa evitar o prosseguimento da cadeia de eventos. Além disso, danos ao equipamento ou à saúde dos trabalhadores podem ser amenizados por meio da definição clara de procedimentos de resposta a emergências.

### 4.2.3 Modelagem do vaso no simulador dinâmico

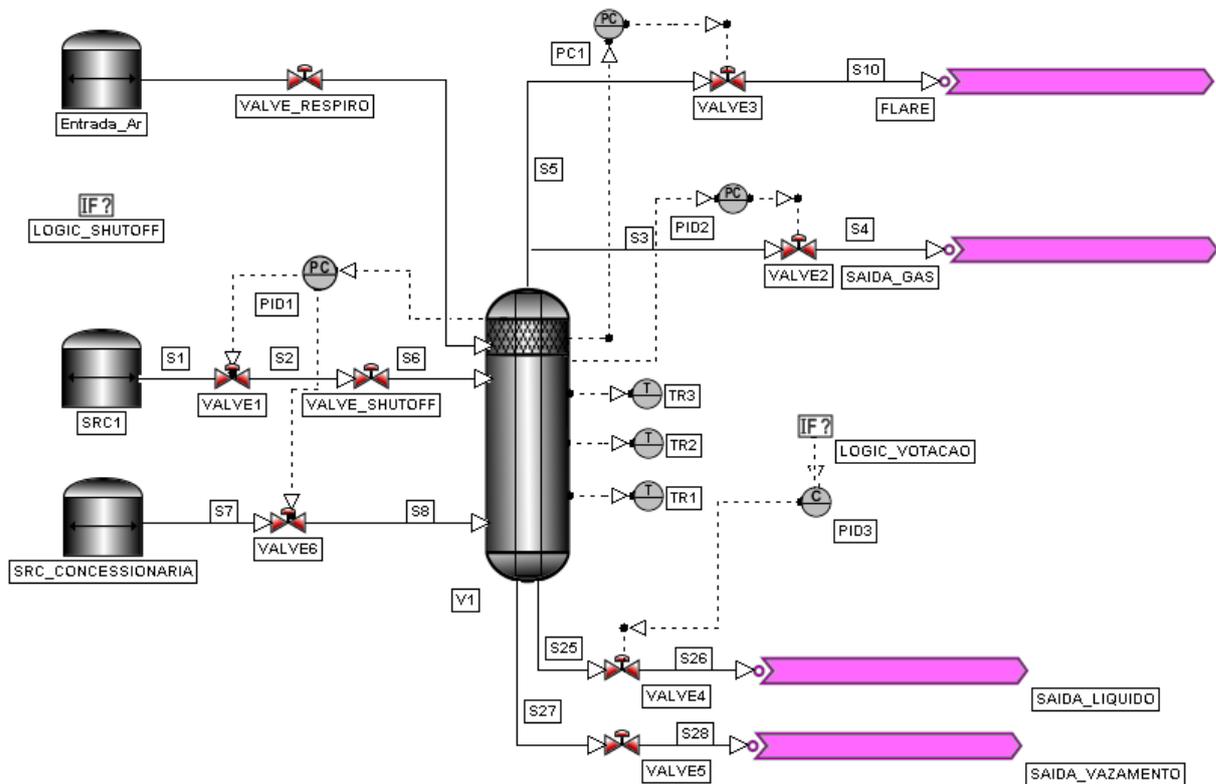
Na indústria de petróleo e gás, a utilização de simuladores dinâmicos é essencial. Tais ferramentas computacionais replicam o comportamento de sistemas e processos, permitindo análises precisas e previsões confiáveis em diferentes cenários. Através destas simulações, é possível avaliar o impacto de variáveis, testar diferentes configurações e otimizar operações, resultando em redução de custos e riscos, além do aumento da eficiência e produtividade.

Utilizamos o software AVEVA Dynamic Simulation para implementar um modelo detalhado de um vaso knockout, incluindo as instrumentações necessárias para a observabilidade e controle do processo. O objetivo principal da simulação foi reproduzir com fidelidade a operação no contexto de uma refinaria de petróleo. No cenário simulado, o vaso recebe um fluxo de gás natural proveniente de outros processos da refinaria. Após a remoção das impurezas presentes no gás, o vaso alimenta as caldeiras para geração de energia termoelétrica, responsável pelo fornecimento de vapor de água e energia elétrica para toda a refinaria. A Figura 20 apresenta o modelo do vaso desenvolvido no simulador. O modelo foi baseado no trabalho de ALAUDDIN et al. (2020) e adaptado para atender aos cenários de risco identificados em nossa análise realizada na seção 4.2.2.

A assertividade da simulação está intrinsecamente ligada à precisão na definição dos parâmetros dos instrumentos e do processo em estudo. Para que o simulador reproduza de maneira fiel o cenário real, é necessário um ajuste minucioso desses parâmetros. Isso envolve a configuração de elementos como dimensões dos equipamentos, especificidades de válvulas, entre outros aspectos.

O vaso knockout V1 possui 2,5 metros de diâmetro e 3 metros de altura. Os componentes SRC1, VALVE1, VALVE\_SHUTOFF e PID1 controlam o fluxo de entrada do gás natural no vaso. O SRC1 é a fonte do gás natural proveniente da refinaria. A Tabela 2 apresenta os compostos químicos presentes no gás, bem como os valores de sua composição. Para fins de simulação, a contaminação desse gás é realizada pela presença de água em sua composição, a qual é variável, permitindo avaliar o comportamento do sistema em cenários de alto fluxo de

Figura 20 – Modelo do vaso knockout no Aveva Dynamic Simulation



Fonte: Autor

líquido. O gás apresenta uma temperatura de  $40^{\circ}\text{C}$  e uma pressão de  $3.5\text{kg}/\text{cm}^2$ . A válvula VALVE1 tem seu fluxo de entrada ajustado de acordo com a pressão interna do vaso, por meio do controlador de pressão PID1. A válvula de segurança VALVE\_SHUTOFF interrompe o fornecimento de gás para o vaso quando o nível de líquido atinge seu valor máximo.

Tabela 2 – Composição do gás natural proveniente dos processos de refino de petróleo

Componente	kg-mol
Nitrogênio	0.0079
Gás carbônico	0.0006
Metano	0.9782
Etano	0.0095
Propano	0.0026
Butano	0.0013
Água	Valor variável

Fonte: Autor

O SRC\_CONCESSIONÁRIA e a VALVE6 controlam a entrada do gás natural fornecido pela concessionária. Esse gás possui a mesma composição do gás da refinaria, porém não

contém contaminantes, pois a concessionária realiza o tratamento prévio para eliminá-los. Em uma refinaria, para otimizar custos, utiliza-se o gás extraído durante os processos de refino de petróleo da própria instalação, aumentando o aproveitamento de recursos e evitando o descarte deste gás. A ativação do fluxo para utilizar o gás da concessionária garante a continuidade do fornecimento de gás natural ao vaso temporariamente, até que o nível do líquido seja normalizado, prevenindo o desligamento não programado do processo.

Os transmissores TR1, TR2 e TR3, operando de forma redundante, medem o nível do líquido no interior do vaso. Para garantir a confiabilidade da medição, foi implementado um sistema de votação. As leituras da altura do líquido são realizadas simultaneamente, e qualquer valor divergente é descartado. O valor final resultante serve como referência para a abertura da válvula VALVE4, responsável por permitir o escoamento do líquido interno.

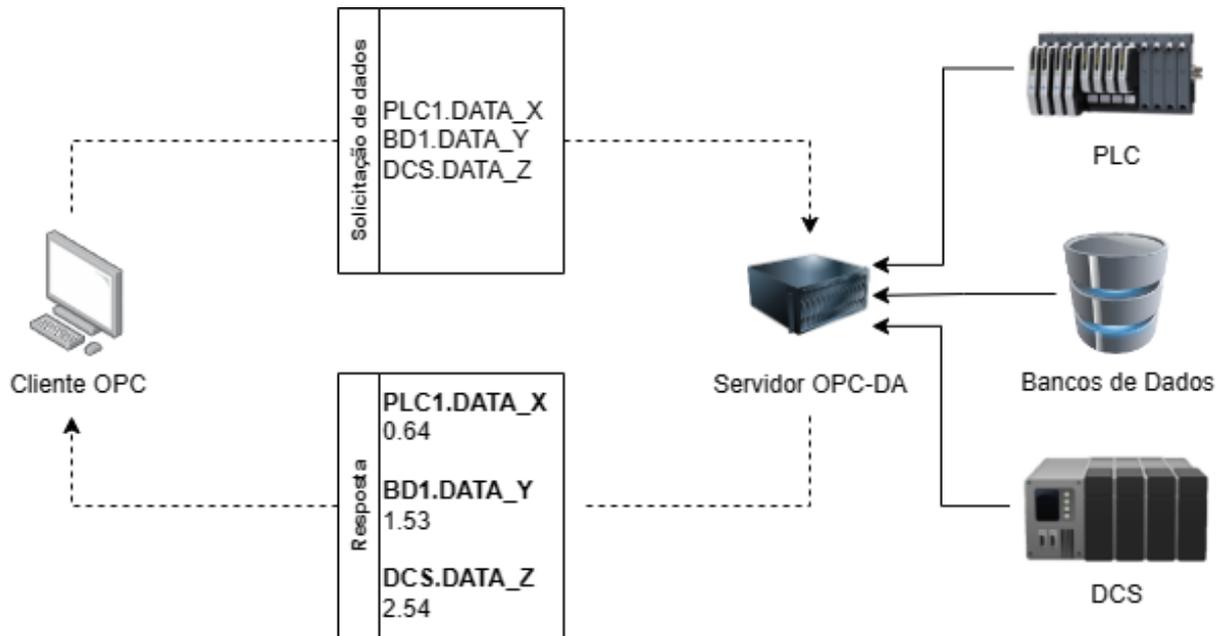
A válvula VALVE2 regula a saída do gás, ajustando sua abertura de acordo com a pressão interna do vaso, através do controlador de pressão PID2. Este ajuste visa manter a pressão interna estável e garantir uma pressão de saída constante. A válvula VALVE3, em conjunto com o controlador de pressão PC1, direciona o gás para a tocha. A válvula VALVE\_RESPIRO permite a entrada de nitrogênio, um gás inerte, no vaso para equilibrar a pressão interna e a válvula VALVE5 é utilizada para simular um cenário de vazamento de líquidos do vaso knockout.

### 4.3 COMUNICAÇÃO ENTRE O GÊMEO DIGITAL E OS MÓDULOS

O OLE for Process Control - Data Access (OPC-DA) é uma especificação da Fundação OPC que define a forma de comunicação e transferência de dados entre uma fonte de dados e uma aplicação cliente (ABBAS; MOHAMED, 2015). Esta especificação foi desenhada para mitigar a necessidade de familiaridade com os protocolos nativos entre dispositivos através da criação de grupos cliente-servidor. Como demonstrado na Figura 21, o cliente OPC seleciona os itens a serem monitorados e estabelece comunicação com o servidor OPC, responsável por converter o protocolo de comunicação do hardware. Sob esta estrutura, os dados podem ser lidos, escritos e monitorados em tempo real durante a execução dos processos.

Dentre as vantagens associadas ao OPC-DA, destaca-se a padronização da interface de comunicação entre dispositivos e aplicações distintas, resultando em uma redução da complexidade e dos custos associados à integração. O OPC-DA assegura segurança e confiabilidade na troca de dados por meio da implementação de mecanismos de autenticação, criptografia e

Figura 21 – Diagrama de comunicação cliente-servidor do padrão OPC-DA



Fonte: O autor

verificação de qualidade.

