

**CENTRO UNIVERSITÁRIO SENAI CIMATEC****CURSO DE ESPECIALIZAÇÃO EM ENGENHARIA DE  
CONFIABILIDADE****PREVISÃO DE INTEGRIDADE EM TUBULAÇÕES INDUSTRIAIS ATRAVÉS DE  
REDES NEURAIAS: UMA ABORDAGEM ABRANGENTE**

Leonardo Lopes Nascimento<sup>1</sup>  
Orientador: Prof. Dr. Carlos Augusto de Souza<sup>2</sup>

**Resumo:** Este artigo avalia a integridade de tubulações de drenagem industrial, visando à confiabilidade operacional em sistemas complexos. Diante da diversidade de materiais e fluidos empregados, a utilização de Redes Neurais Artificiais (RNAs) surge como uma abordagem promissora. Autores como Elsayed e Lafraia ressaltam a relevância da confiabilidade em contextos industriais. A metodologia adotada compreendeu a normalização dos dados coletados das tubulações, pré-processamento e análise exploratória. O Multi-Layer Perceptron (MLP), validação cruzada *Stratified K-Fold* e regularização L2 foram estratégias escolhidas para a construção do modelo. Os resultados apresentaram consistência, com acurácias médias de teste variando entre 83.77% à 91.54%. As previsões confirmaram tendências identificadas na análise exploratória, destacando a influência do material e tipo de fluido nas previsões. A sinergia entre conhecimento técnico e IA evidenciou-se como recurso valioso para aprimorar a gestão da confiabilidade em ambientes industriais complexos. As conclusões indicam que a aplicação de RNAs na avaliação da integridade de tubulações oferece potencial para melhorar a tomada de decisões, otimizar a manutenção e prolongar a vida útil desses sistemas, impactando positivamente a indústria como um todo.

**Palavras Chaves:** Redes Neurais Artificiais, Confiabilidade, Drenagem Industrial, Tubulações Enterradas

---

<sup>1</sup>Leonardo Lopes Nascimento: Bacharel em Engenharia Mecânica, [leoln93@gmail.com](mailto:leoln93@gmail.com)

<sup>2</sup>Carlos Augusto de Souza: Doutor em Engenharia Mecânica, Universidade Paris VI, [carlos.souza@fiieb.org.br](mailto:carlos.souza@fiieb.org.br)

# 1 Introdução

A integridade operacional das tubulações desempenha um papel fundamental na indústria, especialmente no contexto de sistemas de drenagem industrial. A confiabilidade desses sistemas é essencial para garantir que fluidos sejam direcionados de maneira eficiente e segura, contribuindo para a manutenção do desempenho e atendimento a regulamentações ambientais rigorosas. De acordo com Fogliatto (2006), a confiabilidade é definida como a probabilidade de um sistema realizar suas funções sob condições estabelecidas, é um elemento crítico para a operação bem-sucedida de indústrias em todo o mundo.

A diversidade das tubulações de drenagem industrial é agravada pela variedade de materiais utilizados em sua construção. Materiais como polímeros, ligas metálicas e concreto são empregados para atender a requisitos específicos de cada aplicação. Essa variedade de materiais cria um ambiente desafiador para avaliar e prever a integridade dessas tubulações, demandando abordagens inovadoras e avançadas para garantir que a confiabilidade seja mantida ao longo do tempo (Lafraia, 2001).

Autores como Elsayed (1992) e Lafraia (2001) enfatizam a importância da confiabilidade na manutenção de sistemas complexos. Elsayed destaca a necessidade de métodos precisos para avaliar e melhorar a confiabilidade, especialmente em contextos industriais, onde as consequências de falhas podem ser significativas. Lafraia, por sua vez, contribui com a aplicação da análise de sobrevivência na avaliação da confiabilidade de sistemas, demonstrando a relevância da abordagem de análise de dados para compreender a integridade e a longevidade dos sistemas.

No cenário atual, a Inteligência Artificial (IA) tem emergido como uma ferramenta poderosa para enfrentar os desafios da confiabilidade e integridade das tubulações de drenagem industrial. Especificamente, as Redes Neurais Artificiais (RNAs) têm se destacado como uma abordagem promissora para avaliar e prever problemas de integridade. Segundo Haykin (1999), as RNAs são estruturas computacionais inspiradas no funcionamento do cérebro humano, capazes de aprender padrões complexos a partir de dados brutos. Sua capacidade de lidar com informações multidimensionais e não lineares as torna particularmente adequadas

para enfrentar os desafios inerentes à avaliação da confiabilidade de sistemas complexos, como as tubulações de drenagem industrial.

Este artigo visa explorar a aplicação das RNAs na avaliação da integridade das tubulações de drenagem industrial, considerando a diversidade de materiais empregados. Foram discutidos os benefícios da utilização de RNAs para prever problemas de integridade, otimizar operações e garantir a confiabilidade desses sistemas. A abordagem proposta neste artigo combina conhecimentos técnicos de engenharia de materiais e IA (Inteligência Artificial), fornecendo uma metodologia inovadora para prevenir falhas e melhorar a eficiência das operações de drenagem industrial.

O principal objetivo é discutir a efetividade de uma RNA criada de forma customizada para prever a integridade de tubulações com diversas características. Por consequência, o artigo apresenta os seguintes desdobramentos:

- A exploração da influência dos diferentes materiais de tubulação na confiabilidade e previsão de integridade em sistemas de drenagem industrial.
- Uma abordagem detalhada baseada em Redes Neurais Artificiais para avaliar a integridade de sistemas complexos de tubulação.
- A relevância da análise de dados e IA na detecção precoce de problemas de integridade e otimização da confiabilidade operacional.
- *Insights* sobre como a combinação de conhecimentos técnicos especializados e IA pode transformar a gestão da confiabilidade em ambientes industriais desafiadores.

Neste contexto, é importante ressaltar que os riscos de vazamento de produtos em sistemas de drenagem industrial podem ter sérios impactos ambientais, incluindo a contaminação do solo e a possibilidade de comprometimento dos ecossistemas locais. Normas regulamentadoras como a NR-25 (2023), estabelecem diretrizes estritas para a prevenção de vazamentos e o manuseio seguro de produtos químicos e materiais perigosos. Garantir a integridade desses sistemas não apenas promove a eficiência operacional, mas também contribui para a preservação ambiental e o cumprimento das regulamentações.

