



MINISTÉRIO DA EDUCAÇÃO
Universidade Federal de Ouro Preto
Instituto de Ciências Exatas e Aplicadas
Especialização em Ciência de Dados



Detecção de falhas em ativos críticos utilizando redes neurais artificiais

Flavio Hirotaka Mine

João Monlevade, MG
2024

Flavio Hirotaka Mine

Detecção de falhas em ativos críticos utilizando redes neurais artificiais

Trabalho de conclusão de curso apresentado ao curso de Ciência de Dados do Instituto de Ciências Exatas e Aplicadas da Universidade Federal de Ouro Preto, como parte dos requisitos necessários para a obtenção do título de Especialista em Ciência de Dados.

Orientador: Prof. Dr. Thiago Augusto de Oliveira Silva

João Monlevade, MG

2024

SISBIN - SISTEMA DE BIBLIOTECAS E INFORMAÇÃO

M664d Mine, Flavio Hirotaka.
Detecção de falhas em ativos críticos utilizando redes neurais artificiais. [manuscrito] / Flavio Hirotaka Mine. - 2024.
51 f.

Orientador: Prof. Dr. Thiago Augusto de Oliveira Silva.
Produção Científica (Especialização). Universidade Federal de Ouro Preto. Departamento de Engenharia de Produção.

1. Administração fabril. 2. Equipamentos industriais - Confiabilidade. 3. Falhas estruturais - Detecção. 4. Inteligência artificial. 5. Localização de falhas (Engenharia). 6. Redes neurais (Computação). I. Silva, Thiago Augusto de Oliveira. II. Universidade Federal de Ouro Preto. III. Título.

CDU 658.5:004.8

Bibliotecário(a) Responsável: Flavia Reis - CRB6-2431



FOLHA DE APROVAÇÃO

Flavio Hirotaka Mine

Deteção de Falhas em Ativos Críticos Utilizando Redes Neurais Artificiais

Trabalho de conclusão de curso apresentado ao curso de Especialização em Ciência de Dados da Universidade Federal de Ouro Preto como requisito parcial para obtenção do título de Especialista em Ciência de Dados

Aprovada em 26 de junho de 2024

Membros da banca

Dr. Thiago Augusto de Oliveira Silva - Orientador - Universidade Federal de Ouro Preto
Dra. Sarah Negreiros de Carvalho Leite - Instituto Tecnológico de Aeronáutica
Me. Leonardo Souza de Caux - Celulose Nipo Brasileira - CENIBRA

Thiago Augusto de Oliveira Silva, orientador do trabalho, aprovou a versão final e autorizou seu depósito na Biblioteca Digital de Trabalhos de Conclusão de Curso da UFOP em 29/07/2024



Documento assinado eletronicamente por **Thiago Augusto de Oliveira Silva, PROFESSOR DE MAGISTERIO SUPERIOR**, em 01/08/2024, às 17:17, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **0750939** e o código CRC **5673F094**.

Agradecimentos

Agradeço profundamente a Deus por todas as bênçãos e orientação constante em minha jornada.

À minha amada esposa, Elisângela, e aos nossos preciosos filhos, Arthur, Matheus e Gabrielle, expresso minha eterna gratidão pelo apoio inabalável e pelo amor incondicional que me sustentam diariamente.

Agradeço de coração aos meus pais, Massaharu e Neusa, e aos meus irmãos, Otávio e Márcio, pelo amor, apoio e incentivo inabaláveis ao longo desta jornada acadêmica.

Aos respeitados professores do curso de Especialização em Ciência de Dados, minha sincera apreciação pelo compartilhamento do conhecimento inspirador e pelos inestimáveis ensinamentos que moldaram meu percurso acadêmico e pessoal.

Ao meu orientador, o estimado Prof. Dr. Thiago Augusto de Oliveira Silva, manifesto minha profunda gratidão pela incansável orientação, dedicação e apoio que foram fundamentais para o desenvolvimento deste trabalho.

À CENIBRA, manifesto minha profunda gratidão pelo reconhecimento concedido e pela oportunidade de crescimento profissional que me foi oferecida. Em especial, gostaria de expressar meu sincero agradecimento ao Carlos Fernando Soares Fernandes pelo constante apoio e orientação ao longo desta jornada.

Aos meus colegas de sala, agradeço pela convivência enriquecedora, pela troca de experiências e pelo companheirismo que tornaram essa jornada ainda mais significativa e gratificante.

À banca examinadora, expresso meu mais sincero apreço pelo valioso tempo dedicado à avaliação do trabalho desenvolvido, reconhecendo a importância de suas contribuições para o aprimoramento deste estudo.

*"O futuro pertence àqueles que podem usar os dados
para tomar melhores decisões.- John Naisbitt*

Resumo

Este trabalho aborda os desafios enfrentados pelas indústrias modernas devido à constante ameaça de falhas em equipamentos complexos. A confiabilidade desses equipamentos é essencial para a competitividade e sustentabilidade das empresas, pois falhas inesperadas podem gerar custos elevados com reparos, paradas na produção e perda de qualidade. Nesse contexto, a previsão de falhas assume um papel crucial na mitigação desses riscos. O objetivo deste trabalho foi desenvolver modelos de classificação de falhas com antecedência utilizando técnicas avançadas de machine learning (ML), redes neurais recorrentes (RNR) do tipo LSTM. A metodologia envolveu a coleta de dados de sensores e dados de processos de um equipamento real de uma indústria de celulose. Esses dados foram pré-processados e utilizados para treinar e avaliar os modelos de LSTM para a classificação de falhas futuras. Como resultados do trabalho, foram obtidos 24 modelos que foram avaliados conforme as métricas de avaliação de desempenho, na qual obteve-se o melhor modelo com uma especificidade de 84,48% para uma previsibilidade de 96 horas de antecedência, indicando a viabilidade e o potencial dessa abordagem para a previsibilidade antecipada de falhas em equipamentos industriais. Este estudo ressalta a importância de antecipar falhas no contexto global competitivo, onde a eficiência operacional é crucial. Ao evidenciar a eficácia das técnicas de Machine Learning empregadas, o estudo demonstra como essas ferramentas podem não apenas prevenir falhas inesperadas, mas também promover uma gestão mais inteligente e sustentável dos recursos industriais.

Palavras-chaves: Detecção. Classificação de falhas. Equipamentos, LSTM.

Abstract

This work addresses the challenges faced by modern industries due to the constant threat of failures in complex equipment. The reliability of this equipment is essential for the competitiveness and sustainability of companies, as unexpected failures can result in high repair costs, production stoppages, and loss of quality. In this context, failure prediction plays a crucial role in mitigating these risks. The objective of this work was to develop failure classification models in advance using advanced machine learning (ML) techniques, specifically Long Short-Term Memory (LSTM) recurrent neural networks (RNNs). The methodology involved collecting sensor data and process data from real equipment in a pulp industry. These data were pre-processed and used to train and evaluate the LSTM models for future failure classification. As a result of the work, 24 models were obtained and evaluated according to performance evaluation metrics, with the best model achieving a specificity of 84.48% for a predictability of 96 hours in advance, indicating the feasibility and potential of this approach for early failure prediction in industrial equipment. This study highlights the importance of anticipating failures in the global competitive context, where operational efficiency is crucial. By demonstrating the effectiveness of the employed Machine Learning techniques, the study shows how these tools can not only prevent unexpected failures but also promote smarter and more sustainable management of industrial resources.

Keywords: Detection. Fault classification. Equipment, LSTM.

Lista de ilustrações

Figura 1 – Janelas de tempo.	4
Figura 2 – Soluções de uso de dados para manutenção preditiva.	5
Figura 3 – Etapas metodológicas.	6
Figura 4 – Etapas do processo <i>Kraft</i> de uma planta de celulose.	8
Figura 5 – Curva P-F.	11
Figura 6 – Quantidade de amostras.	12
Figura 7 – Estatística dos dados.	12
Figura 8 – <i>Heatmap</i> das variáveis.	13
Figura 9 – Histograma.	14
Figura 10 – Representação das funções <i>rolling</i> e <i>shift</i>	15
Figura 11 – Matriz de confusão.	20
Figura 12 – Representação da acurácia de cada modelo.	23
Figura 13 – Representação da acurácia de cada modelo.	25
Figura 14 – Melhores hiperparâmetros do Modelo V.	26
Figura 15 – Curva de desempenho do modelo V.	26
Figura 16 – Matriz de confusão do modelo V.	27
Figura 17 – Curva ROC do modelo V - Classe Normal.	28
Figura 18 – Curva ROC do modelo V - Classe Falha.	29
Figura 19 – Melhores hiperparâmetros do Modelo MLP.	31
Figura 20 – Curva de desempenho do modelo MLP.	31
Figura 21 – Matriz de confusão do modelo MLP.	32