Na indústria, a especificação OPC-DA é usada para diversas finalidades, como aquisição e análise de dados de produção, qualidade, eficiência e desempenho de equipamentos e processos industriais. Além disso, o OPC-DA é empregado no controle e supervisão de dispositivos de campo, como sensores e atuadores, e na integração entre diferentes sistemas de automação industrial, como Sistemas de Supervisão e Aquisição de Dados (SCADA), Sistemas de Execução de Manufatura (MES) e Sistemas Integrados de Gestão Empresarial (ERP).

Em nosso estudo, utilizamos um servidor OPC para estabelecer a comunicação entre a simulação do vaso knockout e os módulos desenvolvidos, destinados à escrita e leitura de dados durante a execução da simulação. Na indústria, é prática recorrente utilizar soluções como o AVEVA Pi System para aquisição de dados em tempo real da planta. No entanto, dada a natureza simulada do ambiente em que atuamos, simplificamos o processo, abstraindo a utilização do Pi System e estabelecendo a conexão direta dos módulos desenvolvidos com o simulador por meio do protocolo OPC-DA.

Para estabelecer a conexão, utilizamos o MatrikonOPC Server for Simulation<sup>2</sup>, um software que permite criar uma instância de um servidor OPC. A configuração desse servidor envolve a criação de apelidos para cada variável de processo monitorada na simulação. Essas variáveis representam informações como a leitura do sensor de pressão do vaso ou a porcentagem de

<sup>2</sup> <<https://www.matrikonopc.com/products/opc-drivers/opc-simulation-server.aspx>>

abertura de uma válvula. Além disso, essas variáveis devem ser vinculadas ao simulador para garantir o envio e recebimento correto de dados, permitindo a interação entre o servidor OPC e o ambiente virtual. O Apêndice A lista todas as variáveis do processo e seus respectivos apelidos. Essas variáveis são utilizadas para coletar o conjunto de dados de treinamento e controle do gêmeo digital.

Nossos módulos utilizam a biblioteca OpenOPC-Python3X para se comunicar com o servidor OPC, permitindo a leitura e escrita de valores. Devido às limitações do padrão OPC-DA, o módulo de pré-processamento de dados é executado em uma instância de Python de 32 bits. No entanto, as bibliotecas usadas pelo nosso modelo de previsão requerem um ambiente de 64 bits. Para resolver isso, implementamos um sistema de mensagens usando a biblioteca ZeroMQ. Assim, o módulo de pré-processamento lê os valores e os envia por meio de mensagens para o modelo de previsão.

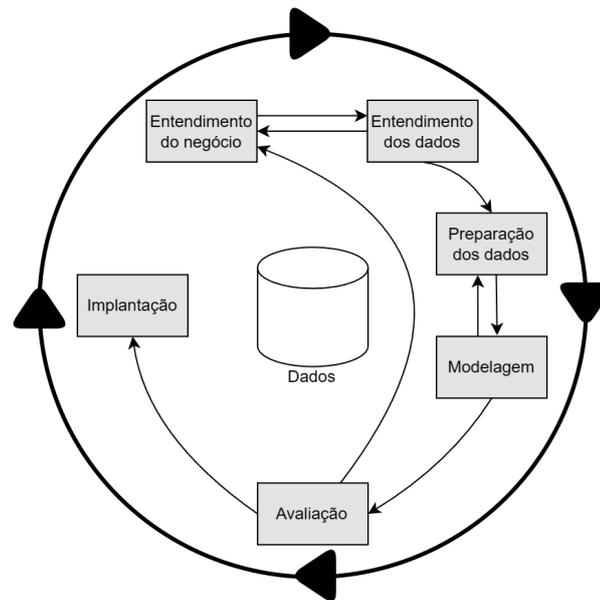
#### 4.4 MODELO PARA PREDIÇÃO DE COMPORTAMENTO FUTURO

Em atividades relacionadas à mineração de dados, a aplicação de metodologias auxilia na compreensão do problema e no desenvolvimento de soluções. O Cross Industry Standard Process for Data Mining (CRISP-DM) é um conjunto de boas práticas recomendadas para serem executadas em projetos de ciência de dados (CHAPMAN, 2000). Essa metodologia, ilustrada na Figura 22, fornece um conjunto de estágios definidos de forma flexível, onde o processo não ocorre de maneira sequencial, mas sim de forma cíclica, onde um mesmo estágio pode ser executado várias vezes até que se atinja o completo entendimento do negócio.

De acordo com SCHRÖER; KRUSE; GÓMEZ (2021), os estágios da metodologia CRISP-DM são:

- **Entendimento do negócio:** Nesta etapa, a situação do negócio deve ser avaliada para se obter uma visão geral dos recursos disponíveis e necessários, além de determinar o objetivo da mineração de dados.
- **Entendimento dos dados:** A exploração e a análise da qualidade dos dados ocorre nesta etapa. Nesta fase são extraídas as primeiras percepções e hipóteses para a solução final.
- **Preparação dos dados:** Uma vez coletados, os dados precisam ser organizados e pre-

Figura 22 – Ciclo de vida dos estágios da metodologia CRISP-DM.



Fonte: Autor

parados para a análise. Nesta etapa ocorre a limpeza, conversão e criação de novos atributos para gerar o conjunto de dados final.

- **Modelagem:** Consiste em aplicar diferentes modelos de aprendizagem no conjunto de dados. A escolha do modelo adequado depende dos requisitos específicos do projeto.
- **Avaliação:** O modelo é avaliado para verificar seu desempenho e garantir que os objetivos definidos na fase de entendimento do negócio foram atendidos.
- **Implantação:** O modelo final é disponibilizado para uso.

Ao utilizar a metodologia CRISP-DM no desenvolvimento de nossa técnica, asseguramos que o processo seja sistemático, eficiente e que esteja alinhado com os objetivos estabelecidos.

#### 4.4.1 Extração dos dados de treinamento e validação

A fim de gerar o conjunto de dados de treinamento, simulamos diversas situações com o objetivo de observar o comportamento do DTE e coletar os dados dos sensores. Os cenários envolveram a simulação de um vazamento no vaso, ruídos nos transmissores de nível e grande fluxo de líquido na entrada do vaso, assim como descritos na Seção 4.2.2. Para isso, desenvolvemos um módulo que se comunica com o modelo virtual, atribuindo valores às variáveis

de controle de acordo com os cenários de falhas a serem simulados. As variáveis controladas nesta etapa foram: taxa de abertura da válvula de vazamento, inserção de ruídos nas leituras dos transmissores de nível TR1, TR2 e TR3 e controle da quantidade de líquido no fluxo de gás natural. O Algoritmo 1 apresenta a lógica empregada na geração das entradas enviadas ao modelo virtual.

---

**Algoritmo 1:** Geração de entradas para o modelo virtual

---

```

início
  Inicialize: R = [ ], W = [ ];
  inicialize_valores_simulacao();
  enquanto Verdade faça
    R = leia_valores_simulacao();
    //Controle da quantidade de líquidos
    se R[Valve_Shutoff] == 1 então
      | W[H2O_QTD] = gera_valor_aleatorio(0.0, 10.0);
    fim
    //Controle dos ruídos dos transmissores
    W[TR1_RUIDO] = aleatorio_boolean(0.05);
    W[TR2_RUIDO] = aleatorio_boolean(0.05);
    W[TR3_RUIDO] = aleatorio_boolean(0.05);
    //Controle do vazamento
    W[VALVE5_OP] = aleatorio_boolean(0.05);
    //Envia novos valores para o modelo virtual
    escreva_opc(W);
  fim
fim

```

---

Para reproduzir com maior fidelidade o comportamento real de um sistema de gás natural, desenvolvemos uma metodologia de simulação que incorpora aleatoriedade na entrada de líquido. Nessa abordagem, geramos números aleatórios entre 0.0 e 10.0 a cada leitura de dados, simulando a variação dinâmica do volume de líquido presente no gás. A definição desses valores visa simular um fluxo intenso de líquido no vaso. Essa escolha justifica-se pelo fato de que, após a normalização da composição do gás pelo simulador, o líquido representará cerca de 91% do produto final. Também consideramos o estado da válvula de *shutoff*. Caso a válvula esteja fechada, a geração de números aleatórios não é executada, pois não há entrada de líquido no sistema. Além disso, aplicamos aleatoriedade à simulação de ruídos nos transmissores de nível e à abertura da válvula de vazamento, com probabilidade de 5% para cada evento.

Os valores de probabilidade foram definidos por meio de testes, executando o algoritmo com diferentes configurações de probabilidade e analisando os resultados obtidos. Esses valores

desempenham um papel fundamental, pois têm o objetivo de garantir a representatividade dos dados de cada cenário de risco no conjunto final de treinamento e avaliação. A Tabela 3 apresenta os valores de probabilidade testados e os resultados alcançados. Esses valores foram aplicados em uma rotina até que um conjunto de aproximadamente 135 mil registros fosse formado.

Tabela 3 – Análise dos valores de probabilidades para a geração das entradas do modelo virtual

Prob.	Ruídos nos transmissores		Vazamento	
	Quantidade	Porcentagem	Quantidade	Porcentagem
0.01	3036	2,23%	985	0,72%
0.02	6023	4,43%	2037	1,50%
<b>0.05</b>	<b>13984</b>	<b>10,30%</b>	<b>4955</b>	<b>3,65%</b>
0.1	26984	19,88%	10034	7,39%
0.4	78343	57,72%	39840	29,35%
0.5	87511	64,48%	49941	36,80%

Fonte: Autor

Após analisarmos os resultados obtidos com diferentes configurações de probabilidade, escolhemos o valor de 0.05 por apresentar um equilíbrio entre a quantidade de ocorrências e a fidelidade ao comportamento real do sistema. Os valores 0.01 e 0.02 resultaram em um número insuficiente de ocorrências para uma análise robusta, o que poderia comprometer a validação dos cenários simulados por falta de exemplos suficientes para embasar as conclusões. Por outro lado, valores de probabilidade superiores a 0.05 geraram um número excessivo de ocorrências, distorcendo a dinâmica real do sistema. Essa distorção poderia levar à criação de um modelo artificial, comprometendo a confiabilidade dos resultados. Portanto, a escolha de 0.05 como valor da probabilidade baseia-se em sua capacidade de gerar um número suficiente de ocorrências para uma análise confiável, sem comprometer a fidelidade do modelo.

Para registrar os comportamentos do modelo virtual durante a execução do algoritmo, desenvolvemos um módulo que lê os estados das variáveis do servidor OPC em tempo real e os armazena em um formato estruturado. Essa estrutura facilita os processos de tratamento, treinamento e avaliação do modelo, permitindo uma análise mais profunda e eficiente dos resultados da simulação. A simulação foi executada durante 65 horas, gerando um conjunto de dados com 12 eventos de *trip* distribuídos entre 135 mil registros. Cada registro é composto por 56 atributos. Essas informações permitem um melhor entendimento do comportamento do vaso em diferentes cenários e condições de operação, fornecendo subsídios para a validação,

otimização e aprimoramento do modelo.