Nos próximos segmentos deste artigo, foi apresentado em detalhes os conceitos fundamentais das RNAs, a metodologia proposta para avaliação de

integridade e os resultados obtidos a partir da aplicação dessa abordagem em sistemas de drenagem industrial.

## **2 Metodologia**

A avaliação da integridade das tubulações industriais foi conduzida por meio da aplicação de dois métodos: o teste de estanqueidade e a vídeo inspeção. Esses procedimentos desempenharam um papel fundamental na análise do estado de integridade das tubulações sob investigação.

O teste de estanqueidade foi empregado para verificar a capacidade das tubulações em manter a contenção do efluente transportado. As tubulações que demonstraram sucesso nesse ensaio foram classificadas como "íntegras". Tal classificação indicava a ausência de indícios de perda de contenção do efluente, implicando a integridade das tubulações.

O teste de estanqueidade é um procedimento utilizado para verificar a integridade de tubulações industriais, garantindo que não haja vazamentos ao longo do sistema. Ele consiste em pressurizar a tubulação com um fluido, geralmente ar ou água, e monitorar se há queda na pressão ao longo do tempo, o que indicaria a presença de vazamentos. Já a vídeo de inspeção é uma técnica que utiliza câmeras de vídeo acopladas a equipamentos especiais para percorrer o interior das tubulações, permitindo a visualização direta do estado das mesmas. Essa inspeção visual remota tem como finalidade identificar possíveis danos, corrosão, obstruções ou qualquer outra anomalia que possa comprometer a integridade da tubulação. Ambos os testes são essenciais para garantir a segurança e confiabilidade das operações industriais, uma vez que permitem a detecção precoce de problemas e a realização de intervenções preventivas ou corretivas quando necessário. A vídeo inspeção, por sua vez, teve um papel significativo na avaliação das condições físicas das tubulações. Este procedimento possibilitou a identificação de vulnerabilidades substanciais nas tubulações e contribuiu para a categorização de certos mecanismos de danos identificados.

Com base nos resultados obtidos a partir desses ensaios, as tubulações foram classificadas nas seguintes categorias com base em documentação interna da equipe de inspeção de tubulações enterradas:

- **Tubulações Integras:** Compreendem aquelas tubulações que, após a aplicação dos ensaios, não apresentaram indícios de perda de contenção do efluente. Essa classificação reflete a integridade das tubulações, indicando que as mesmas se encontram em um estado seguro em relação à sua capacidade de contenção.
- **Tubulações Não Integras:** Englobam tubulações para as quais foram observados indícios que sugerem a possibilidade de perda de contenção do efluente. Tais indícios podem incluir vulnerabilidades identificadas no ensaio visual ou vazamentos detectados no teste de estanquidade.

Essa categorização das tubulações foi essencial para a análise da integridade das tubulações avaliadas. Ela permitiu uma distinção clara entre aquelas tubulações que se encontram em condições adequadas e as que podem apresentar riscos para o sistema de drenagem industrial em questão.

A construção da Rede Neural Artificial (RNA) empregada neste estudo adotou uma abordagem personalizada desenvolvida pelo autor deste artigo. Essa estratégia customizada permitiu a criação de uma RNA adaptada às necessidades específicas da avaliação da integridade das tubulações de drenagem industrial.

Uma RNA é um modelo computacional inspirado no funcionamento do cérebro humano, composto por neurônios artificiais interconectados. No contexto do estudo, a RNA é empregada para prever o estado de integridade das tubulações com base em uma série de parâmetros de entrada que foram selecionados com base na análise exploratória dos dados e no conhecimento das tubulações industriais. Esses parâmetros foram escolhidos por sua relevância na avaliação da integridade das tubulações, levando em consideração fatores como material, diâmetro, tipo de fluido, comprimento e localização na planta. A escolha desses parâmetros foi fundamentada na compreensão das características das tubulações e de como cada fator pode influenciar sua integridade. Além disso, a seleção visa garantir que o modelo de Rede Neural Artificial (RNA) seja capaz de capturar as nuances dos dados e fazer previsões precisas sobre o estado de integridade das tubulações.

As etapas de entrada e saída de uma RNA envolvem a passagem dos dados através da rede para processamento e geração de uma resposta preditiva. Na etapa de entrada, os dados referentes às características das tubulações são inseridos na rede neural. Cada parâmetro é representado por um nó de entrada, que transmite um

sinal para a camada de neurônios oculta. Nessa camada, os sinais são processados por meio de operações matemáticas, ponderados pelos pesos sinápticos das conexões entre os neurônios.

Após o processamento na camada oculta, os sinais são propagados para a camada de saída, onde são combinados para produzir a resposta final da rede. No contexto da integridade de tubulações, a saída da RNA pode ser uma classificação binária, indicando se a tubulação está íntegra ou não com base nos parâmetros de entrada fornecidos.

A configuração da RNA e a seleção dos parâmetros de entrada garantem a precisão e confiabilidade das previsões geradas. Diferentes tipos de materiais, diâmetros, fluidos transportados e condições operacionais podem influenciar significativamente na integridade das tubulações, sendo essencial considerar esses aspectos na modelagem da rede neural. Assim, a RNA se torna uma ferramenta poderosa para prever a integridade das tubulações industriais, proporcionando insights valiosos para a gestão eficaz desses sistemas críticos.

O desenvolvimento da RNA abrangeu a definição da arquitetura da rede, incluindo parâmetros como o número de camadas ocultas, a quantidade de neurônios em cada camada e as funções de ativação apropriadas. Adicionalmente, foram implementadas técnicas de regularização L2 com o propósito de mitigar o *overfitting*, buscando alcançar um equilíbrio adequado entre simplicidade e complexidade do modelo.

A metodologia adotada neste estudo faz uso de uma Rede Neural Artificial (RNA) para prever a integridade das tubulações industriais, com base nos dados obtidos por meio de vídeo-inspeção e do teste de estanqueidade conduzidos nas tubulações.