Lista de tabelas

Tabela 1 – Configurações de janelas testadas.	16
Tabela 2 – Modelos obtidos com seus indicadores.	22
Tabela 3 – Métricas de desempenho calculadas para os modelos obtidos.	24
Tabela 4 – Quantidade de amostras das classes nas bases de treinamento e teste.	27
Tabela 5 – Modelo MLP obtido com seus indicadores.	30
Tabela 6 – Métricas de desempenho calculadas para o modelo MLP obtido.	31
Tabela 7 – Comparativo das métricas de desempenho dos Modelos LSTM e MLP.	32

Lista de quadros

Quadro 3.1 – Dados técnicos do equipamento crítico.	9
Quadro 3.2 – Dados das variáveis coletadas.	9
Quadro 3.3 – Configurações de janelas testadas.	15
Quadro 3.4 – Espaço de busca dos hiperparâmetros da rede LSTM.	18
Quadro 3.5 – Configurações do sintonizador.	18
Quadro 4.1 – Espaço de busca dos hiperparâmetros da rede MLP.	29

Lista de abreviaturas e siglas

IA Inteligência Artificial

LSTM *Long short-term memory*

ML *Machine Learning*

PIMS *Plant Information Management System*

RNA Redes Neurais Artificiais

RNR Redes Neurais Recorrentes

Sumário

1	INTRODUÇÃO	1
1.1	Objetivo geral	2
1.1.1	Objetivos específicos	2
1.2	Organização do Trabalho	2
2	REVISÃO DA LITERATURA	3
3	METODOLOGIA	6
3.1	Ambiente computacional e ferramentas	7
3.2	Compreensão do negócio	7
3.3	Compreensão dos dados	8
3.3.1	Identificação das variáveis	8
3.3.2	Coleta de dados	10
3.4	Preparação dos dados	10
3.4.1	Pré-processamento de dados	10
3.4.2	Estatística descritiva dos dados	12
3.4.3	Construção da base de dados	14
3.5	Modelagem	18
3.5.1	Seleção de algoritmos	18
3.5.2	Treinamento e teste	19
3.6	Avaliação	20
4	RESULTADOS	22
5	CONSIDERAÇÕES FINAIS	33
5.1	Trabalhos futuros	33
	REFERÊNCIAS	34

1 Introdução

As indústrias modernas utilizam máquinas e equipamentos complexos para garantir a operação de todo o sistema (CAO *et al.*, 2022), enfrentam desafios crescentes devido à complexidade desses equipamentos, exigindo altos padrões de segurança, confiabilidade e eficiência econômica (JIN *et al.*, 2023).

Para lidar com essa complexidade, práticas de manutenção preditiva têm se destacado. Essas práticas, definidas como ações para reduzir manutenções desnecessárias, utilizam técnicas de monitoramento de dados para identificar antecipadamente desvios e defeitos no processo e no equipamento (KARUPPIAH; SANKARANARAYANAN; ALI, 2021).

Essa abordagem é crucial para garantir a confiabilidade dos equipamentos e enfrentar as ameaças constantes de falhas nas indústrias modernas (JIN *et al.*, 2023).

Karuppiah, Sankaranarayanan e Ali (2021) destacam que uma estratégia de manutenção adequada não só evita falhas, mas também contribui significativamente para objetivos empresariais como redução de custos, qualidade do produto e entrega pontual.

Entretanto, falhas inesperadas em equipamentos, especialmente em processos de fabricação sequenciais e contínuos, podem ter impactos significativos em todas as áreas da empresa (CHUNG; PARK; KANG, 2023a). As consequências variam de acordo com a estrutura, sistema e equipamento envolvidos (GUMA; OZOEKWE; ODITA, 2020) mas são sempre custosas e podem prejudicar a capacidade produtiva, aumentar os custos operacionais e interferir nos serviços ao cliente (ARUNRAJ; MAITI, 2007).

De acordo com Gordon *et al.* (2020), interrupções no processo produtivo representam um custo anual significativo na indústria de manufatura, estimado em cerca de US\$ 50 bilhões. Por isso, a previsibilidade de falhas é essencial para evitar paradas não planejadas e reduzir custos de manutenção (MOHAMMED, 2023).

Recentemente, pesquisadores têm propostos diversos algoritmos e teorias eficazes para classificar, diagnosticar ou prever falhas usando dados de séries temporais industriais (CAO *et al.*, 2022).

Essa previsibilidade de falhas eleva a confiabilidade dos equipamentos e traz benefícios como minimização de paradas não planejadas, melhoria na eficiência operacional, redução de custos de manutenção, aumento da vida útil dos equipamentos, entre outros (DREYER, 1995).

Chung, Park e Kang (2023b) enfatizam que o objetivo da tarefa de classificação de falhas é determinar a possibilidade de falha futura de um equipamento alvo, enquanto a previsibilidade de tempo de falhas é estimar o tempo em que o equipamento irá falhar.

Essas melhorias não apenas contribuem para a sustentabilidade da empresa, mas também demonstram compromisso com eficiência, qualidade e inovação, além de fornecerem *insights* valiosos sobre o desempenho dos equipamentos e os fatores que contribuem para as falhas. Isso possibilita uma tomada de decisão mais precisa e assertiva, bem como uma melhoria considerável nas estratégias de manutenção.

1.1 Objetivo geral

O objetivo geral deste trabalho é desenvolver modelos capazes de prever e classificar falhas futuras em equipamentos utilizados no processo de produção de celulose da empresa Celulose Nipo-Brasileira SA, CENIBRA.

1.1.1 Objetivos específicos

Para cumprimento do objetivo geral é necessário atender aos seguintes objetivos específicos:

- Construir uma base de dados significativa, através das fontes de dados existentes.
- Gerar modelos baseados em [Redes Neurais Recorrentes \(RNR\)](#) do tipo *Long short-term memory (LSTM)*.
- Testar e comparar os diversos modelos gerados via *Machine Learning (ML)* para classificação de falha futura.

1.2 Organização do Trabalho

Este trabalho está organizado da seguinte maneira: no Capítulo 2 é apresentada a revisão da literatura com os principais conceitos aplicados e os trabalhos relacionados. O Capítulo 3 apresenta a metodologia de pesquisa utilizada. O Capítulo 4 apresenta os resultados obtidos. Por fim, o Capítulo 5 apresenta as considerações finais e trabalhos futuros.

2 Revisão da Literatura

A confiabilidade dos equipamentos é um aspecto crítico pois suas falhas podem levar a resultados catastróficos em diferentes níveis. Estimar e identificar falhas de forma confiável é uma estratégia fundamental de manutenção para melhorar a sua confiabilidade. Segundo [Mohammed \(2023\)](#), a previsão de falhas é um componente essencial dos métodos de manutenção industrial, visando evitar falhas nos equipamentos e reduzir paradas inesperadas nos processos, máquinas e equipamentos.

Além disso, a previsão de falhas desempenha um papel vital em indústrias, permitindo a extensão da vida útil dos componentes e a redução de falhas imprevistas nos equipamentos, evitando paradas custosas da planta e danos ao equipamento ([ARUNRAJ; MAITI, 2007](#)). A inatividade resultante de falhas nos equipamentos impacta a capacidade produtiva dos ativos físicos, reduzindo a produção, aumentando os custos operacionais e interferindo nos serviços ao cliente ([ARUNRAJ; MAITI, 2007](#)). Isso também afeta a capacidade de manter padrões de qualidade satisfatórios, tanto em termos de serviço quanto de produto ([ARUNRAJ; MAITI, 2007](#)).

Segundo [Mi et al. \(2021\)](#), existem duas abordagens principais para a classificação, diagnóstico e previsão de falhas em equipamentos: o método prévio, orientado por modelo e o método limitado, orientado a dados. O primeiro envolve a modelagem do processo de degradação do equipamento com base em dados históricos ou conhecimento prévio, enquanto o segundo utiliza indicadores limitados de desempenho operacional para mapear índices de estado de saúde do equipamento, como vida útil residual e nível de deterioração do sistema.

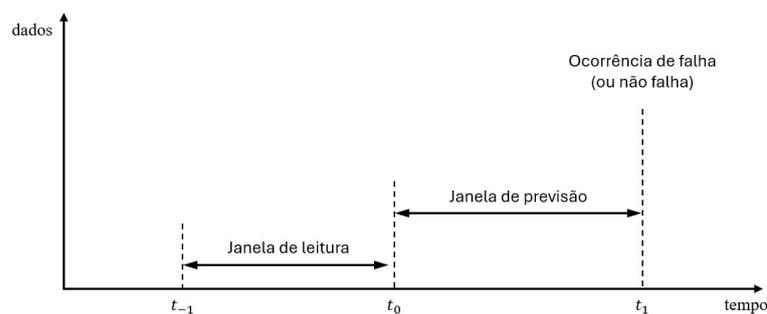
O crescente desenvolvimento de tecnologias de [Inteligência Artificial \(IA\)](#) tem possibilitado a ampla aplicação de métodos de previsibilidade de falhas em equipamentos ([LI; KRISTOFFERSEN; LI, 2022](#)). Os modelos de [ML](#) estão sendo cada vez mais utilizados na manutenção industrial para detecção antecipada de falhas de componentes, equipamentos e sistemas ([LEUKEL; GONZÁLEZ; RIEKERT, 2023](#)).