#### 4.4.2 Estrutura do modelo

O processo de definição da estrutura do modelo é uma etapa fundamental no desenvolvimento de um modelo baseado em inteligência artificial. Portanto, é necessário compreender as características do problema e as respostas desejadas. O problema apresentado neste trabalho consiste na análise do comportamento do nível do líquido no vaso knockout ao longo do tempo, considerando situações adversas como falhas nos sensores, alto fluxo de líquido e vazamento. Essa informação subsidiará a tomada de decisões estratégicas pelo operador, como desligar a entrada de gás natural da refinaria e substituí-la por outra fonte de gás para evitar a interrupção das operações.

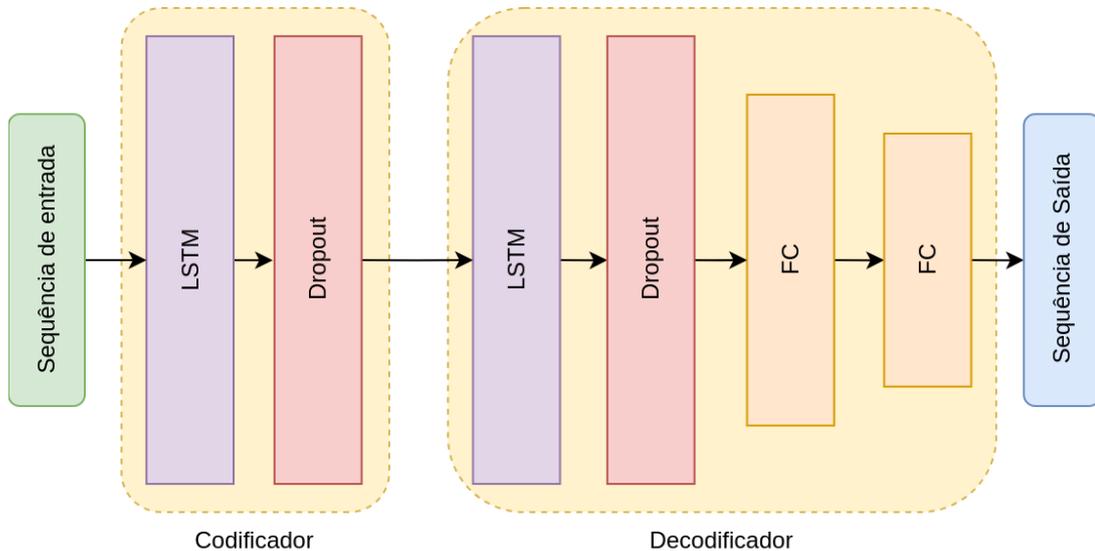
A fim de detectar situações que elevam os riscos, torna-se fundamental a análise de séries temporais. Através da observação do sistema ao longo de um determinado período de tempo, é possível identificar padrões e tendências que servem como base para a previsão de comportamentos futuros.

A análise de séries temporais é um problema bastante explorado pela comunidade científica. Diversos estudos foram realizados com o objetivo de desenvolver modelos capazes de capturar os padrões presente na variação temporal dos dados. Essas séries podem ser uni-variadas, com apenas uma variável sendo observada, ou multivariadas, envolvendo diversas variáveis inter-relacionadas. Entre as diversas arquiteturas utilizadas para a construção desses modelos, a LSTM se destaca por sua capacidade de lidar com dependências de longo prazo, característica fundamental para lidar com séries temporais.

No trabalho de ZHANG et al. (2018b), os autores sugerem que o uso de camadas LSTM é uma abordagem eficiente para prever dados futuros de equipamentos. HOWIND; SAUTER (2023) apresentam um estudo que introduz o uso da técnica Sequence-to-Sequence (Seq-2-Seq) no contexto industrial para modelagem de consumo energético. Essa técnica segue um modelo *encoder-decoder*, utilizando camadas LSTM para mapear a sequência de entrada em um vetor de dimensão fixa. Em seguida, outra camada LSTM é empregada para decodificar a sequência de destino a partir desse vetor (SUTSKEVER; VINYALS; LE, 2014). Os resultados obtidos demonstraram a eficácia dessa abordagem na análise de sequências, permitindo a detecção de padrões e a inferência precisa de informações. Deste modo, o modelo de rede neural proposto em nossa pesquisa implementa a técnica Seq-2-Seq, utilizando camadas LSTM

como codificador e decodificador. A Figura 23 ilustra a arquitetura do modelo.

Figura 23 – Arquitetura do modelo proposto.



Fonte: Autor

Inicialmente, a sequência de entrada tem seus valores normalizados pela técnica MinMax. Logo após, na etapa de codificação, as camadas LSTM processam a sequência, capturando as características e dependências temporais dos dados. O resultado dessa codificação é um vetor que representa o estado interno do modelo. Na etapa de decodificação, o vetor é usado como entrada para outra camada LSTM, que gera uma sequência de saída. A técnica de *dropout* é aplicada após cada camada LSTM para evitar o sobreajuste do modelo. Por fim, essa sequência é processada por duas camadas totalmente conectadas, responsáveis por gerar o vetor de saída final com a dimensão do horizonte de previsão. Na primeira camada totalmente conectada, aplicamos a regularização L2 para penalizar grandes pesos de maneira proporcional ao próprio peso, controlando a complexidade do modelo e prevenindo o overfitting.

O desempenho do modelo será avaliado na subseção a seguir, utilizando diferentes métricas para quantificar a precisão das previsões. A análise dos resultados permitirá verificar a efetividade da arquitetura proposta para a tarefa de previsão do nível do líquido.

#### 4.4.3 Treinamento e avaliação

Para avaliar a capacidade de generalização do modelo proposto e estimar os valores ideais de seus hiperparâmetros, realizamos uma série de treinamentos com o objetivo de verificar o comportamento do modelo em diferentes cenários e identificar a configuração que proporcio-

---

nasse o melhor desempenho. Utilizamos o otimizador ADAM com uma taxa de aprendizagem 0.001 para treinar nosso modelo. Valores maiores, como 0.01, resultaram em valores instáveis da função de perda, enquanto valores menores, como 0.0001, tornaram o processo de treinamento muito lento. A taxa de aprendizagem 0.001 proporcionou um bom equilíbrio entre convergência e estabilidade. Cada experimento foi executado por 100 épocas e o algoritmo foi implementado utilizando a biblioteca Tensorflow<sup>3</sup>. Para manter a consistência dos testes, definimos 0 como o valor para a *seed*, permitindo que os testes possam ser comparados ao remover a aleatoriedade dos dados. Utilizamos uma GPU Nvidia Tesla T4 e 13 GB de memória RAM para realizar o treinamento do modelo.

A validação cruzada é uma técnica utilizada para avaliar a precisão de modelos de aprendizado de máquina. Seu objetivo principal é fornecer uma estimativa precisa da capacidade do modelo de generalizar para novos dados. No entanto, aplicar a validação cruzada em modelos que lidam com séries temporais requer abordagens específicas, uma vez que o embaralhamento dos dados não é possível devido à natureza sequencial dessas séries.

A técnica de validação cruzada chamada `TimeSeriesSplit` é especialmente útil para avaliar modelos em séries temporais. Semelhante aos métodos tradicionais, ela divide o conjunto de dados em subconjuntos. No entanto, em cada iteração, um subconjunto é usado como conjunto de teste, enquanto os subconjuntos anteriores formam o conjunto de treinamento. Isso simula um cenário real em que o modelo é treinado com dados históricos e avaliado com dados futuros. O processo é repetido para cada subconjunto, garantindo que todos os dados sejam usados tanto para treinamento quanto para testes, preservando a ordem temporal. Devido às vantagens dessa abordagem, utilizamos o `TimeSeriesSplit` para treinar e validar nosso modelo.

Foram utilizadas como entrada para o modelo as séries temporais multivariadas, onde cada série é composta por 30 conjuntos de valores obtidos das leituras dos sensores, seguidos pelos próximos 15 valores da variável dependente. Estes valores foram normalizados utilizando a técnica `MinMax`, ajustando todos os valores dentro do intervalo  $[0, 1]$ . Neste processo, adotamos a estratégia de reduzir a quantidade de características enviadas para o modelo, selecionando apenas as variáveis que não são utilizadas para o controle da simulação e que são integrantes do fluxo de entrada e controle do gás. Tal estratégia visa a utilização exclusiva das características que exercem influência sobre o nível de líquido. Além disso, essa abordagem permite que o modelo esteja em conformidade com as restrições de um ambiente de produção real, pois nem todas as variáveis coletadas durante a simulação estão disponíveis para uso em

---

<sup>3</sup> <<https://www.tensorflow.org/>>

ambiente real. O Apêndice A identifica as variáveis que foram selecionadas para uso.

A Tabela 4 apresenta os hiperparâmetros avaliados, os valores testados e os melhores resultados obtidos. A partir dessa análise, foi possível identificar a configuração ideal dos hiperparâmetros para o modelo proposto, otimizando seu desempenho para o problema em questão.

Tabela 4 – Análise dos hiperparâmetros avaliados

Hiperparâmetro	Valor ideal	Valores testados
Unidades LSTM	64	[16, 32, 64, 128]
Taxa de dropout	0.2	[0.0, 0.2, 0.4]
Unidades FC	16	[8, 16, 32]
Tamanho do batch	128	[32, 64, 128]

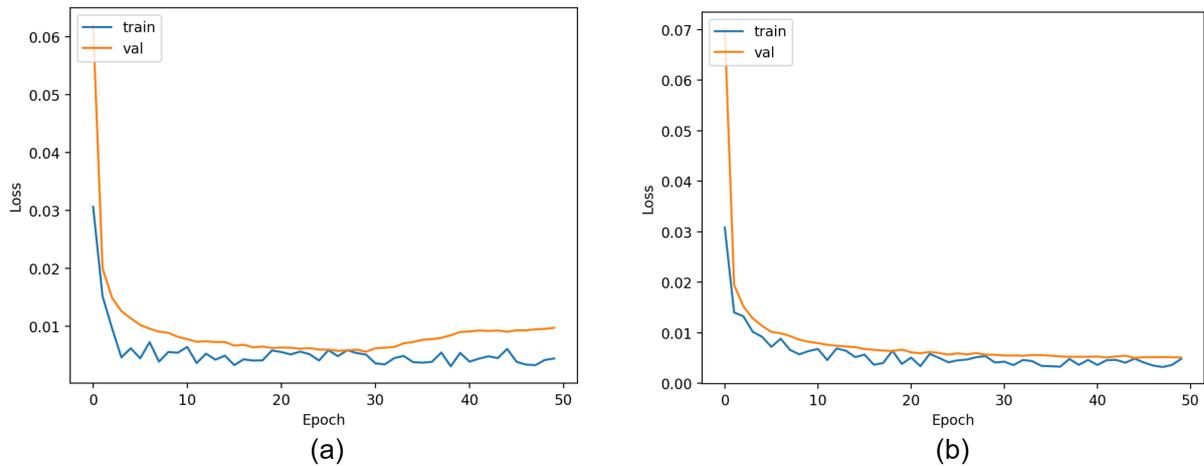
Fonte: Autor

As unidades LSTM correspondem à quantidade de células na camada oculta da rede. Cada célula LSTM desempenha a função de processar um passo na sequência de entrada e de armazenar informações relevantes para o aprendizado de longo prazo. Quanto maior o número de unidades, maior a capacidade de capturar dependências complexas nos dados. No entanto, um número excessivamente elevado pode resultar em um modelo muito complexo, potencialmente levando a problemas de *overfitting*. Por outro lado, um número muito reduzido pode resultar em uma representação limitada, causando *underfitting*. A determinação do número ideal de unidades depende da natureza dos dados e da complexidade do problema em questão. Em nossas avaliações, observamos que redes com 64 unidades LSTM proporcionaram os melhores resultados.