Para treinar a RNA e avaliar seu desempenho, empregou-se a técnica de validação cruzada conhecida como *Stratified K-Fold*. Segundo Silva (2020) a validação cruzada representa uma abordagem essencial em aprendizado de máquina para avaliar a capacidade de generalização de um modelo. No contexto do *Stratified K-Fold*, o conjunto de dados é subdividido em K subconjuntos (ou "*folds*"), preservando a proporção de classes em cada *fold* tão próxima quanto possível da proporção original no conjunto de dados completo. O modelo é, então, treinado e avaliado K vezes, utilizando um *fold* diferente como conjunto de teste em cada iteração, enquanto os demais funcionam como conjunto de treinamento. Essa

abordagem auxilia na obtenção de estimativas robustas do desempenho do modelo, particularmente quando se trabalha com conjuntos de dados desequilibrados, como no caso da avaliação da integridade das tubulações.

A utilização do *Stratified K-Fold* assegura que a distribuição das classes "Integras" e "Não Integras" seja mantida em cada conjunto de treinamento e teste, mitigando quaisquer vieses na avaliação do modelo. Isso desempenha um papel fundamental em garantir que o modelo possa prever com precisão a integridade das tubulações em diferentes cenários de operação, mesmo quando as classes estão representadas de forma desproporcional nos dados.

A construção da RNA, assim como a personalização da metodologia por parte do autor deste estudo, realça a abordagem acadêmica e a originalidade desta pesquisa. Isso ressalta o compromisso de criar uma ferramenta de previsão de integridade específica para as tubulações industriais sob investigação, contribuindo para a qualidade e confiabilidade dos resultados obtidos neste estudo.

O desenvolvimento de uma metodologia robusta e criteriosamente definida viabiliza a criação de um modelo preciso e confiável para prever a integridade das tubulações industriais, levando em consideração a complexidade dos dados e a necessidade de garantir que o modelo seja eficaz na generalização para cenários de operação real.

## **2.1 Estudo de Caso**

A princípio a extensão do estudo de caso abrangeria aproximadamente 41 quilômetros de tubulações, subdividida em cerca de 3600 trechos, variando desde segmentos modestos de 0,5 metros até extensões mais substanciais de 1 quilômetro. Porém para facilitar o escopo e ter um resultado que permita uma análise mais simples, a quantidade de linhas foi reduzida para quase 6 quilômetros em 765 linhas. Esse estudo durou 7 meses com uma equipe de 2 inspetores de integridade, 1 projetista de tubulação e uma equipe de campo com mais de 15 pessoas responsável por coletar os dados e as imagens das tubulações.

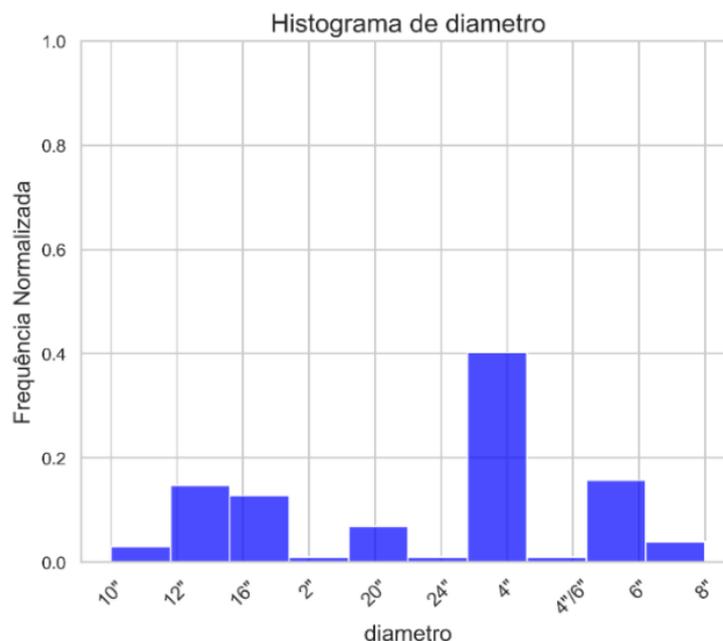
Vale ressaltar que, por se tratar de uma rede de drenagem, há uma constante flutuação na concentração dos hidrocarbonetos presentes no interior dessas tubulações que também tem diversos materiais envolvidos.

Essas peculiaridades da rede de drenagem contribuem para a complexidade adicional do estudo, uma vez que a presença variável de hidrocarbonetos impõe desafios particulares na análise e gestão eficaz desse sistema extenso. O ambiente multifacetado apresenta um cenário complexo para a formulação de estratégias e tomadas de decisão, destacando a importância de uma abordagem cuidadosa e especializada na condução desse estudo de caso na planta petroquímica em questão.

Durante a fase inicial deste estudo, a abordagem de tratamento de dados garantiu a qualidade e a veracidade das informações utilizadas para avaliar as tubulações de drenagem industrial. A normalização dos dados de treinamento foi realizada para padronizar os valores dos atributos, assegurando que o modelo possa aprender de maneira uniforme e eficaz em todo o conjunto de dados. Além disso, técnicas de pré-processamento foram aplicadas aos dados de operação, selecionando aqueles que estavam dentro dos limites estabelecidos durante a fase de teste. Isso permitiu que as previsões de integridade fossem realizadas em condições realistas de operação, aumentando a relevância e a confiabilidade das análises.

A análise exploratória dos dados forneceu *insights* sobre as características das tubulações e na identificação de padrões ou discrepâncias em potencial. Através da criação de histogramas, foi possível visualizar a distribuição de frequência de atributos como área, diâmetro, material e fluido.