Um dos principais desafios da previsibilidade de falhas é a obtenção de dados suficientes, especialmente dados de diferentes tipos de falha, para treinar os modelos orientados a dados ([LI; KRISTOFFERSEN; LI, 2022](#)). A utilização desses modelos permite uma programação mais precisa das manutenções preventivas, minimizando as interrupções não planejadas nas operações e resultando em uma produção mais estável e menores custos de manutenção ([KAREEM; JEW, 2015](#)).

Conforme [Leukel, González e Riekert \(2023\)](#), os modelos de previsão de falhas na manutenção industrial podem ser considerados como tarefas de classificação, mapeando um estado futuro do sistema em classificações binárias ou multinomiais, onde as classes representam os tipos de falhas e não falhas. As classes de falhas representam condições anormais específicas do equipamento enquanto que a classe de não falha representa a condição normal.

Conforme [Leukel, González e Riekert \(2023\)](#), a abordagem para prever a ocorrência de falhas é feita com base na definição de dois intervalos de tempo, nomeadamente janela de previsão e janela de leitura, conforme Figura 1.

Figura 1 – Janelas de tempo.

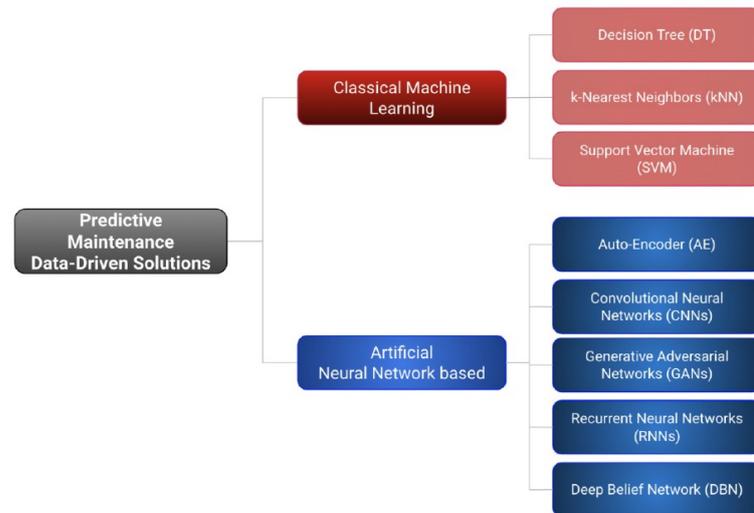


Fonte: [Leukel, González e Riekert \(2023\)](#).

A janela de previsão é definida como o tempo de antecedência em que a falha será prevista. A janela de leitura define o intervalo de tempo durante o qual os dados serão utilizados para fazer a previsão ([LEUKEL; GONZÁLEZ; RIEKERT, 2023](#)).

[Hurtado et al. \(2023\)](#) representa graficamente as soluções com uso de dados para detectar falhas futuras, conforme Figura 2.

Figura 2 – Soluções de uso de dados para manutenção preditiva.



Fonte: [Hurtado et al. \(2023\)](#).

As vantagens das técnicas baseadas em **ML** é a possibilidade de utilizar experiências passadas para encontrar padrões que identificam defeitos atuais e generalizá-los para dados novos. Apesar de objetivos diferentes, tanto o diagnóstico de falhas quanto o prognóstico de falhas utilizam os mesmos modelos básicos para obter suas previsões. Esses modelos básicos podem ser divididos em abordagens de **ML** clássico e **Redes Neurais Artificiais (RNA)** ([HURTADO et al., 2023](#)).

Uma vez que os equipamentos falhem ao longo do tempo, é realizado estudo do efeito das sequências de dados para prever a sua falha. Para tal, são utilizadas **RNR**. Podem ser utilizadas tanto para diagnóstico quanto para prognóstico de falhas ([HURTADO et al., 2023](#)).

[Khaldi et al. \(2023\)](#) complementa que os modelos de aprendizado de máquina mais usados para lidar com tarefas de previsão de séries temporais são as **RNR**.

[Lan Xiaosheng e Xu \(2024\)](#), [Lan et al. \(2022\)](#) e [Zhao, Sun e Jin \(2018\)](#) demonstram que a **LSTM** é amplamente utilizada na previsão e classificação de falhas devido à sua melhor capacidade de lidar com dados não lineares.

[Zhang et al. \(2023\)](#), [Han e Kim \(2023\)](#) e [Belagoune et al. \(2021\)](#) demonstraram o uso da rede **LSTM** com resultados satisfatórios para classificação e detecção de falhas em equipamentos.

3 Metodologia

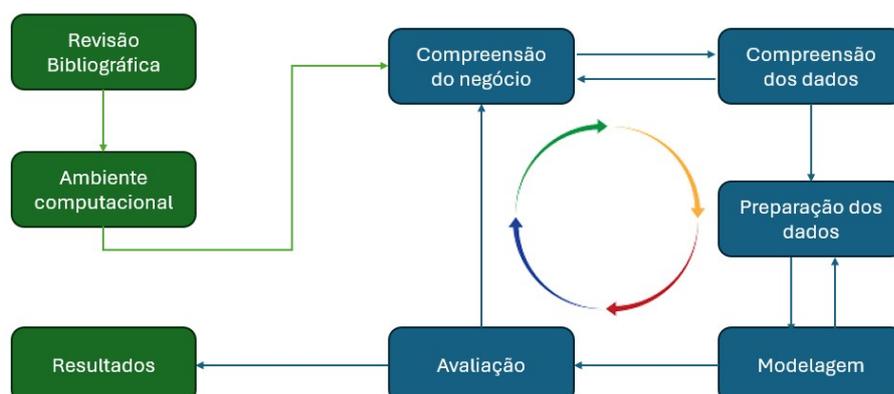
A abordagem de pesquisa adotada para investigar o problema em questão é do tipo quantitativa devido à natureza mensurável e objetiva dos fenômenos envolvidos. Como destacado por [Bertrand e Fransoo \(2002\)](#), a pesquisa quantitativa tem como pressuposto construir modelos que expliquem parte do comportamento de processos reais. Além disso, é importante ressaltar as relações entre causa e efeito.

A pesquisa pode ser classificada como empírica e normativa pois busca testar a validade de modelos científicos, ou em testar a usabilidade e o desempenho das soluções de problemas reais em processos reais ([BERTRAND; FRANSOO, 2002](#)). A partir dos dados coletados, serão realizadas observações sistemáticas com o objetivo de compreender e explicar as causas das falhas em equipamentos críticos. Buscar-se-á analisar e descrever a inter-relação entre diversas variáveis, como dados históricos e condições operacionais, visando classificar falhas em equipamentos industriais.

O foco é na descrição dos fenômenos e na criação de modelos explicativos através do método de pesquisa baseado em modelagem e simulação. A modelagem e simulação são usadas para projeto, controle, previsões de comportamento de sistemas, otimização de plantas ou análise de cenários ([RUIZ; PEREZ; GOMEZ, 2023](#)).

As próximas seções serão utilizadas para descrever o desenvolvimento das etapas metodológicas, conforme a Figura 3.

Figura 3 – Etapas metodológicas.



Fonte: Elaborado pelo autor.

3.1 Ambiente computacional e ferramentas

Os dados para o desenvolvimento deste trabalho foram obtidos através do Banco de Dados de um *Plant Information Management System (PIMS)* da CENIBRA, extraídos via Add-In para Microsoft Excel do Software ExaQuantum, versão 3.40.

O modelo de rede neural proposto foi desenvolvido na linguagem Python na versão 3.10.12, com a utilização dos pacotes Keras, Matplotlib, NumPy, Pandas, Scikit-learn, Seaborn, Statistics e Tensorflow, por meio do ambiente computacional Google Colab PRO, com 54,8 GB de memória RAM e GPU T4 NVIDIA-SMI 535.104.05 com 15,0 GB de memória, utilizando Notebook Jupyter, que é um aplicativo da web de código aberto (NAIK; NAIK; PATIL, 2021).

3.2 Compreensão do negócio

A Celulose Nipo Brasileira SA, CENIBRA, opera com uma unidade industrial no município de Belo Oriente (MG), com duas linhas de produção de celulose branqueada de fibra curta de eucalipto e capacidade instalada de 1.200.000 toneladas/ano.

E para produzir na capacidade instalada, os equipamentos devem operar com confiabilidade e com menor taxa de falhas.

Os equipamentos que estão diretamente ligados ao processo produtivo são classificados como equipamentos críticos.