A utilização de técnicas de regularização pode ser fundamental para prevenir problemas de *overfitting* no modelo. Após cada camada LSTM, incorporamos o *dropout* como uma estratégia para mitigar o risco de *overfitting*. Na Figura 24, são apresentados dois gráficos representando processos de treinamento distintos: no caso (a), nenhuma técnica de regularização foi empregada, enquanto no caso (b), o *dropout* foi aplicado.

Na Figura 24 (a), observa-se que o modelo apresentou sinais de *overfitting*. A função de perda da validação atingiu um valor mínimo e, em seguida, iniciou uma leve subida, distanciando-se da função de perda de treinamento. Isso indica que o modelo estava se adaptando excessivamente aos detalhes do conjunto de treinamento, em detrimento da capacidade de generalização para dados novos. Para mitigar o *overfitting*, aplicamos a técnica de regula-

Figura 24 – Gráficos dos valores da função de perda durante o treinamento. Em (a), a taxa de dropout foi configurada como 0.0, enquanto em (b) foi ajustada para 0.2.



Fonte: Autor

rização *dropout*. Como pode ser visto na Figura 24 (b), o modelo continuou a convergir após a aplicação do *dropout*, sem apresentar sinais de *overfitting*. A função de perda da validação se manteve próxima à função de perda de treinamento, indicando um melhor desempenho em dados novos. Adicionalmente, utilizamos a estratégia de *early stopping* que implementa um mecanismo de parada antecipada do treinamento, o qual é acionado caso a função de perda da validação não demonstre melhora após um número pré-determinado de épocas. Tal medida visa prevenir o supertreinamento do modelo e, conseqüentemente, otimizar seu desempenho. Em nosso treinamento, este valor foi definido como 10, pois valores maiores prolongaram o tempo de treino sem apresentar melhorias significativas na taxa de erros.

As unidades da camada FC consistem em neurônios artificiais que processam as entradas para gerar uma saída. Em nosso modelo, a primeira camada recebe o vetor de saída da camada LSTM, reduzindo sua dimensionalidade e enviando-o para a próxima camada FC para a geração do vetor de saída final. A quantidade de neurônios nesta camada é um parâmetro essencial para garantir a qualidade das inferências. Com base nos testes realizados, o número ideal foi determinado como 16 neurônios.

O tamanho do batch é um fator que influencia a eficiência do treinamento de modelos de aprendizado de máquina e o consumo de recursos computacionais. Um valor elevado para este parâmetro pode intensificar o paralelismo e otimizar o uso da capacidade das GPUs. Por outro lado, lotes de dados menores requerem menos memória, o que é vantajoso para hardwares com capacidades computacionais limitadas. A escolha adequada do tamanho do lote pode também favorecer a generalização do modelo, pois lotes maiores tendem a aumentar a chance de

alcançar o mínimo global na função de custo, contribuindo para a criação de um modelo mais robusto e aplicável a diferentes situações. Em nossos experimentos, o valor 128 se demonstrou o valor ideal, acelerando o processo de treinamento e garantindo a generalização.

No processo de treinamento, o modelo Seq-2-Seq recebe como entrada uma série temporal composta pelas *features* de um período específico e um conjunto contendo os valores da variável dependente (*target*), dimensionado de acordo com a quantidade de unidades de tempo futuras que se deseja prever. A definição das dimensões de entrada e saída influencia diretamente na assertividade das previsões do modelo. Para determinar as melhores dimensões para os dados de treinamento, realizamos alguns experimentos, os quais são apresentados na Tabela 5.

Tabela 5 – Análise da dimensionalidade das séries temporais aplicadas no treinamento do modelo

<b>Entrada</b>	<b>Saída</b>	<b>RMSE</b>
15	15	0.0491
30	15	0.0327
30	30	0.0739

**Fonte:** Autor

Quando a entrada é muito curta, pode haver uma perda significativa de informações relevantes, comprometendo a capacidade do modelo de capturar padrões temporais complexos. Isso é especialmente problemático em séries temporais que exibem dependências de longo prazo. Da mesma forma, ao lidar com saídas muito longas, o modelo pode enfrentar dificuldades na manutenção de contextos relevantes ao longo do tempo. Além disso, saídas excessivamente curtas podem não conter detalhes suficientes, resultando em previsões simplificadas e menos precisas. Conforme indicado por nossos experimentos, o modelo que utiliza uma série temporal composta pelos dados das últimas 30 leituras e realiza previsões para as próximas 15 unidades de tempo demonstrou o melhor desempenho, evidenciando uma relação equilibrada entre as dimensões de entrada e saída.

Avaliamos o uso da tangente hiperbólica e ReLU como funções de ativação das camadas LSTM. A tangente hiperbólica é uma função que incorpora a não-linearidade, permitindo que a rede aprenda relações mais complexas entre os dados de entrada e saída. A função ReLU possui melhor eficiência computacional e evita o problema de desaparecimento do gradiente. Conduzimos dois experimentos para avaliar o desempenho das duas funções de ativação em nosso conjunto de treinamento. Os resultados são apresentados na Tabela 6.

Tabela 6 – Resultado das análises das funções de ativação nas camadas LSTM

<b>Função de ativação</b>	<b>RMSE</b>
ReLU	0.0623
Tangente hiperbólica	0.0327

**Fonte:** Autor

Com base nos resultados coletados, a tangente hiperbólica foi escolhida como função de ativação nas camadas LSTM. Essa escolha se deu em função do melhor desempenho apresentado em comparação com a ReLU, demonstrando maior flexibilidade na captura das correlações entre as variáveis. Isso, por sua vez, aumenta a capacidade da rede neural de aprender representações mais sofisticadas.

Tabela 7 – Resultados alcançados pelos modelos de RNNs após o treinamento em nosso conjunto de dados

<b>Método</b>	<b>Modelo</b>	<b>RMSE</b>	<b>MAE</b>
ZHANG et al. (2018b)	LSTM	0.0437	0.0389
LIU et al. (2023)	LSTM-GRU	0.0384	0.0298
<b>Modelo proposto</b>	<b>LSTM Seq-2-Seq</b>	<b>0.0327</b>	<b>0.0214</b>

**Fonte:** Autor

Na Tabela 7, comparamos nosso modelo proposto com os modelos de redes neurais recorrentes apresentados no Capítulo 3. Por meio das métricas Erro Quadrático Médio (RMSE) e Erro Absoluto Médio (MAE), obtidos pela média dos valores alcançados durante a validação cruzada, constatamos que nossa proposta forneceu inferências com taxas de erro menores que os demais modelos comparados.

A métrica RMSE penaliza os resultados levando em consideração a magnitude dos erros individuais, o que significa que essa métrica é sensível a *outliers*. Por outro lado, a métrica MAE representa a média da magnitude dos erros de forma absoluta, indicando que valores baixos de erro significam que o modelo está fazendo previsões com erros relativamente pequenos.

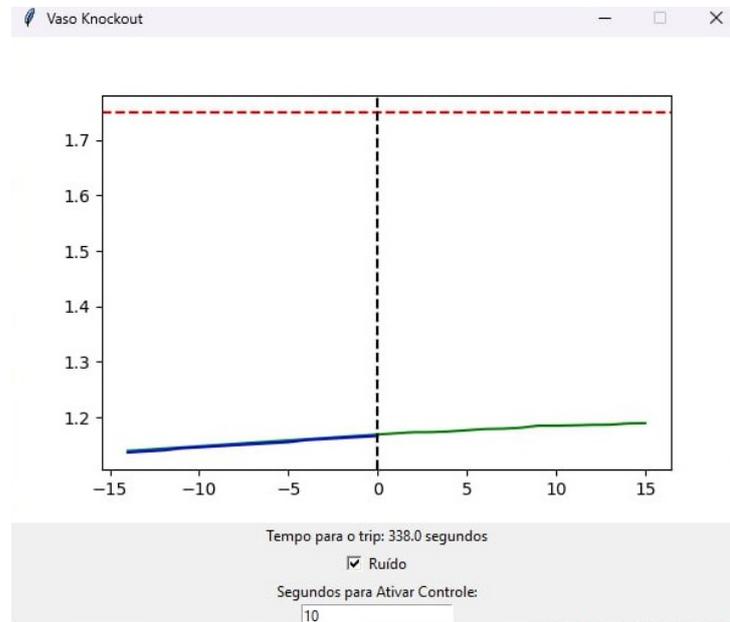
Ao analisarmos os resultados obtidos, podemos concluir que nosso modelo realizou previsões de valores mais próximos aos reais, demonstrando sua eficácia na tarefa em questão.

#### 4.5 INTERFACE DE VISUALIZAÇÃO

Uma interface visual foi implementada para apresentar de maneira simplificada tanto o estado corrente da simulação quanto as projeções produzidas pelo modelo. O propósito desta

interface é facilitar a interpretação dos dados e auxiliar os profissionais encarregados do monitoramento do vaso knockout na tomada de decisões. A interface foi construída utilizando o pacote Tkinter<sup>4</sup>, que é a ferramenta padrão do Python para a criação de interfaces de usuário.

Figura 25 – Interface de visualização do estado atual da simulação e dos valores inferidos pelo modelo



Fonte: Autor

A Figura 25 apresenta a interface em funcionamento. Esta interface contém um gráfico que é atualizado em tempo real, onde a linha azul mostra o nível atual do líquido dentro do vaso, a linha verde mostra o comportamento esperado para os próximos 15 segundos e a linha vermelha mostra o nível máximo de líquido antes que ocorra o *trip*. Utilizamos segundos como unidade de tempo, pois é a mesma unidade utilizada na criação do conjunto de dados e nas séries temporais enviadas para treinamento. Essa decisão se justifica porque utilizamos um conjunto restrito de dados, então optar pelo uso de uma unidade de tempo menor permitiu obter mais dados para treinamento e validação.

A interface, com o objetivo de fornecer melhores subsídios para a tomada de decisão estratégica, realiza um cálculo para prever o tempo, em segundos, necessário para que o nível máximo de líquido seja alcançado. Este cálculo é realizado com base nos valores inferidos pelo modelo, levando em consideração a taxa de variação atual do nível a cada segundo, conforme estabelecido pela Equação 4.1.

<sup>4</sup> <<https://docs.python.org/pt-br/3/library/tkinter.html>>

$$y = \left\lceil \frac{MAX - REAL}{\left| \frac{1}{N-1} \sum_{i=1}^{N-1} (X_i - X_{i-1}) \right|} \right\rceil \quad (4.1)$$

Onde  $y$  é a previsão do valor em segundos para o *trip* ocorrer,  $MAX$  é o nível máximo que o vaso pode atingir antes do *trip*,  $REAL$  é o valor atual do nível do líquido do vaso,  $N$  é a quantidade de valores inferidos pela rede e  $X$  é o valor da previsão do nível do líquido.

Para reproduzir cenários com ruídos nas leituras dos sensores, implementamos uma caixa de seleção que adiciona perturbações na leitura do fluxo do tubo de entrada de gás. Essa funcionalidade visa simular condições de risco, onde o sensor fornece dados inconsistentes, permitindo a avaliação da precisão da rede diante de tais situações.