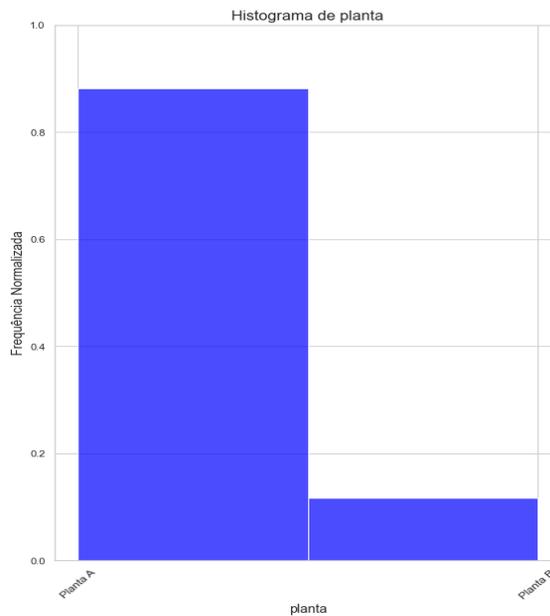
**Figura 1 – Histograma dos diâmetros (normalizados)**



Fonte: Autor (2023)

Conforme demonstrado na Figura 1, o histograma de diâmetros destacou uma variação considerável, com a maioria das tubulações apresentando diâmetros entre e 4 e 6 polegadas.

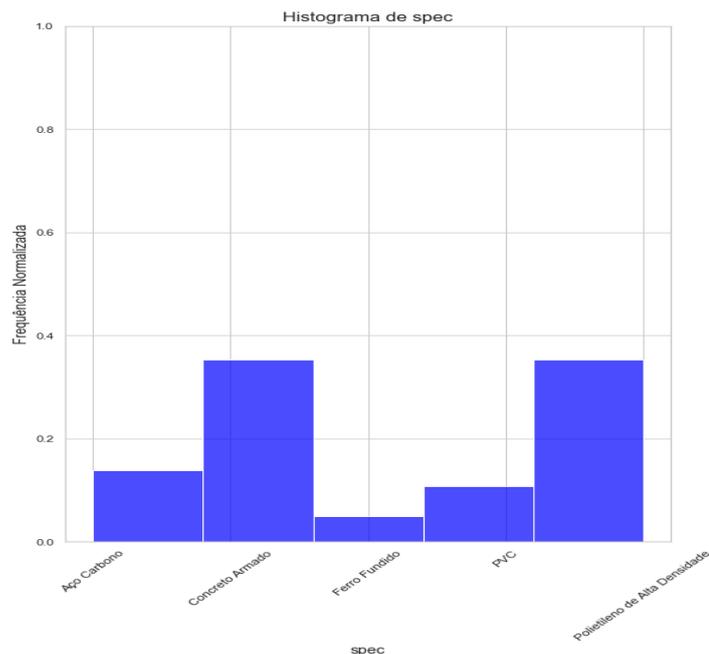
**Figura 2 - Histograma das plantas (normalizados)**



Fonte: Autor (2023)

A Figura 2 apresenta o histograma das plantas, com uma concentração maior de dados na área Planta A, possivelmente indicando assimetrias na distribuição das áreas das tubulações.

**Figura 3 - Histograma dos materiais (normalizados)**



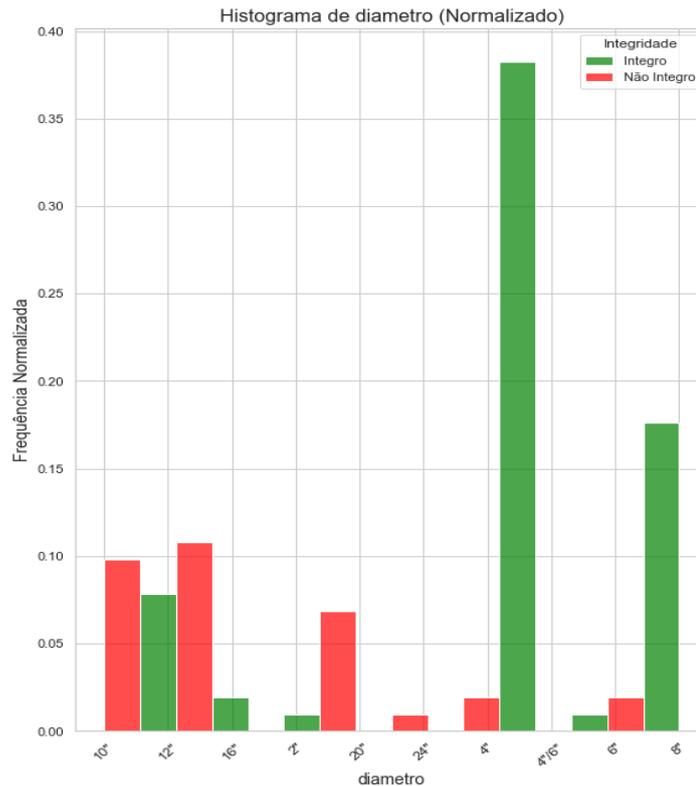
Fonte: Autor (2023)

Em relação ao material, a Figura 3 revelou a predominância dos tipos Polietileno de Alta Densidade (PEAD) e concreto armado nas tubulações analisadas.

Essa exploração dos dados proporcionou um direcionamento sobre a distribuição e tendências dos atributos das tubulações. Os resultados contribuíram para a seleção apropriada das variáveis de entrada e para o desenvolvimento de um modelo de previsão de integridade mais preciso e confiável, baseado nos padrões identificados durante a análise exploratória.

Ao realizar a análise exploratória, avaliações detalhadas foram conduzidas para identificar padrões e relações entre os atributos das tubulações e seu estado de integridade. Gráficos de barras foram criados para visualizar essas relações. Uma descoberta notável foi a relação entre o diâmetro das tubulações e seu estado de integridade. Observou-se que tubulações com maiores diâmetros tendiam a apresentar mais casos de não integridade, enquanto aquelas com menores diâmetros estavam associadas a uma maior integridade, como mostrado na Figura 4. Esse comportamento pode ser parcialmente atribuído à composição dos materiais utilizados nas tubulações.