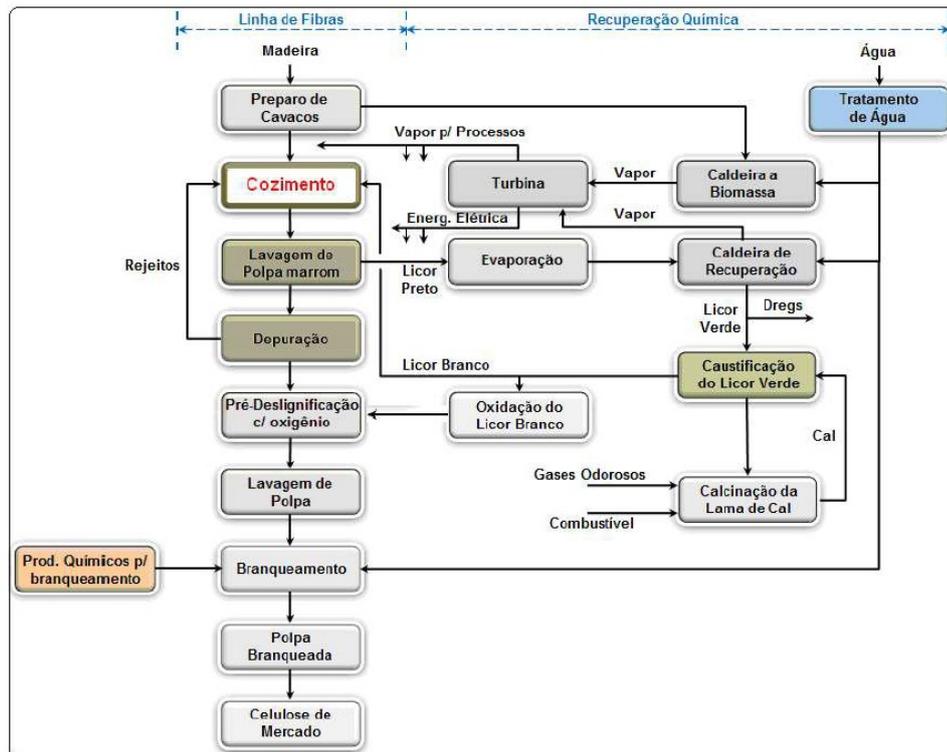
Baseado nas pesquisas realizadas, este trabalho se concentra na classificação de falha futura de um equipamento industrial. Para a escolha do equipamento foram utilizados os seguintes critérios:

- equipamento considerado como crítico para o processo;
- equipamento com histórico de falhas;
- equipamento com histórico de ocorrência de perdas de produção;
- disponibilidade e acesso aos dados.

O equipamento crítico escolhido para o desenvolvimento do trabalho foi a bomba de cavacos, identificado como 215BA30, pertencente ao processo de cozimento de uma planta de produção de celulose.

Na Figura 4 pode-se identificar o processo de cozimento dentro das etapas do processo *Kraft* de uma planta de celulose.

Figura 4 – Etapas do processo *Kraft* de uma planta de celulose.



Fonte: Correia (2016).

A função da bomba de cavacos é transportar a mistura de cavacos e licor ao digester para cozimento e processos seguintes: lavagem, deslignificação, depuração, branqueamento e secagem.

3.3 Compreensão dos dados

Na abordagem de diversos desafios no mundo real, é frequentemente notável que as variáveis pertinentes são dispersas, sugerindo que nem todas desempenham um papel significativo. Quando essas variáveis podem ser identificadas e removidas antes do processo de identificação, a complexidade do problema pode ser ainda mais reduzida (CHENG; BAI, 2019).

3.3.1 Identificação das variáveis

O Quadro 3.1 descreve os dados técnicos do equipamento, obtidos do documento interno nº: FE-215-27-0002-2601.

Quadro 3.1 – Dados técnicos do equipamento crítico.

Característica	Valor
Tag	215BA30
Tipo da bomba	centrífuga
Processo	cozimento
Aplicação	bomba de cavacos
Vazão (Q)	370.0 l/sec
Coluna de água (H)	35 m
Característica da curva	96-K5387a
Potência da bomba	220 kw
Eficiência	72 %
Rotação	910 rpm
Variador de velocidade	sim
NPSH requerido	4 m
Fabricante	Wemco
Tamanho da bomba	16"x 12"

Fonte: Elaborado pelo autor.

O Quadro 3.2 apresenta as variáveis, suas descrições, unidades e sua origem.

Quadro 3.2 – Dados das variáveis coletadas.

Item	Variável	Descrição	Unidade	Base de Dados
01	215AA62.PV	Relação licor/cavaco	-	Sistema PIMS
02	215BA30.FV	Corrente elétrica	A	Sistema PIMS
03	215FC60.PV	Fluxo de licor	m ³ /h	Sistema PIMS
04	215FC72.PV	Fluxo de licor calha cavacos	m ³ /h	Sistema PIMS
05	215LA05H.PV	Indicador de nível alto 215DT01	-	Sistema PIMS
06	215LC01.PV	Nível no silo de cavacos	%	Sistema PIMS
07	215LC04.PV	Nível de cavaco/licor	%	Sistema PIMS
08	215PC55.PV	Pressão no recalque bomba	kg/cm ²	Sistema PIMS
09	215PDI52.PV	Diferencial de pressão	kg/cm ²	Sistema PIMS
11	215PI72.PV	Pressão na calha de cavaco	mH ₂ O	Sistema PIMS
11	215SC02.PV	Velocidade rosca dosadora 215DO01	rpm	Sistema PIMS
12	215SC03.PV	Velocidade alimentador de alta	%	Sistema PIMS
13	215SI30.PV	Velocidade da bomba	rpm	Sistema PIMS
14	215TC47.PV	Temperatura do licor	°C	Sistema PIMS
15	215TI06.PV	Temperatura do licor	°C	Sistema PIMS
16	215TI51.PV	Temperatura do cavaco/licor	°C	Sistema PIMS
17	215VI02.PV	Vibração da bomba	mm/s	Sistema PIMS

Fonte: Elaborado pelo autor.

3.3.2 Coleta de dados

A obtenção de dados envolve predominantemente adquirir informações, rotular dados e aprimorar conjuntos de dados ou modelos já existentes (ROH; HEO; WHANG, 2021). Os dados utilizados na pesquisa foram coletados do banco de dados do Sistema ExaQuantum;

Todos os dados foram coletados e extraídos por meio do próprio sistema e contém registros de janeiro de 2023 a dezembro de 2023, com amostragem a cada minuto, totalizando 935.379 registros de cada variável e um total de 15.901.443 registros.

3.4 Preparação dos dados

3.4.1 Pré-processamento de dados

Os métodos de pré-processamento de dados incluem a limpeza de dados, integridade dos dados, transformação de dados e redução de dados (NAYAK; MISRA; BEHERA, 2014). Foram realizadas verificações de dados possibilitando identificar dados faltantes ou possíveis erros de medição de instrumentos.

Conforme Hakimi e Kamranrad (2017), a presença de *outliers* nos dados coletados leva a estimativas imprecisas dos parâmetros de regressão. Porém Singh e Upadhyaya (2012) refere-se ao uso de *outliers* para auxiliar na detecção de falhas em sistemas. Desta maneira, os *outliers* não foram excluídos.

Os dados referentes a períodos de parada de área foram expurgados. Além disso, foram geradas médias horárias das variáveis para composição dos dados para geração dos modelos. Após a geração das médias horárias das variáveis e aplicação dos filtros, obteve-se, para cada variável, 11.397 registros e um total de 193.749 registros.

De acordo com Nayak, Misra e Behera (2014), técnicas de normalização de dados também foram utilizadas com o objetivo de garantir a qualidade dos dados antes de serem alimentados nos algoritmos.

Os dados foram normalizados com o auxílio da função *MinMaxScaler*, padrão do *Scikit Learn*.

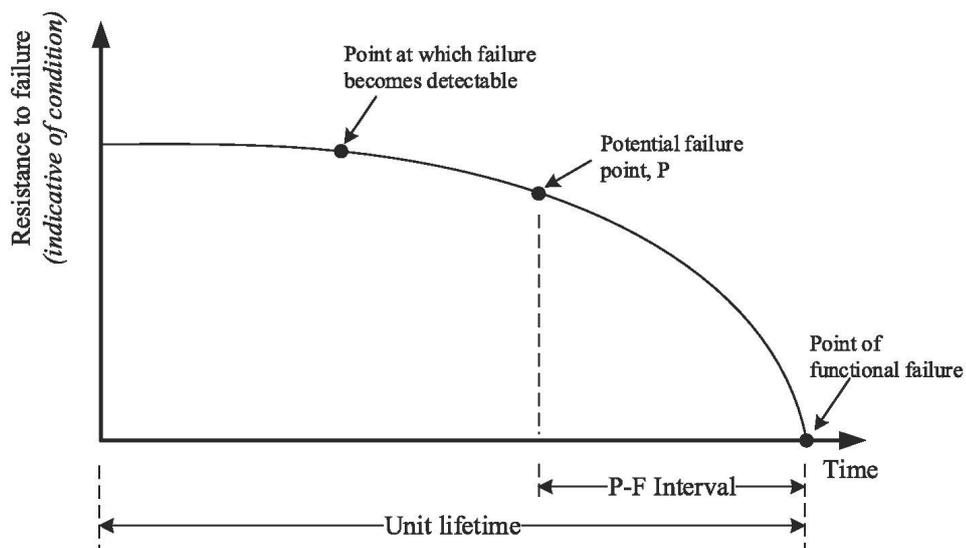
No período referente a coleta de dados foram registrados 3 ocorrências de falhas que geraram perdas de produção.