A prevenção do acúmulo de líquido até o limite máximo do vaso pode ser realizada por meio do chaveamento da entrada de gás da refinaria para o gás da concessionária. Essa troca é realizada quando o resultado da Equação 4.1 é igual ao valor limite inserido pelo usuário na caixa de entrada da interface. Esse chaveamento representa uma tomada de decisão hipotética da central de controle da refinaria. Em um ambiente de produção real, outras decisões podem ser tomadas com base nos resultados fornecidos pela rede.

## 5 EXPERIMENTOS E RESULTADOS

Este capítulo tem como objetivo validar a técnica proposta para avaliação de riscos em tempo real. Primeiramente, descrevemos a estratégia de validação utilizada, apresentando as etapas e como a avaliação foi conduzida. Em seguida, apresentamos um resumo dos cenários de risco avaliados e suas principais características. Por último, analisamos os resultados coletados durante os experimentos para avaliar o desempenho da técnica proposta como uma barreira de segurança para prevenção do acúmulo de líquido em um vaso knockout.

### 5.1 ESTRATÉGIA DE VALIDAÇÃO

Para analisar o funcionamento da técnica proposta neste trabalho, realizamos duas avaliações com o objetivo de entender a eficácia do nosso modelo e identificar potenciais oportunidades para aprimoramento. Visamos garantir que a solução proposta seja aplicável em várias situações para evitar o acúmulo de líquido internamente no vaso.

A primeira avaliação concentrou-se em coletar informações sobre o desempenho do modelo na prevenção do acúmulo de líquido. Para isso, comparamos o funcionamento do vaso knockout em dois cenários distintos: com e sem o uso da técnica apresentada neste trabalho. Realizamos a avaliação utilizando o Algoritmo 1 para criar novas entradas aleatórias para o nosso modelo virtual. Para garantir que os comportamentos gerados sejam determinísticos, definimos o valor 0 como semente na geração dos valores aleatórios. Deste modo, conseguimos comparar os diferentes cenários de avaliação sob as mesmas condições de funcionamento.

Em nossa segunda avaliação, exploramos o desempenho das previsões do modelo diante de ruídos na leitura do fluxo do tubo de entrada de gás, falha nos transmissores e vazamentos. O principal objetivo desta análise foi compreender como o modelo proposto reage a situações adversas e como as suas estimativas são influenciadas por diferentes tipos de falhas. Para avaliar a precisão das inferências, executamos cada simulação durante 5 minutos e armazenamos a diferença entre o valor real do nível do líquido e o valor estimado pelo modelo proposto. Posteriormente, calculamos a média desses valores para efeitos de avaliação.

## 5.2 CENÁRIOS DE RISCO

Durante a construção do modelo virtual do vaso knockout, implementamos mecanismos que permitem simular alguns cenários de risco que podem ocorrer durante o funcionamento do vaso. Esses cenários foram identificados e detalhados na Seção 4.2.2.

Em nossa avaliação, identificamos quatro potenciais ameaças que podem causar o excesso de líquido no vaso knockout e, por consequência, ativar o *trip* como uma barreira de mitigação: a presença de vazamentos, grande volume de líquido entrando no vaso, falhas nos transmissores de nível e ruídos na leitura de sensores. Durante o processo de validação, abrangemos todos estes cenários para avaliar a taxa de erro do modelo proposto em diferentes situações.

Como descrito na Seção 5.1, a primeira avaliação teve como objetivo medir o desempenho na prevenção do acúmulo de líquido. Esse cenário pôde ser avaliado ajustando a composição do gás para incluir quantidades significativas de líquido. A segunda avaliação, que visou entender o desempenho da previsão do modelo, foi realizada através da abertura aleatória da válvula que simula um vazamento e da injeção de valores aleatórios na leitura da taxa de fluxo do tubo S6 para simular a presença de ruídos nas leituras. No cenário em que ocorrem falhas nos transmissores de nível, aplicamos valores de ruído distintos para cada transmissor. Dessa forma, o sistema de votação não seria capaz de indicar qual é o valor correto da leitura do nível do líquido.

## 5.3 AVALIAÇÃO

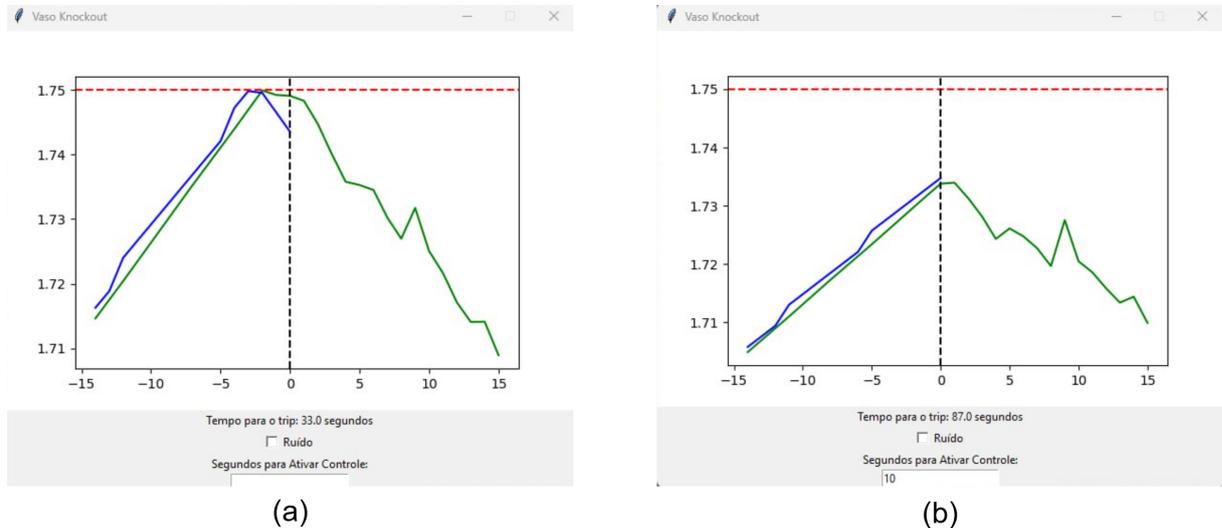
Esta seção apresenta uma análise detalhada dos resultados obtidos após a execução dos testes. Os testes foram conduzidos com o objetivo de avaliar o desempenho do sistema nos cenários de risco mencionados anteriormente.

Para avaliar a eficácia na prevenção de *trips*, realizamos duas simulações. Na primeira simulação, executamos apenas o modelo virtual; na segunda simulação, o mesmo modelo virtual foi executado, porém com a técnica proposta integrada. Ambas as simulações foram executadas por um período de 24 horas, mantendo as mesmas condições operacionais.

Durante a execução do experimento que não incorporou nossa técnica, foram registradas quatro ocorrências de *trip*, resultando na interrupção das operações das caldeiras devido à suspensão temporária do fornecimento de gás. No experimento em que nossa técnica foi utilizada, não foram observadas ocorrências de *trip*, assegurando, assim, a estabilidade no

fornecimento de gás para as caldeiras.

Figura 26 – Captura de tela do gráfico de comportamento do nível do líquido durante os testes de prevenção do trip



Fonte: Autor

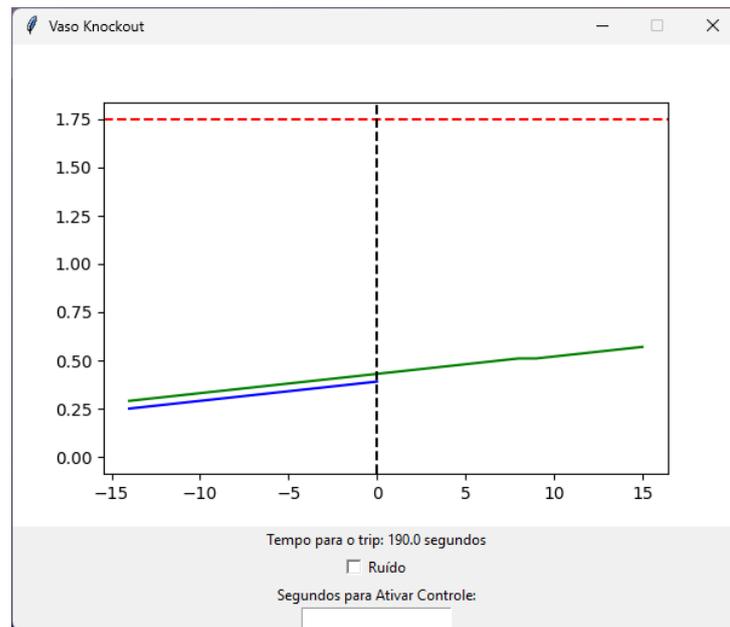
Nos gráficos apresentados na Figura 26, a linha azul indica a leitura do nível de líquido em tempo real, e a linha verde indica a previsão gerada pelo nosso modelo. A Figura 26 (a) ilustra o comportamento da simulação sem a aplicação da técnica proposta. Observa-se que o nível do líquido atinge o limite máximo, e o *trip* foi acionado para interromper o fornecimento de gás para as caldeiras e prevenir o risco de explosão. Na Figura 26 (b), com a técnica em ação, verifica-se que, ao se aproximar do nível máximo, a fonte de gás da refinaria é automaticamente trocada para o gás tratado da concessionária. Isso garante o fornecimento contínuo de gás às caldeiras, além de proporcionar mais tempo para a drenagem do líquido.

Seguindo nossa estratégia de validação, também realizamos testes para verificar a precisão das previsões do modelo em situações de vazamentos, ruídos na leitura da taxa de fluxo da tubulação de entrada (S6) e nos transmissores de nível. O propósito desses testes é assegurar a acurácia das previsões mesmo quando os dados fornecidos ao modelo possam estar incorretos.

A Figura 27 demonstra a boa taxa de assertividade do modelo proposto nas previsões, mesmo com a presença de vazamento. As linhas no gráfico se mantêm próximas, indicando uma discrepância mínima entre os valores reais e os valores inferidos. O erro médio neste cenário foi de aproximadamente 0.04.