**Figura 4 – Relação entre o estado de integridade e os diâmetros (normalizados)**



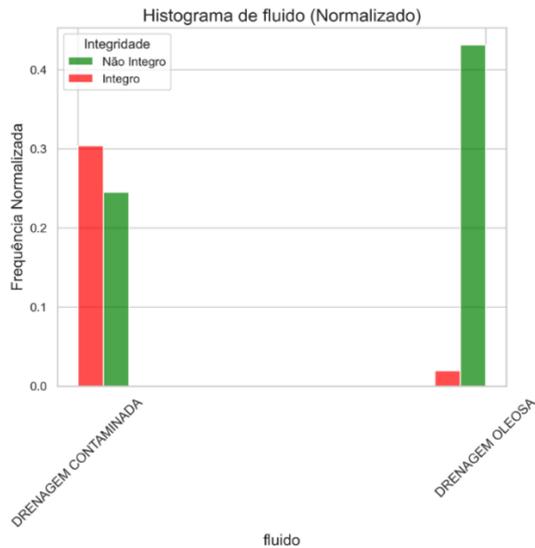
Fonte: Autor (2023)

Tubulações fabricadas com polímeros e ligas metálicas, geralmente apresentando diâmetros menores, demonstraram manter sua integridade, enquanto aquelas com diâmetros maiores, frequentemente encontradas em materiais diferentes, exibiram uma maior incidência de não integridade. A influência do tipo de fluido transportado também foi objeto de avaliação. Conforme ilustrado na Figura 5, tubulações destinadas à drenagem de efluentes oleosos mostraram uma proporção significativamente maior de componentes íntegros em comparação com aquelas destinadas à drenagem de efluentes contaminados. Essa discrepância não se deve apenas às propriedades químicas dos fluidos, mas também ao volume de efluentes presentes nas tubulações. Adicionalmente, tubulações de drenagem contaminada, frequentemente compostas pelo material concreto armado, tiveram sua integridade comprometida devido à possível incompatibilidade desse material com efluentes corrosivos e o ambiente de transporte. Portanto, a relação entre o tipo de fluido e a integridade das tubulações é de natureza complexa e influenciada por diversos fatores inter-relacionados.

Drenagem oleosa pode ser definida como o sistema de tubulação que conduz diretamente os produtos provenientes dos equipamentos, visando o tratamento e

descarte adequados, enquanto drenagem contaminada refere-se ao sistema de tubulação da planta que pode conter traços residuais de produtos, caracterizados por concentrações baixas desses componentes.

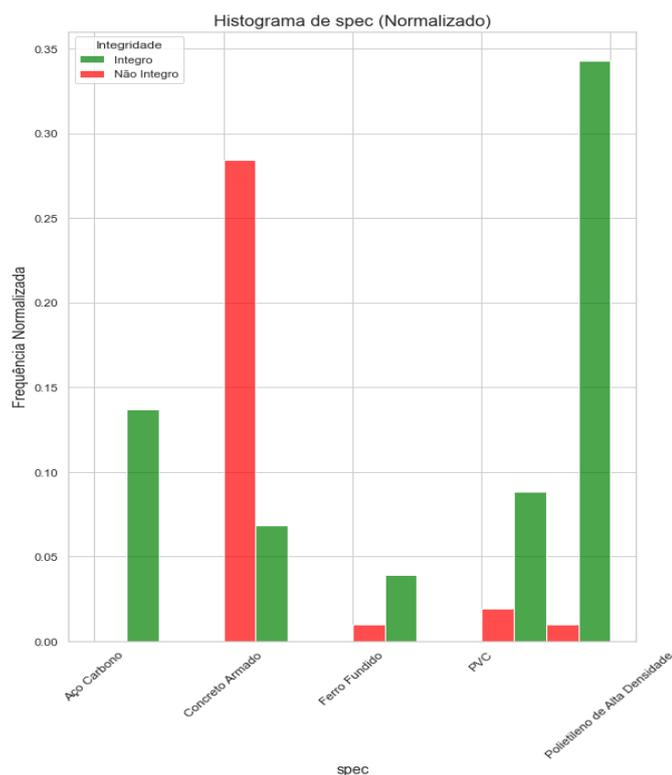
**Figura 5 – Relação entre o estado de integridade e tipo de fluido (normalizado)**



Fonte: Autor (2023)

Além disso, a análise revelou informações significativas sobre a influência do material das tubulações em seu estado de integridade. Os resultados indicaram que tubulações feitas de concreto armado demonstraram um maior número de casos não íntegros em comparação com tubulações feitas de PEAD, que apresentaram uma incidência maior de tubulações íntegras. O ferro fundido e o aço carbono também exibiram variações notáveis, mas em direções opostas, como observado na Figura 6.

**Figura 6 – Relação entre o estado de integridade e os materiais das tubulações (normalizado)**



Fonte: Autor (2023)

As análises reforçaram a relevância das características específicas das tubulações na determinação de seu estado de integridade. Essas conclusões foram fundamentais para o desenvolvimento de um modelo de previsão de integridade, que utilizou uma abordagem baseada em Redes Neurais Artificiais (RNAs).

Para construir o modelo de previsão de integridade das tubulações, optou-se pelo *Multi-Layer Perceptron* (MLP), uma arquitetura de redes neurais artificiais. O MLP é uma escolha adequada para tarefas de classificação e reconhecimento de padrões, devido à sua capacidade de aprender representações complexas dos dados. O uso de RNAs oferece flexibilidade para capturar relações não lineares entre os atributos, permitindo uma modelagem mais precisa do problema.

A avaliação robusta do desempenho do modelo foi conduzida através da técnica de validação cruzada *Stratified K-Fold*. Essa abordagem é particularmente indicada para conjuntos de dados desequilibrados, como o utilizado, onde a distribuição das classes não é uniforme. O *Stratified K-Fold* assegura a manutenção da proporção entre as classes em cada etapa, evitando vieses na avaliação do modelo.

Além disso, técnicas de regularização L2 foram aplicadas para lidar com problemas de overfitting e melhorar a generalização do modelo. O parâmetro alpha foi

ajustado para controlar a intensidade da regularização, prevenindo ajustes excessivos aos dados de treinamento e aumentando a capacidade de generalização do modelo para novos dados.