Devido a pequena quantidade de falhas do equipamento no período da coleta de dados, foram definidos indicadores de pré-aviso de falhas, baseado na *expertise* dos Engenheiros de Processo, para utilização no modelo para classificação de falhas.

Ochella, Shafiee e Sansom (2021) definem que pré-aviso da falha ou intervalo P-F, é qualquer alteração detectável e significativa de parâmetros de monitoramento da condição do equipamento, objetivo ou subjetivo, permitindo antever as ocorrências da falha com antecedência suficiente para que se tomem providências para minimizar suas consequências.

Intervalo P-F pode ser visualizado na curva P-F, conforme a Figura 5, que indica o ponto em que a falha de um equipamento que está sendo monitorado se torna detectável (OCHELLA; SHAFIEE; SANSOM, 2021).

Figura 5 – Curva P-F.



Fonte: Ochella, Shafiee e Sansom (2021).

Os pré-avisos de falhas foram utilizados para rotular os dados como classe 1 (falha) durante o treinamento do modelo. Dados fora dessas faixas de pré-aviso foram rotulados como classe 0 (sem falha), criando-se uma nova variável de saída denominada *status*.

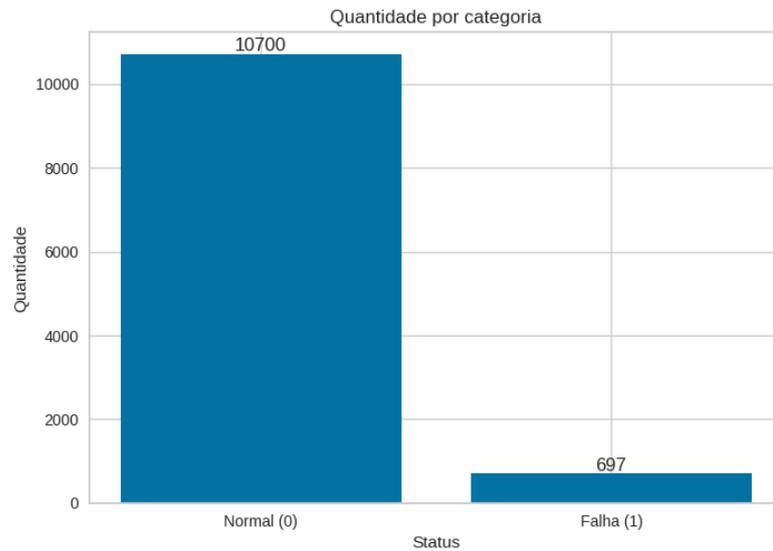
Os pré-avisos definidos foram:

- relação licor/cavaco (215AA62) menor que 2,5;
- temperatura licor (215TI06) maior que 102,5 °C;
- temperatura cavaco/licor (215TI51) menor que 96 °C;
- vibração na bomba (215VI02) maior que 20 mm/s;
- velocidade da bomba (215SI30) menor que 900 rpm e pressão de recalque da bomba (215PC55) maior que 2,5 kg/cm²;
- corrente elétrica do motor que aciona a bomba maior que 500 A.

Para qualquer uma das condições de pré-aviso de falhas definidas, se atribuiu o valor igual 1 à variável *status*, enquanto as condições contrárias atribuem o valor igual a 0.

Na Figura 6 pode-se observar a quantidade por categoria após a classificação dos pré-avisos como falhas:

Figura 6 – Quantidade de amostras.



Fonte: Elaborado pelo autor.

3.4.2 Estatística descritiva dos dados

Lin e Tsai (2017) mencionam que a análise de dados é essencial para o desempenho de tarefas de mineração de dados, com base no emprego de técnicas estatísticas, conforme Figura 7.

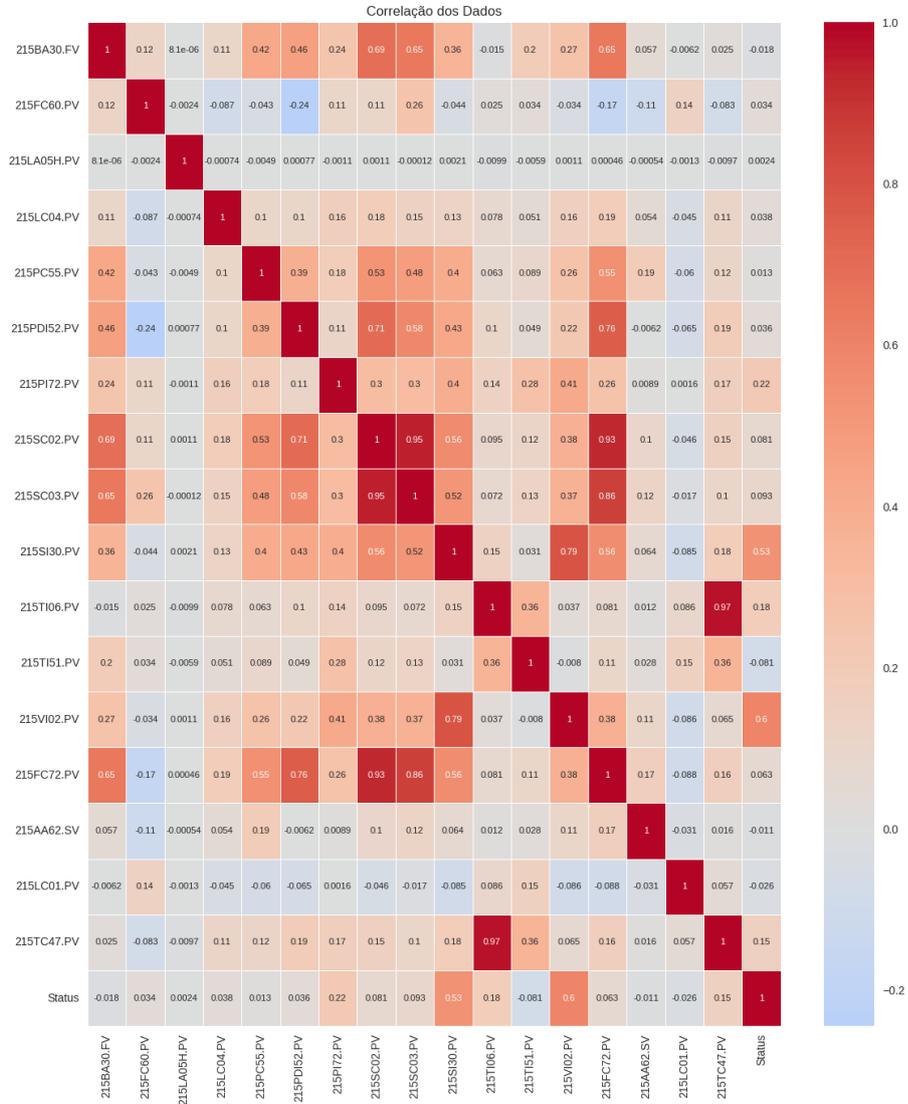
Figura 7 – Estatística dos dados.

	count	mean	std	min	25%	50%	75%	max
215BA30.FV	11397.0	431.756477	23.612192	357.525391	414.708252	432.846680	449.302979	512.354248
215FC60.PV	11397.0	90.544164	17.405732	48.382866	81.703133	93.367564	99.703627	133.313932
215LA05H.PV	11397.0	0.000042	0.001731	0.000000	0.000000	0.000000	0.000000	0.116667
215LC04.PV	11397.0	48.987334	1.707393	40.220488	48.022814	49.903062	50.027767	55.784657
215PC55.PV	11397.0	3.351191	0.087759	2.723157	3.300070	3.351732	3.401393	3.838875
215PDI52.PV	11397.0	0.243378	0.120184	-0.033258	0.164089	0.223241	0.289218	0.821099
215PI72.PV	11397.0	0.223062	0.250668	-0.037354	0.018168	0.195038	0.321583	1.721585
215SC02.PV	11397.0	41.467470	2.667085	35.004169	39.680074	42.046436	43.667213	46.078812
215SC03.PV	11397.0	21.738816	1.354171	17.543174	20.995085	22.103465	23.021779	23.742401
215SI30.PV	11397.0	849.125338	40.776177	724.578223	824.320779	844.145996	865.253540	1023.552277
215TI06.PV	11397.0	100.486785	0.859601	86.086608	100.015022	100.548348	101.040630	103.687111
215TI51.PV	11397.0	97.722931	0.455108	83.351078	97.454088	97.760581	98.022580	98.958812
215VI02.PV	11397.0	9.351059	6.538938	1.323326	4.847552	7.882633	12.319858	41.891037
215FC72.PV	11397.0	821.077391	60.986194	520.529907	780.317278	827.334620	864.721912	941.347777
215AA62.SV	11397.0	2.900561	0.013583	1.740000	2.900000	2.900000	2.900000	3.000000
215LC01.PV	11397.0	51.532347	12.739688	0.000148	44.765254	54.367071	60.395945	87.058977
215TC47.PV	11397.0	101.693972	0.849887	87.267596	101.248981	101.761081	102.216205	104.779330

Fonte: Elaborado pelo autor.