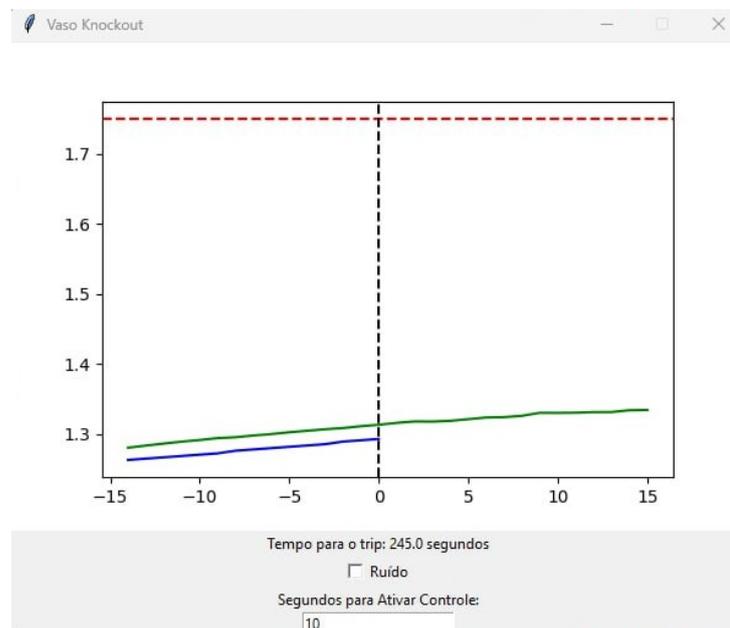
O impacto das falhas nos transmissores sobre a assertividade da inferência do modelo pode ser observado na Figura 28. Nota-se uma pequena diferença entre os valores reais e os inferidos, uma vez que todos os transmissores fornecem informações incorretas. Essa falha

Figura 27 – Gráfico com o comportamento real e o inferido pelo modelo durante a simulação de vazamento



Fonte: Autor

Figura 28 – Comportamento do nível do líquido durante os testes de falha nos transmissores de nível

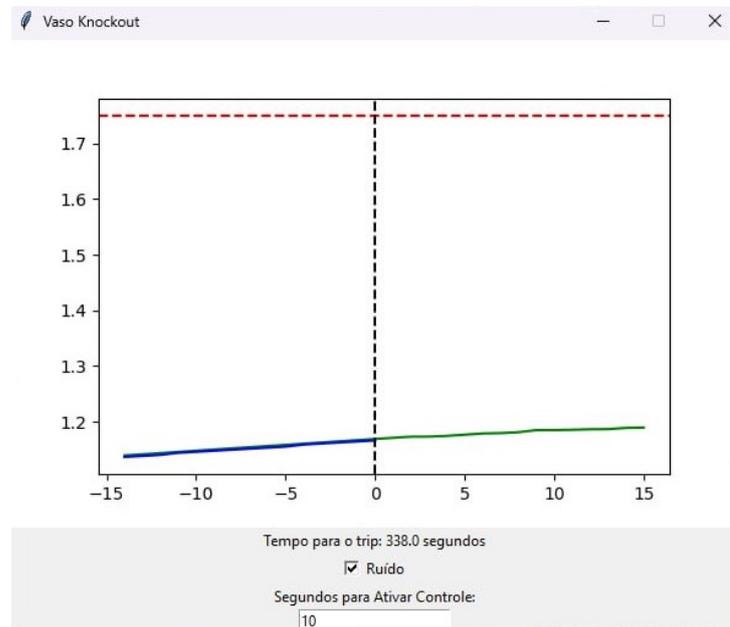


Fonte: Autor

interfere no sistema de votação, levando o modelo a inferir valores com menor precisão. Os testes realizados revelaram que os valores preditos sempre se mostraram um pouco maiores que os valores reais, com um erro médio de aproximadamente 0.09. Isso indica que a técnica proposta ainda conseguiu apresentar bons resultados na prevenção do *trip*, pois, mesmo com a falha nos transmissores, a troca da fonte de gás ocorreu antes do líquido atingir seu nível

máximo.

Figura 29 – Comportamento do nível do líquido durante a inserção de ruídos na taxa de fluxo do tubo S6



Fonte: Autor

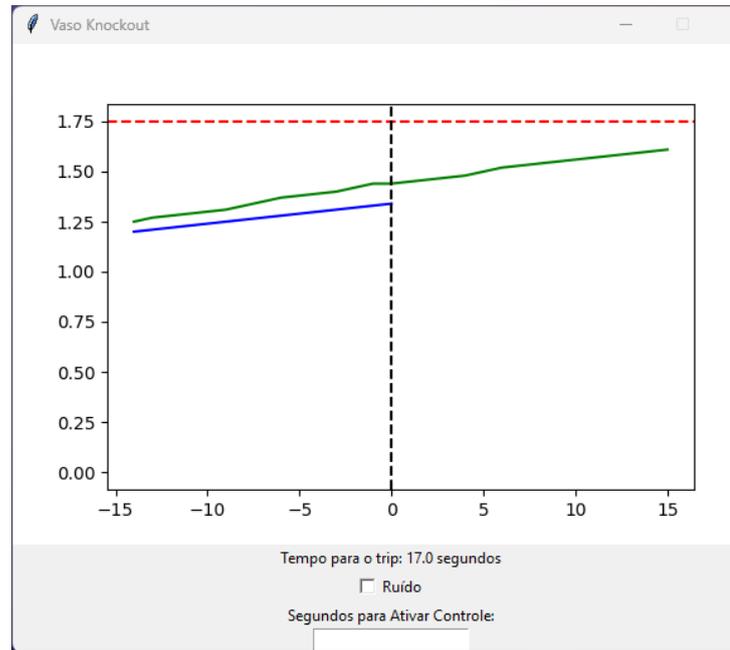
A inserção de ruídos na taxa de fluxo do tubo S6 não causou grande impacto na precisão dos valores inferidos, como demonstrado na Figura 29. O valor do erro médio neste cenário foi de 0.008. Isso é possível porque o modelo recebe como entrada informações de diferentes componentes da simulação, como a pressão interna do vaso, os dados de saída dos controladores, entre outros. Desta forma, a importância dos atributos de entrada é distribuída, e caso algum valor esteja incorreto, o impacto na inferência é menor. No entanto, se muitas informações estiverem incorretas, a taxa de erro pode aumentar, como mostrado na Figura 30.

Neste cenário, foram simuladas falhas nos transmissores de nível e na leitura da taxa de fluxo do tubo S6 simultaneamente. Durante a execução da simulação, observou-se um aumento gradual na disparidade entre os valores reais e os valores preditos, indicando que nossa técnica não obteve resultados satisfatórios para esta situação.

A avaliação do desempenho do sistema revelou que cada processo de inferência, desde a coleta de dados no servidor OPC até a exibição do gráfico no software de visualização, teve uma duração média de 0.23 segundos. Isso demonstra que as inferências são realizadas em tempo adequado para permitir a tomada de decisões. O tempo de execução mencionado foi alcançado utilizando uma GPU Nvidia GeForce 1650 e 32GB de memória RAM.

A capacidade do modelo de manter sua precisão em grande parte dos cenários de risco apresentados assegura a estabilidade da técnica proposta no processo produtivo. Isso indica

Figura 30 – Comportamento do gráfico quando simuladas falhas nos transmissores e ruídos na taxa de fluxo do tubo S6



Fonte: Autor

que, mesmo em situações anormais, o modelo ainda é capaz de fornecer boas estimativas, permitindo que medidas corretivas sejam tomadas para evitar a necessidade de acionamento do *trip*.

## 6 CONCLUSÃO

Esta dissertação apresentou uma técnica de avaliação de risco em tempo real para prevenção do acúmulo de líquidos em um vaso knockout. Um DTE foi construído para coletar os dados de treinamento e para a realização das avaliações dos cenários de risco. Propomos uma arquitetura de rede neural utilizando camadas LSTM para extrair padrões de séries temporais e realizar inferências do comportamento do nível de líquido.

Para garantir a eficácia e a confiabilidade de nossa técnica, utilizamos metodologias de desenvolvimento, modelos e técnicas de análise de risco presentes na literatura, buscando reaproveitar suas principais características e adaptá-las às necessidades específicas de nossos objetivos. Além disso, propomos um método para a extração de dados de treinamento por meio de simulações, o que permite a coleta de informações sobre eventos raros. Também utilizamos a abordagem Seq-2-Seq (SUTSKEVER; VINYALS; LE, 2014) para analisar os dados históricos do processo e inferir informações futuras sobre o comportamento do nível do líquido.

Para avaliar a efetividade da técnica proposta, simulamos os cenários de risco identificados durante a etapa de análise de risco em nosso gêmeo digital. A arquitetura final foi capaz de realizar previsões em tempo real, fornecendo aos operadores informações valiosas que auxiliam durante o processo de tomada de decisões e previnem a ocorrência de paradas não programadas.

Neste capítulo, discutimos as conclusões do nosso estudo, bem como os prós e contras da técnica proposta. Na Seção 6.1, abordamos os objetivos alcançados e suas relações com os objetivos estabelecidos para esta pesquisa. A Seção 6.2 destaca as principais vantagens e as contribuições científicas deste estudo. Na Seção 6.3, falamos sobre as restrições associadas ao uso da técnica desenvolvida. Por fim, a Seção 6.4 propõe possíveis pesquisas futuras que podem melhorar os resultados deste estudo.

### 6.1 OBJETIVOS

Este trabalho teve como principal finalidade atender aos objetivos apresentados na Seção 1.3. Estes objetivos incluem: apresentar uma solução para inferir comportamentos do nível de líquido de um vaso knockout para prevenir eventos indesejados e desenvolver uma metodologia para coletar dados por meio de simulações, dispensando a dependência de especialistas.

Durante o desenvolvimento da técnica, criamos um DTE de um vaso knockout baseado no modelo apresentado por ALAUDDIN et al. (2020). Esse modelo virtual foi utilizado para gerar um conjunto de treinamento por meio de simulações dos cenários de risco pré-definidos na Seção 4.2.2. Para isso, propôs-se um algoritmo que controla a simulação de forma aleatória, permitindo a geração de informações difíceis de serem coletadas em um ambiente real devido à raridade dos eventos.

A partir do conjunto de dados gerado, desenvolvemos um modelo de rede neural utilizando camadas LSTM e a abordagem Seq-2-Seq para identificar padrões em séries temporais. Esse modelo mostrou-se capaz de prever o comportamento do nível do líquido ao observar diversas variáveis do processo, mesmo na presença de informações incorretas, como demonstrado na Seção 5.3. Essa informação é disponibilizada aos operadores para que possam tomar decisões e evitar que o nível do líquido atinja seu limite.

## 6.2 CONTRIBUIÇÕES

Esta pesquisa representa um avanço significativo na análise de riscos associados aos equipamentos e processos presentes na indústria de petróleo e gás. Ao utilizar redes neurais artificiais, ela oferece uma abordagem que dispensa a necessidade de especialistas e permite inferências em tempo real. O modelo apresentado destaca-se por sua capacidade de produzir resultados consistentes e confiáveis, mesmo quando os dados fornecidos pelos sensores estão com ruídos. Essas características combinadas representam um avanço no estado da arte, conforme demonstrado na Tabela 8, contribuindo para uma análise de riscos mais precisa e eficaz. Esta pesquisa também explorou o uso da abordagem Seq-2-Seq, onde os resultados apresentados no Capítulo 5 mostraram que esta abordagem pode ser uma excelente opção para aplicações de análise de risco, especialmente devido à sua eficácia na previsão de séries temporais. Além disso, descrevemos a criação de um gêmeo digital de um vaso knockout, que pode ser utilizado tanto para explorar otimizações de processos quanto para compreender melhor o funcionamento desse equipamento, servindo como base para o desenvolvimento de novas pesquisas. O projeto do gêmeo digital além do código-fonte dos módulos desenvolvidos estão disponíveis para acesso em: <https://github.com/jrafaelsantana/analise-risco>.