O otimizador estocástico (Stochastic Gradient Descent - SGD) foi escolhido como solver para o MLP. Esse otimizador é adequado para conjuntos de dados grandes e eficaz na otimização de redes neurais profundas. Ele trabalha atualizando os pesos da rede de forma incremental, ajustando-os gradualmente em direção ao mínimo global da função de perda. Essa abordagem é vantajosa para problemas complexos de previsão de integridade de tubulações, permitindo uma convergência mais rápida e eficiente durante o treinamento da rede.

O MLP (Multi-Layer Perceptron) é um tipo de rede neural artificial composta por várias camadas de neurônios interconectados. Cada neurônio em uma camada está conectado a todos os neurônios na camada seguinte, formando uma rede em que a informação flui de uma camada para a próxima. O MLP é conhecido por sua capacidade de aprender e modelar relações complexas entre os dados de entrada e saída, tornando-se uma ferramenta poderosa para tarefas de previsão e classificação.

A escolha do MLP, a validação cruzada *Stratified K-Fold* e a configuração cuidadosa dos parâmetros formam uma base sólida para a construção de um modelo preciso e robusto de previsão de integridade de tubulações. Essa abordagem captura complexidades dos dados de integridade das tubulações, fornecendo previsões precisas mesmo em situações desafiadoras.

Considerando os parâmetros definidos em nosso método de avaliação de ajuste, analisamos os impactos do underfitting e overfitting no desempenho de nosso modelo de previsão de integridade de tubulações, juntamente com a avaliação da acurácia média nos conjuntos de treinamento e teste. O objetivo é encontrar um equilíbrio entre a simplicidade e complexidade do modelo, evitando ajustes excessivos ou inadequados.

### 3 Resultados e Discussões

A metodologia adotada foi projetada para avaliar a integridade das tubulações industriais por meio da aplicação de métodos de teste de estanqueidade e vídeo inspeção. Esses métodos forneceram a base para a análise subsequente, permitindo a classificação das tubulações em "Integras" e "Não Integras". Com base nesse procedimento, uma Rede Neural Artificial (RNA) customizada foi desenvolvida, utilizando parâmetros cuidadosamente selecionados, como material, diâmetro, tipo de fluido, entre outros, para prever a integridade das tubulações. A escolha desses parâmetros foi orientada pela análise exploratória dos dados e pelo conhecimento especializado do domínio das tubulações industriais, garantindo a relevância e a eficácia do modelo. Com a metodologia estabelecida, é possível apresentar os resultados obtidos a partir da aplicação dessa abordagem em um estudo de caso específico.

Os resultados após a execução do algoritmo de previsão de integridade de tubulações revelaram o seguinte desempenho:

**Tabela 3.1 - Resultado das Acurácias Médias Para Cada *Fold***

	<b><i>Fold</i></b>	<b>1</b>	<b>2</b>	<b>3</b>	<b>4</b>	<b>5</b>
<b>Acurácia</b>	<b>Treinamento</b>	0.8693	0.8572	0.8961	0.8686	0.8592
<b>Média</b>	<b>Teste</b>	0.8510	0.9154	0.8377	0.8386	0.9095
	Status	Modelo adequado				

Fonte: Autor (2023)

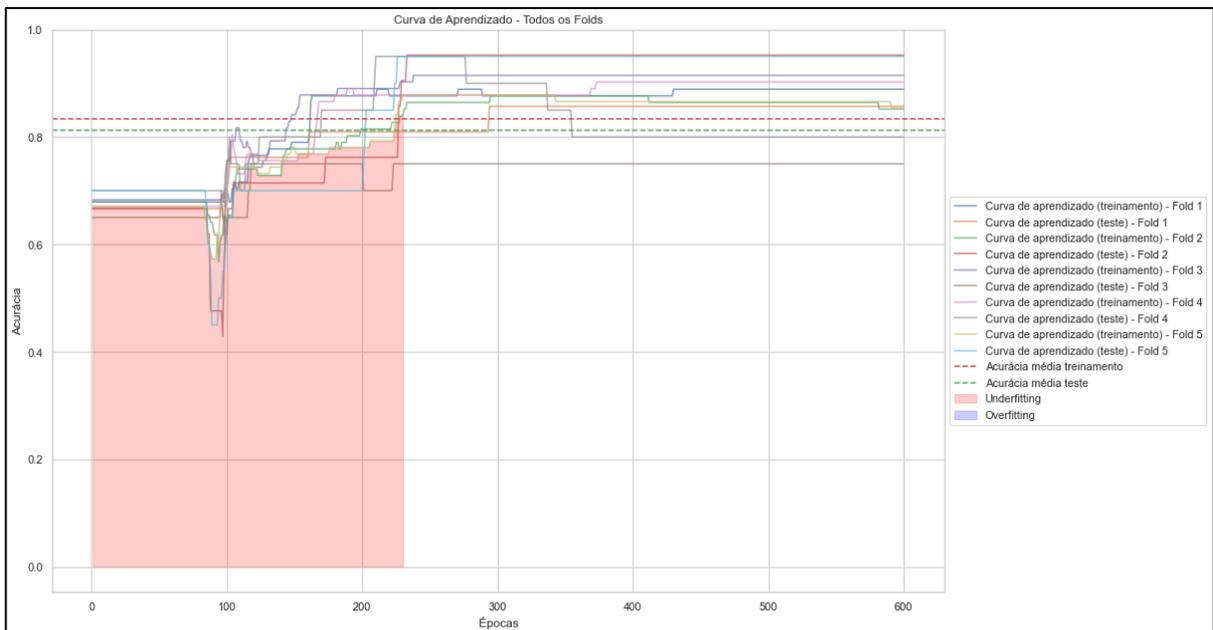
Os resultados da tabela 3.1 indicam um bom desempenho do modelo na maioria dos casos, com acurácia média de teste variando entre aproximadamente 83,77% à 91,54%. A consistência entre diferentes *folders* reforça a robustez do modelo, indicando uma boa capacidade de generalização para diferentes subconjuntos de dados.

De acordo com Silva (2020), o *underfitting* ocorre quando o modelo de machine learning não consegue capturar adequadamente a complexidade dos dados, resultando em uma baixa performance tanto nos dados de treinamento quanto nos de teste. Isso pode acontecer quando o modelo é muito simples para representar a relação entre as variáveis de entrada e saída, ou quando há uma quantidade insuficiente de dados disponíveis para treinamento.