Após a coleta e pré-processamento dos dados, mapa de correlação entre as variáveis foi utilizado para visualizar correlações entre as variáveis, conforme Figura 8.

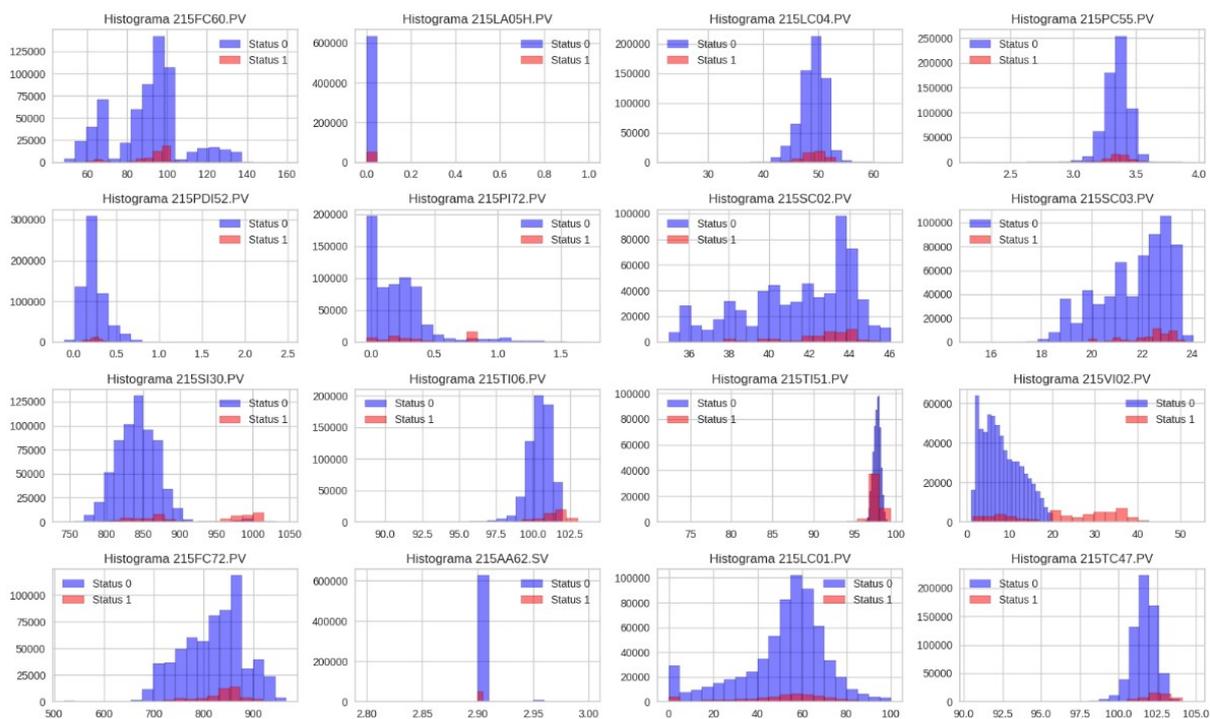
Figura 8 – Heatmap das variáveis.



Fonte: Elaborado pelo autor.

São analisadas as variáveis de dados quanto a sua distribuição e linearidade. Após a análise de correlações, foi utilizado histograma, conforme Figura 9 para visualização dos dados.

Figura 9 – Histograma.



Fonte: Elaborado pelo autor.

3.4.3 Construção da base de dados

López *et al.* (2013) demonstram que o treinamento para classificação a partir de um conjunto de dados com distribuições de classes desbalanceadas é um problema de desequilíbrio de classes.

O problema com conjuntos de dados desbalanceados é que os algoritmos de aprendizagem de classificação padrão tendem a ser tendenciosos em favor da classe majoritária, resultando em uma taxa de classificação incorreta mais alta para as instâncias da classe minoritária (LÓPEZ *et al.*, 2013).

Observa-se que a categoria de falha possui 697 registros, representando 6,11% do total de 11.397 dados.

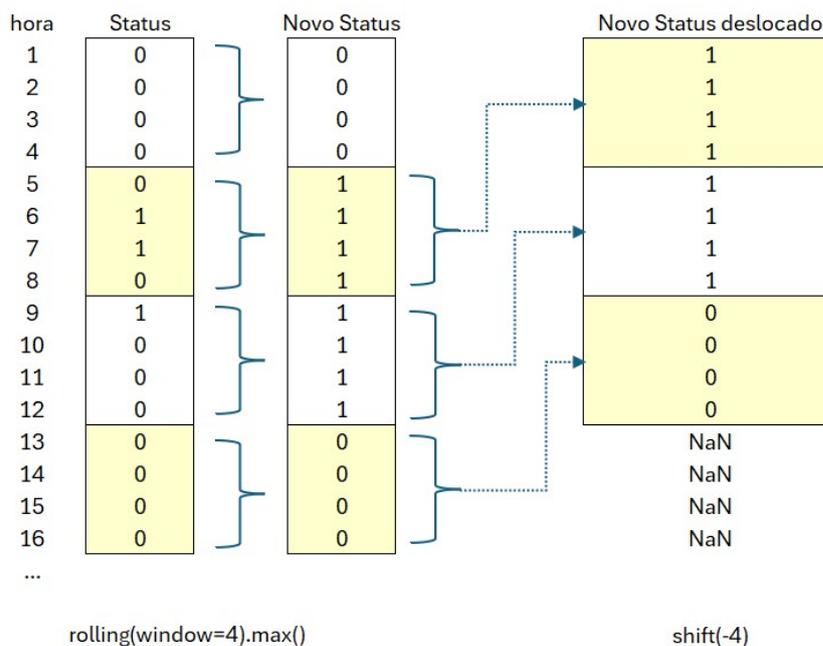
Para reduzir o desbalanceamento de classes, foi aplicada uma técnica de reconstrução dos dados utilizando janelas temporais. Para tal, utilizou-se as funções disponíveis na biblioteca Pandas, especificamente o *rolling* e o *shift*, para mover janelas de dados ao longo da série temporal.

A função *rolling* foi utilizada para identificar o registro de status de falha dentro de cada janela consecutiva. Dentro da janela definida de horas, a função *rolling* determina e retorna o valor máximo, representando a ocorrência de falha.

Além disso, a função *shift* foi aplicada para deslocar os dados de acordo com a janela estabelecida, criando uma nova variável de status. Essa nova variável é essencial para identificar tendências de mudança em relação aos demais dados do equipamento.

Na Figura 10 pode-se observar o resultado das funções *rolling* e *shift* para uma janela = 4 horas.

Figura 10 – Representação das funções *rolling* e *shift*.



Fonte: Elaborado pelo autor.

As configurações de janelas a serem utilizadas e testadas para geração dos modelos testados foram realizados variando a janela de previsão (futuro) e de leitura (passado), conforme o Quadro 3.3.

Quadro 3.3 – Configurações de janelas testadas.

Janela	Intervalo (horas)	Passo (horas)
Previsão	24 - 96	24
Leitura	1 - 6	1

Fonte: Elaborado pelo autor.

O intervalo de leitura definido entre 1 e 6 horas foi estabelecido com base na experiência dos Engenheiros de Processo. Eles mencionam que as alterações que ocorrem no processo além de 6 horas podem estar relacionadas a outras condições e mudanças no processo que não estão diretamente correlacionadas com problemas no equipamento.

O uso das funções *rolling* e o *shift* trouxeram melhor balanceamento dos dados. A Tabela 1 apresenta a distribuição das amostras, por categoria, após a aplicação das funções *rolling* e o *shift*, dentro do intervalo de janela de previsão definida no Quadro 3.3.

Tabela 1 – Configurações de janelas testadas.

Janela	Variável status	Categoria normal (0)	Categoria falha (1)
24	11.373	8.540	2.833
48	11.349	7.373	3.976
72	11.325	6.519	4.806
96	11.301	5.880	5.421

Fonte: Elaborado pelo autor.