Tabela 8 – Visão geral do estado da arte

Autores e ano de publicação	Modelo	Base de dados	Tempo Real?	Técnica	Vantagens	Desvantagens
ALAUDDIN et al. (2020)	Probabilístico	TALEBBEROUANE; KHAN; LOUNIS (2016); OREDA (2002)	Não	Rede bayesiana	(1) A rede calcula a probabilidade de falhas em cada etapa do processo. (2) Explora a interdependência entre os eventos básicos e as consequências no sistema.	(1) Os valores de probabilidades são estáticos. (2) Exige conhecimento de especialistas para definir os valores de probabilidades.
HE et al. (2022)	Probabilístico	OREDA (2002)	Sim	Rede bayesiana dinâmica	(1) Não requer conhecimento adicional de especialistas.	(1) Exige que seja informado um valor de limiar para ativar os alarmes. A má configuração pode gerar falsos alertas.
YOLCHUYEV (2023)	Rede neural artificial	ConocoPhillips	Sim	FC (FFNN)	(1) Modelo de alta precisão, alcançando 97% de acurácia. (2) Modelo simples que pode ser utilizado em IoT.	(1) Não prevê problemas nos estágios iniciais.
ZHANG et al. (2018b)	Rede neural artificial	Privado	Sim	LSTM (RNN)	(1) Obteve erro quadrático menor quando comparado ao ARIMA.	(1) O modelo não realiza previsões de várias unidades de tempo futuras.
LIU et al. (2023)	Rede neural artificial	Privado	Sim	LSTM-GRU (RNN)	(1) Combinação de conhecimento físico e o modelo baseado em dados, melhorando a generalização e a interpretabilidade da previsão.	(1) Desempenho pouco maior se comparado ao modelo GRU, porém modelo final mais complexo.
Técnica proposta	Rede neural artificial	Privado	Sim	LSTM Seq-2-Seq (RNN)	(1) Não exige conhecimento de especialistas. (2) Prevê o problema em estágios iniciais. (3) Realiza previsões de várias unidades de tempo futuras.	(1) Aumento do erro médio diante de falhas em múltiplos sensores.

Fonte: Autor

### 6.3 LIMITAÇÕES

Embora a técnica proposta tenha apresentado tolerância em diversos cenários, os resultados revelaram um desempenho insatisfatório durante a ocorrência de falhas simultâneas em múltiplos sensores. A probabilidade de tal evento é baixa devido às manutenções preventivas rotineiramente realizadas nos sensores. No entanto, este cenário representa uma vulnerabilidade na técnica, capaz de comprometer sua efetividade e permitir a concretização do evento indesejado que se busca evitar.

É importante ressaltar que os experimentos realizados se restringiram a um conjunto limitado de cenários simuláveis virtualmente. Essa restrição implica que o conjunto de treinamento utilizado não contempla exemplos de algumas situações que podem ocorrer em um ambiente real de produção. Para superar essa limitação, é recomendável realizar o retreinamento do modelo, utilizando dados históricos coletados em um ambiente de produção real. A inclusão de dados reais no treinamento permitirá que o modelo aprenda a lidar com a variabilidade e a complexidade do ambiente real, aprimorando sua capacidade de generalizar para situações não previstas.

### 6.4 TRABALHOS FUTUROS

A técnica proposta nesta dissertação tem grande potencial para aprimorar a segurança do processo. No entanto, pesquisas futuras são necessárias para entender melhor suas capacidades e maximizar os resultados obtidos. Uma área promissora de investigação seria explorar o impacto do uso de um conjunto mais abrangente de variáveis na eficácia e precisão da técnica. Além disso, a incorporação de outras variáveis inferidas por modelos de aprendizagem de máquina pode aumentar a robustez dos resultados.

Em um vaso knockout, sensores de nível físicos geralmente estão instalados em sua estrutura e são usados pelos operadores para inspeção visual. Por meio de técnicas de visão computacional, câmeras podem ser instaladas com foco nesses sensores, permitindo a extração dos valores do nível do líquido e sua inclusão como entrada no modelo. Essa informação pode melhorar os resultados em cenários com falhas nos transmissores de nível ou falhas simultâneas em múltiplos sensores.

Adicionalmente, é importante aprofundar a investigação das técnicas de pré-processamento para lidar com os *outliers*. Em cenários do mundo real, falhas de comunicação entre os sensores

são frequentes, podendo causar leituras atípicas de valores. O tratamento adequado desses valores atua positivamente na precisão do modelo.

## REFERÊNCIAS

- ABBAS, H. A.; MOHAMED, A. M. Review on the design of web based scada systems based on opc da protocol. *arXiv preprint arXiv:1506.05069*, 2015.
- ALAUDDIN, M.; KHAN, F.; IMTIAZ, S.; AHMED, S. A probabilistic risk assessment of offshore flaring systems using bayesian network. In: KHAN, F. I.; SIDDIQUI, N. A.; TAUSEEF, S. M.; YADAV, B. P. (Ed.). *Advances in Industrial Safety*. Singapore: Springer Singapore, 2020. p. 121–131. ISBN 978-981-15-6852-7.
- CHAPMAN, P. Crisp-dm 1.0: Step-by-step data mining guide. In: . [s.n.], 2000. Disponível em: <<https://api.semanticscholar.org/CorpusID:59777418>>.
- CHEBBI, I.; BOULILA, W.; FARAH, I. R. Big data: Concepts, challenges and applications. In: NÚÑEZ, M.; NGUYEN, N. T.; CAMACHO, D.; TRAWIŃSKI, B. (Ed.). *Computational Collective Intelligence*. Cham: Springer International Publishing, 2015. p. 638–647. ISBN 978-3-319-24306-1.
- CHEN, F.-C. Back-propagation neural networks for nonlinear self-tuning adaptive control. *IEEE Control Systems Magazine*, v. 10, n. 3, p. 44–48, 1990.
- CHO, K.; MERRIËNBOER, B. V.; BAHDANAU, D.; BENGIO, Y. On the properties of neural machine translation: Encoder-decoder approaches. *arXiv preprint arXiv:1409.1259*, 2014.
- GABHANE, L. R.; KANIDARAPU, N. Environmental risk assessment using neural network in liquefied petroleum gas terminal. *Toxics*, v. 11, n. 4, 2023. ISSN 2305-6304. Disponível em: <<https://www.mdpi.com/2305-6304/11/4/348>>.
- GANTZ, J.; REINSEL, D. The digital universe in 2020: Big data, bigger digital shadows, and biggest growth in the far east. *IDC iView: IDC Analyze the future*, v. 2007, n. 2012, p. 1–16, 2012.
- Grand View Research. *Digital Twin Market Size, Share & Trends Analysis Report By End-use (Manufacturing, Agriculture), By Solution (Component, Process, System), By Region, And Segment Forecasts, 2023 - 2030*. 2022. Disponível em: <<https://www.grandviewresearch.com/industry-analysis/digital-twin-market>>.
- GRIEVES, M. *Origins of the Digital Twin Concept*. 2016. Disponível em: <[https://www.researchgate.net/publication/307509727\\_Origins\\_of\\_the\\_Digital\\_Twin\\_Concept](https://www.researchgate.net/publication/307509727_Origins_of_the_Digital_Twin_Concept)>.
- GRIEVES, M.; VICKERS, J. Digital twin: Mitigating unpredictable, undesirable emergent behavior in complex systems. In: *Transdisciplinary perspectives on complex systems*. Springer, 2017. p. 85–113. ISBN 978-3-319-38756-7. Disponível em: <[https://doi.org/10.1007/978-3-319-38756-7\\_4](https://doi.org/10.1007/978-3-319-38756-7_4)>.
- HE, K.; ZHANG, X.; REN, S.; SUN, J. Delving deep into rectifiers: Surpassing human-level performance on imagenet classification. In: *Proceedings of the IEEE international conference on computer vision*. [S.l.: s.n.], 2015. p. 1026–1034.
- HE, R.; ZHU, J.; CHEN, G.; TIAN, Z. A real-time probabilistic risk assessment method for the petrochemical industry based on data monitoring. *Reliability Engineering & System Safety*, v. 226, p. 108700, 2022. ISSN 0951-8320. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0951832022003234>>.

HINTON, G. E.; SRIVASTAVA, N.; KRIZHEVSKY, A.; SUTSKEVER, I.; SALAKHUTDINOV, R. R. Improving neural networks by preventing co-adaptation of feature detectors. *arXiv preprint arXiv:1207.0580*, 2012.

HOCHREITER, S.; SCHMIDHUBER, J. Long short-term memory. *Neural computation*, v. 9, p. 1735–80, 12 1997.

HOWIND, S.; SAUTER, T. Modeling energy consumption of industrial processes with seq2seq machine learning. In: *2023 IEEE 32nd International Symposium on Industrial Electronics (ISIE)*. [S.l.: s.n.], 2023. p. 1–4.

IACOB, I. E.; APOSTOLOU, A. A quantitative risk analysis framework for bow-tie models. In: *2015 7th International Conference on Electronics, Computers and Artificial Intelligence (ECAI)*. [S.l.: s.n.], 2015. p. Y–43–Y–46.

JAIN, S.; SHUKLA, S.; WADHVANI, R. Dynamic selection of normalization techniques using data complexity measures. *Expert Systems with Applications*, Elsevier, v. 106, p. 252–262, 2018.

JALAYER, M.; ORSENIGO, C.; VERCELLIS, C. Fault detection and diagnosis for rotating machinery: A model based on convolutional lstm, fast fourier and continuous wavelet transforms. *Computers in Industry*, v. 125, p. 103378, 2021. ISSN 0166-3615. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0166361520306126>>.

KINGMA, D. P.; BA, J. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*, 2014.

KOCSIS, P.; SÚKENÍK, P.; BRASÓ, G.; NIESSNER, M.; LEAL-TAIXÉ, L.; ELEZI, I. The unreasonable effectiveness of fully-connected layers for low-data regimes. *Advances in Neural Information Processing Systems*, v. 35, p. 1896–1908, 2022.

KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, v. 25, 2012.

LIU, S.; LIU, Q.; AHMED, S.; WANG, J.; LEI, F.; ZHAO, D. A method for the early prediction of abnormal conditions in chemical processes combined with physical knowledge and the data-driven model. *Journal of Loss Prevention in the Process Industries*, v. 86, p. 105185, 2023. ISSN 0950-4230. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0950423023002152>>.

LU, L. Dying relu and initialization: Theory and numerical examples. *Communications in Computational Physics*, Global Science Press, v. 28, n. 5, p. 1671–1706, jun. 2020. ISSN 1991-7120. Disponível em: <<http://dx.doi.org/10.4208/cicp.OA-2020-0165>>.

MAAS, A. L.; HANNUN, A. Y.; NG, A. Y. et al. Rectifier nonlinearities improve neural network acoustic models. In: ATLANTA, GA. *Proc. icml*. [S.l.], 2013. v. 30, n. 1, p. 3.

MACHMOOD, K.; SHEVTSHENKO, E. Analysis of machine production processes by risk assessment approach. *Journal of Machine Engineering*, Wrocławska Rada Federacji Stowarzyszeń Naukowo-Technicznych, v. 15, n. 1, p. 112–124, 2015.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, Springer, v. 5, p. 115–133, 1943.