Por outro lado, o *overfitting* ocorre quando o modelo se ajusta muito bem aos dados de treinamento, capturando até mesmo o ruído presente neles, o que leva a uma baixa capacidade de generalização para novos dados. Isso pode ser causado por um modelo muito complexo ou por um volume insuficiente de dados de treinamento em relação à complexidade do modelo.

O limiar de *underfitting* igual a 0,85 e o limiar de *overfitting* igual a 0,95 foram estabelecidos com base em considerações práticas e teóricas. O valor mais alto do limiar de *underfitting* foi escolhido para evitar a simplicidade excessiva do modelo, que poderia resultar em previsões imprecisas. Enquanto isso, o limiar de *overfitting* foi definido em 0,95 para evitar ajustes excessivos aos dados de treinamento, comprometendo a capacidade de generalização do modelo para novos conjuntos de dados. Esses limiares tiveram uma grande importância na obtenção de um modelo balanceado, capaz de prever a integridade das tubulações com precisão e confiabilidade.

**Figura 7 – Curva de aprendizado para Kfold com limiares de under e overfitting**



Fonte Autor (2023)

A figura 7 ilustra a curva de aprendizado para K-Fold com limiares de underfitting e overfitting, demonstrando como o modelo se comporta em relação aos limiares estabelecidos.

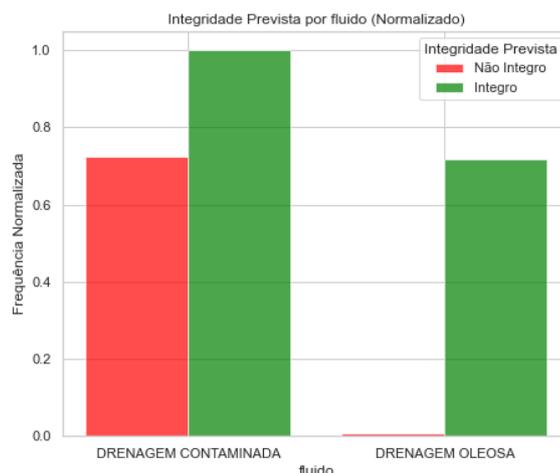
Em uma análise aprofundada da curva de aprendizado gerada durante o treinamento do modelo, observamos inicialmente a presença de underfitting, caracterizado por uma discrepância entre as previsões do modelo e os dados reais. No entanto, à medida que o treinamento avança, notamos uma notável mudança de padrão após aproximadamente 250 iterações, indicando que o modelo começa a capturar mais nuances nos dados. Esse fenômeno sugere que, após essa fase inicial de ajuste insuficiente, o modelo converge para uma representação mais precisa e eficiente, refletindo uma redução no underfitting e uma melhoria na capacidade do modelo de se ajustar aos dados de treinamento.

Neste estudo, a combinação da abordagem baseada em MLP, validação cruzada, regularização e otimização SGD permitiu a construção de um modelo sólido e confiável para previsão de integridade de tubulações. Esse modelo demonstrou sua eficácia ao capturar as complexidades dos dados e gerar previsões precisas, tornando-se uma ferramenta valiosa para a manutenção e gestão desses sistemas críticos.

Após a aplicação do modelo de previsão de integridade de tubulações utilizando a Rede Neural Artificial (RNA), obtivemos as previsões para cada tubulação do conjunto de dados. Os resultados das previsões refletem as classificações realizadas pela RNA para determinar se uma tubulação está íntegra ou não.

Ao analisar as previsões obtidas, não foram identificadas variações significativas em relação ao que foi observado durante a análise exploratória dos dados. Entretanto, ao examinarmos as previsões com base nos diferentes atributos das tubulações, notamos algumas tendências interessantes. Em relação ao material das tubulações, foi evidenciado um alto número de tubulações previstas como não íntegras para o material concreto armado. Por outro lado, os outros materiais apresentaram um desempenho melhor, com um maior número de tubulações previstas como íntegras. Esses resultados reforçam a importância do material na determinação da integridade das tubulações, com o concreto armado se destacando como um material que pode estar mais suscetível a problemas de integridade, conforme apresentado na Figura 8.

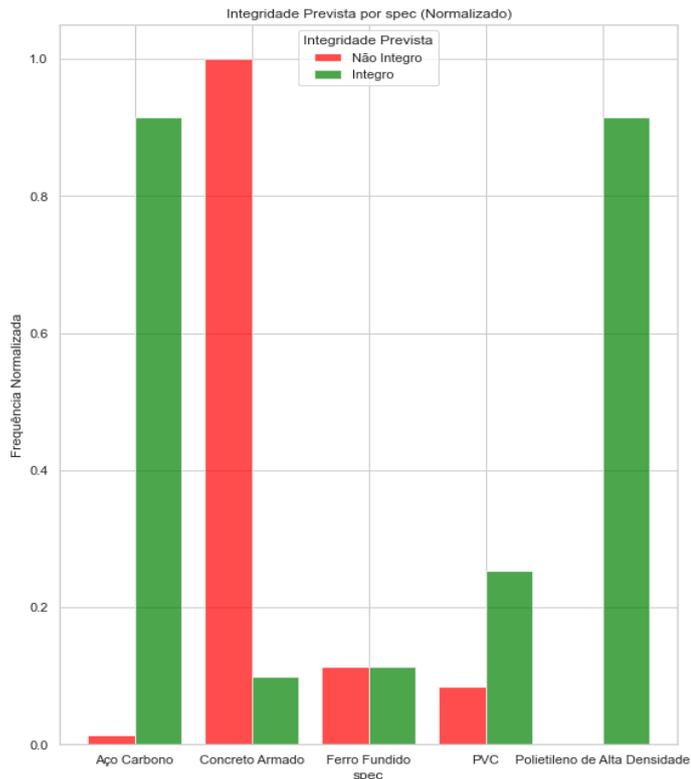
**Figura 8 – Relação entre o estado de integridade prevista e o material da tubulação (normalizado)**



Fonte: Autor (2023)

Além disso, foi observado que as previsões para as tubulações de drenagem oleosa indicaram um maior número de tubulações previstas como íntegras, conforme ilustrado na Figura 9. Esse padrão pode ser explicado pelo fato de que as tubulações de drenagem oleosa, geralmente feitas de PEAD, apresentam uma maior resistência à corrosão e uma menor quantidade de efluentes corrosivos. Por outro lado, para as tubulações de drenagem contaminada, que frequentemente são feitas de materiais como concreto armado, a previsão apontou para um maior número de tubulações não íntegras. Isso pode ser associado à natureza corrosiva da drenagem contaminada e à possível incompatibilidade do material com esses fluidos.