Como a base de dados se trata de séries temporais, foi utilizado em sequência o Algoritmo 1 para criar subconjuntos deslizantes de dados históricos e alvos futuros para treinar e testar modelos de classificação de falhas futuras.

Abaixo a explicação do funcionamento do Algoritmo 1.

Inicia-se com a definição dos parâmetros de entrada a serem informados para o Algoritmo 1, sendo:

- *dataset*: o conjunto de dados de entrada do modelo;
- *target*: o conjunto de saída que o modelo irá classificar;
- *start*: índice inicial para a preparação dos dados;
- *end*: índice final para a preparação dos dados;
- *window*: tamanho da janela de previsão;
- *horizon*: horizonte de previsão, conforme janela de leitura.

E funciona da seguinte maneira:

- passo 1: inicializa as listas vazias X e y para armazenar os dados de entrada e saída, respectivamente;
- ajusta o valor da variável *start* considerando o tamanho da janela de previsão;
- define a variável *end* como a diferença entre o comprimento do dataset e o horizonte;
- itera sobre o intervalo entre *start* e *end*;
- nesta iteração, pada cada índice i , que representa a janela de previsão atual, e adiciona ao valor X ;

- cria um range *indicey* que representa o horizonte de previsão e adiciona ao valor de *y*;
- por fim, converge *X* e *y* em um array.

Abaixo o pseudocódigo do Algoritmo 1:

Algoritmo 1: Preparar dados para treinamento e teste

input : dataset, target, start, end, window, horizon
output : X, y

- 1 **início**
- 2 inicializa X = []
- 3 inicializa y = []
- 4 start = start + window
- 5 **se** end is None **então**
- 6 end = len(dataset) - horizon
- 7 **senão**
- 8 **fim**
- 9 **para** i in range(start,end) **faça**
- 10 indices = range(i+window,i)
- 11 X.append(dataset[indices])
- 12 indicey = range(i+1, i+1+horizon)
- 13 y.append(target[indicey])
- 14 **fim**
- 15 **retorna** np.array(X), np.array(y)

Para a geração dos dados de treinamento, os seguintes valores foram utilizados:

- start = 0 (iniciar a construção a partir do começo da base de dados).
- end = 70% (finalizar quando atingir 70% da base de dados).

Para a geração dos dados de teste, os seguintes valores foram utilizados:

- start = 70% (iniciar após 70% da base de dados).
- end = None (finalizar até final da base de dados).

Demais parâmetros do algoritmo:

- window = janela de leitura passada dos dados (intervalo de 1 até 6 horas).
- horizon = 1 (horizonte de saída igual a 1, baseado nas previsões (janelas) de tempo futuro, em horas, definidos conforme o Quadro 3.3.

Após os dados serem tratados conforme o Algoritmo 1, foram separados o conjunto, sendo 70% para treinamento e 30% para teste, utilizados para modelagem da rede neural recorrente do tipo LSTM.

3.5 Modelagem

3.5.1 Seleção de algoritmos

Para a classificação futura de falhas, foram utilizadas Redes Neurais Recorrentes do tipo LSTM, escolhidas com base na pesquisa exploratória científica. Os modelos foram desenvolvidos com as configurações apresentadas no Quadro 3.4.

Quadro 3.4 – Espaço de busca dos hiperparâmetros da rede LSTM.

Parâmetro	Valor	Passo (step)
Unidades de memória	10 a 1.000	50
Camadas ocultas	0 a 5	1
Unidades de memória das camadas ocultas	10 a 1.000	50
Camada de <i>dropout</i>	0.20	-
Funções de ativação	tanh, sigmoid, relu	-
Otimizador	adam	-
Taxa de aprendizagem	0.001	-
Função de perda	BinaryCrossentropy	-
Funções de ativação camada saída	sigmoid	-

Fonte: Elaborado pelo autor.

Foi utilizado o sintonizador *Hyperband* do *keras-tuner*, com as seguintes configurações, conforme demonstrado no Quadro 3.5.

Quadro 3.5 – Configurações do sintonizador.

Parâmetro	Valor
<i>objective</i>	<i>val_binary_accuracy</i>
<i>max_epochs</i>	300
fator	5
<i>hyperband_iterations</i>	2
<i>seed</i>	10811
<i>overwrite</i>	<i>True</i>
<i>max_consecutive_failed_trials</i>	5

Fonte: Elaborado pelo autor.

A função de perda utilizada para treinamento do modelo foi a *BinaryCrossentropy*. Conforme Ruby e Yendapalli (2020), é uma função de perda usada em tarefas de classificação binária

A função objetivo utilizada foi a *val_binary_accuracy* utilizada para avaliar a performance do modelo.

A acurácia binária varia entre 0 e 1. Para avaliação do modelo de classificação, foi utilizado o parâmetro *threshold*, com valor igual a 0,5. Isso significa que os valores de probabilidades acima de 0,5 serão classificados como 1 (falha) e valores abaixo ou iguais a 0,5 serão classificados como 0 (não falha).

A função *search* da biblioteca Keras Tuner, em conjunto das configurações dos hiperparâmetros demonstrados conforme no Quadro 3.4 e do sintonizador demonstrados no Quadro 3.5, realiza uma busca sistemática para encontrar a combinação ótima de hiperparâmetros que maximiza a precisão binária de validação do modelo LSTM. Isso é feito através de um processo iterativo que envolve a avaliação de múltiplas configurações de hiperparâmetros e a seleção da melhor rede com base no desempenho em um conjunto de dados de validação.

Para prevenir o *overfitting* e economizar tempo de treinamento, foi utilizado o método de parada denominada *earlystopping*, considerando o monitoramento pela métrica *val_binary_accuracy*, com tempo de espera em 10 épocas e definindo pela restauração dos pesos da melhor época observada na métrica monitorada.

O modelo LSTM é empregado para classificar falhas futuras do equipamento escolhido. Conforme Brahimi *et al.* (2024), a configuração LSTM facilita o gerenciamento eficaz da memória de curto e longo prazo por meio de seus sistemas de porta. Essas portas controlam o fluxo de informações na célula de memória, permitindo que a LSTM aprenda quais informações reter e quais descartar.

A configuração LSTM produz classificação futura de falha ou não falha do equipamento.

3.5.2 Treinamento e teste

A divisão de conjuntos de dados, em treinamento e teste, é uma prática considerada indispensável e altamente necessária para eliminar ou reduzir viés no treinamento de dados em modelos de ML (MURAINA, 2022). Porém, é desafiador obter uma estratégia de divisão dos conjuntos de dados em proporções que tragam resultados eficazes.

Classificação multiclases são comumente utilizados, porém, não existe um estudo comparativo sobre os efeitos do tamanho do conjunto de dados e das razões de divisão entre treinamento e teste (RACZ; BAJUSZ; HEBERGER, 2021).

É possível afirmar que o número de amostras e a razão de divisão dos conjuntos de treinamento e testes exercem efeito significativo no desempenho dos modelos obtidos (RACZ; BAJUSZ; HEBERGER, 2021). O conjunto de dados foi dividido, sendo 70% para treinamento e 30% para validação.

3.6 Avaliação

Para avaliação de desempenho dos modelos obtidos foi utilizada a matriz de confusão, demonstrada na Figura 11, com seus indicadores de desempenho, sendo elas: sensibilidade, especificidade, valor preditivo positivo, valor preditivo negativo e acurácia (OHSAKI *et al.*, 2017).

Figura 11 – Matriz de confusão.

		Classe Predita	
		Não Falha	Falha
Classe Atual	Não Falha	Verdadeiro Positivo (TP)	Falso Negativo (FN)
	Falha	Falso Positivo (FP)	Verdadeiro Negativo (TN)

Fonte: Elaborado pelo autor.

Foram utilizadas as métricas de desempenho de precisão (RPC) e Pontuação F1 (F1-score) (LUQUE *et al.*, 2019).

Conforme Valero-Carreras, Alcaraz e Landete (2023), as métricas utilizadas para avaliação são:

- A sensibilidade é a capacidade do modelo de classificar casos positivos. É calculado como a proporção entre as previsões verdadeiramente positivas e o conjunto de todas as previsões positivas.

$$SNS = \frac{TP}{TP + FN} \quad (3.1)$$

- A especificidade é a capacidade do modelo de classificar casos negativos. É a proporção entre as previsões verdadeiramente negativas e o conjunto de todas as previsões negativas.

$$SPC = \frac{TN}{TN + FP} \quad (3.2)$$

- A precisão é uma medida usada para avaliar as instâncias relevantes entre as instâncias recuperadas. É calculado como a proporção entre as previsões verdadeiramente positivas e o conjunto de todos os valores positivos reais.

$$PRC = \frac{TP}{TP + FP} \quad (3.3)$$

- A acurácia é a proporção de previsões corretas. Ele mede o quão bem um classificado prevê uma condição.

$$ACC = \frac{TP + TN}{TP + FN + TN + FP} \quad (3.4)$$

- O F1-Score é uma métrica que leva em conta a Precisão e a Sensibilidade da mesma forma.

$$FSC = 2 * \frac{PRC * SNS}{PRC + SNS} \quad (3.5)$$

- A Área sob a Curva (AUC) é uma medida usada para comparar diferentes classificadores. Essa estatística mede a área gerada pela curva ROC no espaço ROC. Os modelos que estão próximos do ponto (0,1) são melhores classificadores, uma vez que apresentam valores mais elevados de AUC.