- MIN, Q.; LU, Y.; LIU, Z.; SU, C.; WANG, B. Machine learning based digital twin framework for production optimization in petrochemical industry. *International Journal of Information Management*, v. 49, p. 502–519, 2019. ISSN 0268-4012. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0268401218311484>>.
- NAIR, S. *The increasing popularity of digital twins in oil and Gas*. 2016. Disponível em: <<https://www.gep.com/blog/mind/the-increasing-popularity-of-digital-twins-in-oil-and-gas>>.
- NAIR, V.; HINTON, G. E. Rectified linear units improve restricted boltzmann machines. In: *Proceedings of the 27th international conference on machine learning (ICML-10)*. [S.l.: s.n.], 2010. p. 807–814.
- NOH, S.-H. Analysis of gradient vanishing of rnns and performance comparison. *Information*, v. 12, n. 11, 2021. ISSN 2078-2489. Disponível em: <<https://www.mdpi.com/2078-2489/12/11/442>>.
- OREDA, S. *Offshore Reliability Data Handbook*. [S.l.]: OREDA Participants, 2002. ISBN 82-14-02705-5.
- RAJU, V. N. G.; LAKSHMI, K. P.; JAIN, V. M.; KALIDINDI, A.; PADMA, V. Study the influence of normalization/transformation process on the accuracy of supervised classification. In: *2020 Third International Conference on Smart Systems and Inventive Technology (ICSSIT)*. [S.l.: s.n.], 2020. p. 729–735.
- REASON, J. Human error: models and management. *Bmj*, British Medical Journal Publishing Group, v. 320, n. 7237, p. 768–770, 2000.
- ROBBINS, H. E. A stochastic approximation method. *Annals of Mathematical Statistics*, v. 22, p. 400–407, 1951. Disponível em: <<https://api.semanticscholar.org/CorpusID:16945044>>.
- ROSEN, R.; von Wichert, G.; LO, G.; BETTENHAUSEN, K. D. About the importance of autonomy and digital twins for the future of manufacturing. *IFAC-PapersOnLine*, v. 48, n. 3, p. 567–572, 2015. ISSN 2405-8963. 15th IFAC Symposium on Information Control Problems in Manufacturing. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2405896315003808>>.
- ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, American Psychological Association, v. 65, n. 6, p. 386, 1958.
- ROUGHGARDEN, T.; VALIANT, G. Cs168: The modern algorithmic toolbox lecture# 6: Stochastic gradient descent and regularization. *Lecture Notes, Tim Roughgarden's Homepage*, <http://theory.stanford.edu/~tim/s16/l/l6.pdf>, v. 13, 2016.
- SABBAGH, A. *Digital Twins in the oil and gas industry*. Ericsson, 2021. Disponível em: <<https://www.ericsson.com/en/blog/2021/11/how-digital-twins-in-the-oil-and-gas-industry-can-modernize-your-business>>.
- SARAVANAN, R. Disasters and accidents—what shall not go wrong? In: *Disaster, Risk and Vulnerability Conference*. [S.l.: s.n.], 2014. p. 220.

SCHRÖER, C.; KRUSE, F.; GÓMEZ, J. M. A systematic literature review on applying crisp-dm process model. *Procedia Computer Science*, v. 181, p. 526–534, 2021. ISSN 1877-0509. CENTERIS 2020 - International Conference on ENTERprise Information Systems / ProjMAN 2020 - International Conference on Project MANAgement / HCist 2020 - International Conference on Health and Social Care Information Systems and Technologies 2020, CENTERIS/ProjMAN/HCist 2020. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1877050921002416>>.

SHAFTO, M.; CONROY, M.; DOYLE, R.; GLEASSGEN, E.; KEMP, C.; LEMOIGNE, J.; WANG, L. Draft modelling, simulation, information technology & processing roadmap. *Technology Area*, v. 11, 2010.

SHEN, F.; REN, S. S.; ZHANG, X. Y.; LUO, H. W.; FENG, C. M. A digital twin-based approach for optimization and prediction of oil and gas production. *Mathematical Problems in Engineering*, Hindawi, v. 2021, p. 3062841, Sep 2021. ISSN 1024-123X. Disponível em: <<https://doi.org/10.1155/2021/3062841>>.

SINGH, M.; FUENMAYOR, E.; HINCHY, E.; QIAO, Y.; MURRAY, N.; DEVINE, D. Digital twin: Origin to future. *Applied System Innovation*, v. 4, p. 36, 05 2021.

SUTSKEVER, I.; VINYALS, O.; LE, Q. V. *Sequence to Sequence Learning with Neural Networks*. 2014.

SZANDAŁA, T. Review and comparison of commonly used activation functions for deep neural networks. *Bio-inspired neurocomputing*, Springer, p. 203–224, 2021.

TALEBBERROUANE, M.; KHAN, F.; LOUNIS, Z. Availability analysis of safety critical systems using advanced fault tree and stochastic petri net formalisms. *Journal of Loss Prevention in the Process Industries*, v. 44, p. 193–203, 2016. ISSN 0950-4230. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0950423016302480>>.

WANASINGHE, T. R.; WROBLEWSKI, L.; PETERSEN, B. K.; GOSINE, R. G.; JAMES, L. A.; SILVA, O. D.; MANN, G. K. I.; WARRIAN, P. J. Digital twin for the oil and gas industry: Overview, research trends, opportunities, and challenges. *IEEE Access*, v. 8, p. 104175–104197, 2020.

WU, X.; HUANG, H.; XIE, J.; LU, M.; WANG, S.; LI, W.; HUANG, Y.; YU, W.; SUN, X. A novel dynamic risk assessment method for the petrochemical industry using bow-tie analysis and bayesian network analysis method based on the methodological framework of aramis project. *Reliability Engineering & System Safety*, v. 237, p. 109397, 2023. ISSN 0951-8320. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0951832023003113>>.

YANG, S.; YU, X.; ZHOU, Y. Lstm and gru neural network performance comparison study: Taking yelp review dataset as an example. In: *2020 International Workshop on Electronic Communication and Artificial Intelligence (IWECAI)*. [S.l.: s.n.], 2020. p. 98–101.

YOLCHUYEV, A. Feed-forward neural network based petroleum wells equipment failure prediction. *Engineering*, v. 15, n. 03, p. 163–175, Mar 2023.

ZADAKBAR, O.; KHAN, F.; IMTIAZ, S. Development of economic consequence methodology for process risk analysis. *Risk Analysis*, v. 35, n. 4, p. 713–731, 2015. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1111/risa.12313>>.

ZHANG, J.; CAI, B.; MULENGA, K.; LIU, Y.; XIE, M. Bayesian network-based risk analysis methodology: A case of atmospheric and vacuum distillation unit. *Process Safety and Environmental Protection*, v. 117, p. 660–674, 2018. ISSN 0957-5820. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0957582018303306>>.

ZHANG, W.; GUO, W.; LIU, X.; LIU, Y.; ZHOU, J.; LI, B.; LU, Q.; YANG, S. Lstm-based analysis of industrial iot equipment. *IEEE Access*, PP, p. 1–1, 04 2018.

## APÊNDICE A – LISTA DE VARIÁVEIS MONITORADAS

Variável no Dynsim	Variável no OPC	Descrição	Usado na rede?
VALVE_RESPIRO.OP	Valvula.VALVE_RESPIRO.OP	Comando de abertura da válvula de respiro do vaso	Sim
VALVE_RESPIRO.L	Valvula.VALVE_RESPIRO.L	Elevação da válvula de respiro do vaso	Sim
VALVE1.OP	Valvula.VALVE1.OP	Comando de abertura da válvula de entrada de gás	Sim
VALVE1.L	Valvula.VALVE1.L	Elevação da válvula de entrada de gás	Sim
VALVE2.L	Valvula.VALVE2.L	Elevação da válvula de saída de gás	Sim
VALVE2.OP	Valvula.VALVE2.OP	Comando de abertura da válvula de saída de gás	Sim
SAIDA_VAZAMENTO.P	StreamSend.SAIDA_VAZAMENTO.P	Pressão do fluxo de saída do vazamento de teste	Não
SAIDA_LIQUIDO.P	StreamSend.SAIDA_LIQUIDO.P	Pressão do fluxo de saída do líquido	Sim
SAIDA_GAS.P	StreamSend.SAIDA_GAS.P	Pressão do fluxo de saída do gás	Sim
FLARE.P	StreamSend.FLARE.P	Pressão do fluxo de saída do flare	Sim
VALVE4.OP	Valvula.VALVE4.OP	Comando de abertura da válvula de saída de líquido	Sim
VALVE4.L	Valvula.VALVE4.L	Elevação da válvula de saída de líquido	Sim
VALVE3.L	Valvula.VALVE3.L	Elevação da válvula de saída do flare	Sim
VALVE3.OP	Valvula.VALVE3.OP	Comando de abertura da válvula do flare	Sim
VALVE5.L	Valvula.VALVE5.L	Elevação da válvula de saída do vazamento	Não
PID1.OUT	Controlador.PID1.OUT	Controlador de pressão para controlar a entrada de gás no vaso	Sim
PID2.OUT	Controlador.PID2.OUT	Controlador de pressão para controlar a saída de gás do vaso	Sim
PID3.OUT	Controlador.PID3.OUT	Controlador para controlar a válvula de saída de líquido	Sim
PC1.OUT	Controlador.PC1.OUT	Controlador para controlar a válvula do flare	Sim
TR3.OUT	Transmissor.TR3.OUT	Transmissor do nível de líquido do vaso	Não
TR2.OUT	Transmissor.TR2.OUT	Transmissor do nível de líquido do vaso	Não
TR1.OUT	Transmissor.TR1.OUT	Transmissor do nível de líquido do vaso	Não
V1.T	Drum.V1.T	Temperatura do vaso	Sim
V1.P	Drum.V1.P	Pressão interna do vaso	Sim
V1.L	Drum.V1.L	Nível do líquido no vaso	Não
S28.W	Tubo.S28.W	Taxa de fluxo de massa	Não
S28.P	Tubo.S28.P	Pressão	Não
S27.W	Tubo.S27.W	Taxa de fluxo de massa	Não
S27.P	Tubo.S27.P	Pressão	Não
S26.W	Tubo.S26.W	Taxa de fluxo de massa	Sim
S26.P	Tubo.S26.P	Pressão	Sim
S25.W	Tubo.S25.W	Taxa de fluxo de massa	Não
S25.P	Tubo.S25.P	Pressão	Não
S4.W	Tubo.S4.W	Taxa de fluxo de massa	Sim
S4.P	Tubo.S4.P	Pressão	Sim
S3.W	Tubo.S3.W	Taxa de fluxo de massa	Não
S3.P	Tubo.S3.P	Pressão	Não
S10.W	Tubo.S10.W	Taxa de fluxo de massa	Sim
S10.P	Tubo.S10.P	Pressão	Sim
S5.W	Tubo.S5.W	Taxa de fluxo de massa	Não

S5.P	Tubo.S5.P	Pressão	Não
S6.W	Tubo.S6.W	Taxa de fluxo de massa	Sim
S6.P	Tubo.S6.P	Pressão	Sim
S2.W	Tubo.S2.W	Taxa de fluxo de massa	Não
S2.P	Tubo.S2.P	Pressão	Não
S1.P	Tubo.S1.P	Pressão	Não
S1.W	Tubo.S1.W	Taxa de fluxo de massa	Não
VALVE_SHUTOFF.OP	Valvula.VALVE_SHUTOFF.OP	Comando de abertura da válvula de shutoff	Sim
VALVE_SHUTOFF.L	Valvula.VALVE_SHUTOFF.L	Elevação da válvula de shutoff	Sim
VALVE5.OP	Valvula.VALVE5.OP	Comando de abertura da válvula de vazamento	Não
VOTACAO_TRANSMISSORES	Variaveis.VOTACAO_TRANSMISSORES	Variável para armazenar o valor do nível de líquido do vaso após votação dos transmissores	Sim
TR3_RUIDO	Variaveis.TR3_RUIDO	Variável para ativar e desativar o ruído no transmissor 3	Não
TR2_RUIDO	Variaveis.TR2_RUIDO	Variável para ativar e desativar o ruído no transmissor 2	Não
TR1_RUIDO	Variaveis.TR1_RUIDO	Variável para ativar e desativar o ruído no transmissor 1	Não
OP_CONCESSIONARIA	Variaveis.OP_CONCESSIONARIA	Variável para ligar e desligar a entrada de gás pela concessionária	Não
H2O_QTD	Variaveis.H2O_QTD	Variável para controlar a taxa de entrada de líquido no vaso	Não