**Figura 9 – Relação entre o estado de integridade prevista e o tipo de fluido (normalizado)**



Fonte: Autor (2023)

Em resumo, as previsões realizadas pela RNA corroboram as tendências identificadas na análise exploratória dos dados, fornecendo uma validação adicional para os padrões observados. Esses resultados reforçam a eficácia do modelo desenvolvido para prever a integridade das tubulações, considerando diversos atributos como material e tipo de fluido.

A utilização da RNA como ferramenta de previsão demonstra seu potencial para auxiliar na manutenção e gestão de sistemas de tubulações industriais, contribuindo para a tomada de decisões mais informadas e eficazes. Essa abordagem proporciona um insight valioso para a identificação precoce de problemas de integridade, permitindo a implementação de ações preventivas e estratégias de manutenção com base em dados confiáveis e previsões precisas.

## 4 Considerações Finais

Neste estudo, foi abordada a avaliação da integridade das tubulações industriais por meio da aplicação de métodos de teste de estanquidade e vídeo inspeção, com o intuito de contribuir para a gestão eficaz desses sistemas críticos. A classificação das tubulações em "Integras" e "Não Integras" com base em procedimentos internos proporcionou uma base sólida para a análise subsequente.

A construção de uma Rede Neural Artificial (RNA) customizada, desenvolvida pelo autor deste artigo, demonstrou um compromisso em criar uma ferramenta precisa e adaptada às necessidades específicas da avaliação da integridade das tubulações de drenagem industrial. A configuração cuidadosa da RNA, incluindo a definição da arquitetura da rede, a implementação de técnicas de regularização L2 e a seleção de parâmetros, estabeleceram as bases para um modelo robusto e confiável.

A metodologia adotada, que emprega validação cruzada *Stratified K-Fold*, destacou-se como uma abordagem eficaz para avaliar o desempenho do modelo em um conjunto de dados desequilibrado. Essa técnica garantiu que a distribuição das classes "Integras" e "Não Integras" fosse mantida em cada etapa, evitando vieses na avaliação do modelo.

A análise exploratória dos dados permitiu a identificação de padrões e relações entre os atributos das tubulações e seu estado de integridade, enriquecendo a compreensão do problema. A escolha do Multi-Layer Perceptron (MLP) como arquitetura de RNA, juntamente com a seleção criteriosa dos parâmetros, consolidou a construção de um modelo capaz de capturar complexidades nos dados.

Os resultados obtidos comprovaram a eficácia do modelo, com uma acurácia média de teste variando entre aproximadamente 83,77% a 91,54%. A consistência entre diferentes *folds* demonstrou a robustez do modelo, indicando sua capacidade de generalização para diferentes subconjuntos de dados. A definição de limiares de underfitting e overfitting contribuiu para alcançar um equilíbrio entre simplicidade e complexidade do modelo.

As previsões geradas pela RNA corroboraram as tendências identificadas na análise exploratória dos dados, reforçando a importância do material das tubulações, do tipo de fluido e do diâmetro na determinação de sua integridade.

Portanto, a abordagem proposta neste estudo, que combina técnicas de inspeção física, análise exploratória de dados e modelagem com RNA, representa uma contribuição valiosa para a manutenção e gestão de sistemas de tubulações industriais. Esta pesquisa abre caminho para um gerenciamento mais eficaz e seguro das tubulações industriais, sobretudo em avaliar a condição de integridade com diferentes parâmetros envolvidos, contribuindo para a segurança e confiabilidade das operações industriais.

#### **4.1 Trabalhos Futuros**

Além disso, há oportunidades significativas para a expansão desta pesquisa em várias direções. Dois aspectos específicos que merecem destaque são a aplicação da metodologia RBI (Inspeção Baseada em Risco) no domínio do tempo e a exploração da modelagem de múltiplas classes.

No contexto do RBI, a incorporação de uma abordagem no domínio do tempo permitiria uma análise mais dinâmica e em tempo real da integridade das tubulações. Isso consideraria a evolução das condições ao longo do tempo, o que é essencial para a gestão de riscos em sistemas industriais.

Além disso, a expansão da modelagem para incluir múltiplas classes, refletindo diferentes graus de integridade ou tipos específicos de danos, proporcionaria uma visão mais granular da condição das tubulações e permitiria a implementação de estratégias de manutenção mais específicas.

Essas áreas de pesquisa representam caminhos promissores para avançar no campo da avaliação da integridade de tubulações industriais e contribuir ainda mais para a segurança e eficiência das operações industriais.

## REFERÊNCIAS

- KARDEC, A e LAFRAIA, J.R. (2009). **Gestão Estratégica e Confiabilidade**. Rio de Janeiro, Qualitymark, 2009
- Elsayed, E. A. **Reliability engineering**.1992 *Prentice Hall*.
- Fogliatto, F. S., & Da Silveira, G. J. C. **Administração da produção e operações: conceitos, modelos e exemplos**.2006 *Bookman Editora*.
- da I.N. Silva, Spatti D.H, Flauzino, R.A. **Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas. Fundamentos Teóricos e Práticos**.2020 *Artliber Editora*.
- Haykin, S. **Neural networks: A comprehensive foundation**.1999 *Prentice Hall*.
- Lafraia, J. R. S. **Aplicação da análise de sobrevivência ao estudo da confiabilidade do sistema de abastecimento de água de Curitiba**. 2001. Universidade Federal do Paraná.