[Galar et al. \(2012\)](#) enfatiza que, para avaliação de modelos de classificação com classes desbalanceadas, o gráfico ROC é uma maneira de combinar essas medidas e produzir um critério de avaliação. Complementa ainda que a área sob a curva ROC (AUC) corresponde à probabilidade de identificar corretamente as classes normal e falha. AUC fornece uma única medida do desempenho de um classificador para a avaliação de qual modelo é melhor em média.

No trabalho foi considerado a classe positiva como situação normal, sem falha e a classe negativa como falha.

4 Resultados

O trabalho foi desenvolvido a partir de um conjunto de dados de um equipamento real do processo de cozimento de uma planta de produção de celulose.

Os modelos das redes neurais artificiais foram desenvolvidas com base nas redes neurais recorrentes, especificamente utilizando o tipo **LSTM**, produzindo classificações futuras de falha ou não falha do equipamento, com antecedência de 48 horas.

Foram obtidos 1.440 modelos de **RNR LSTM**, identificando a melhor rede com base nas janelas testadas, conforme demonstrado no Quadro 3.3. Os resultados dos 24 melhores modelos gerados em cada cenário são apresentados na Tabela 2.

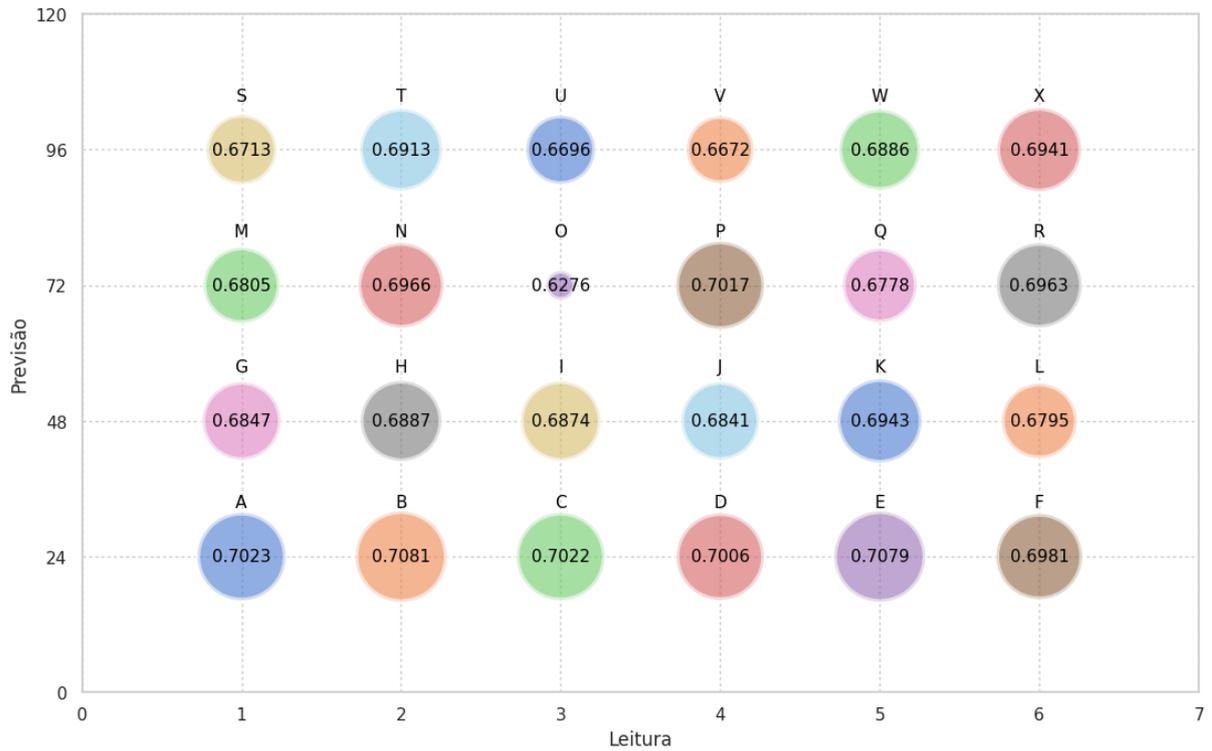
Tabela 2 – Modelos obtidos com seus indicadores.

Modelo	Previsão	Leitura	Loss	Binary_accuracy	Val_Loss	Val_binary_accuracy	Accuracy
A	24	1	0,4224	0,8395	0,5454	0,7267	0,7023
B	24	2	0,4948	0,8205	0,6297	0,6566	0,7081
C	24	3	0,4042	0,8568	0,6199	0,6518	0,7022
D	24	4	0,3949	0,8493	0,6579	0,6375	0,7006
E	24	5	0,4319	0,8545	0,6512	0,6414	0,7079
F	24	6	0,4939	0,8498	4,3294	0,5306	0,6981
G	48	1	0,5611	0,7628	0,6540	0,5500	0,6847
H	48	2	0,5641	0,7667	0,6649	0,5777	0,6887
I	48	3	0,5640	0,7676	0,6585	0,5990	0,6874
J	48	4	0,5330	0,7716	0,7261	0,6623	0,6841
K	48	5	0,5409	0,7683	0,8067	0,6470	0,6943
L	48	6	0,5227	0,7800	0,7177	0,6489	0,6795
M	72	1	0,6356	0,7010	0,6861	0,4453	0,6805
N	72	2	0,5755	0,7076	0,6035	0,6835	0,6966
O	72	3	0,5819	0,6955	0,6683	0,5657	0,6276
P	72	4	0,5470	0,7316	1,5240	0,5343	0,7017
Q	72	5	0,5785	0,7033	0,7904	0,6091	0,6778
R	72	6	0,5324	0,7174	3,1553	0,5597	0,6963
S	96	1	0,5578	0,7052	0,6889	0,6744	0,6713
T	96	2	0,6138	0,6543	0,6328	0,6357	0,6913
U	96	3	0,5989	0,6729	0,6392	0,6320	0,6696
V	96	4	0,6490	0,6137	0,6768	0,5218	0,6672
W	96	5	0,6280	0,6503	1,3001	0,6375	0,6886
X	96	6	0,6085	0,6619	0,6261	0,5453	0,6941

Fonte: Elaborado pelo autor.

A Figura 12 representa graficamente os dados dos modelos e os valores de leitura, previsão e acurácia, conforme demonstrados na Tabela 2.

Figura 12 – Representação da acurácia de cada modelo.



Fonte: Elaborado pelo autor.

Analisando pela métrica de acurácia, observa-se que os modelos apresentam valores na faixa entre 0,6275 a 0,7081.

Para uma melhor avaliação dos modelos, foram calculadas as métricas de desempenho para cada modelo obtido, apresentadas na Tabela 3.

Tabela 3 – Métricas de desempenho calculadas para os modelos obtidos.

Modelo	Previsão	Leitura	Precisão	Recall	F1-Score	Sensibilidade	Especificidade	Acurácia
A	24	1	0,4950	0,1482	0,2281	0,9362	0,1482	0,7023
B	24	2	0,5889	0,0524	0,0963	0,9846	0,0524	0,7081
C	24	3	0,4933	0,1822	0,2661	0,9212	0,1822	0,7022
D	24	4	0,4766	0,1110	0,1801	0,9487	0,1110	0,7006
E	24	5	0,7826	0,0179	0,0349	0,9979	0,0179	0,7079
F	24	6	0,4658	0,1420	0,2177	0,9316	0,1420	0,6981
G	48	1	0,6684	0,5873	0,6252	0,7637	0,5873	0,6847
H	48	2	0,6452	0,6770	0,6607	0,6982	0,6770	0,6887
I	48	3	0,6364	0,7037	0,6683	0,6743	0,7037	0,6874
J	48	4	0,6481	0,6430	0,6455	0,7174	0,6430	0,6841
K	48	5	0,6812	0,5947	0,6351	0,7749	0,5947	0,6943
L	48	6	0,6204	0,7294	0,6705	0,6392	0,7294	0,6795
M	72	1	0,7825	0,5801	0,6663	0,8031	0,5801	0,6805
N	72	2	0,7394	0,6919	0,7148	0,7024	0,6919	0,6966
O	72	3	0,7816	0,4472	0,5689	0,8476	0,4472	0,6276
P	72	4	0,7591	0,6695	0,7115	0,7410	0,6695	0,7017
Q	72	5	0,7689	0,5910	0,6683	0,7835	0,5910	0,6778
R	72	6	0,7173	0,7374	0,7272	0,6462	0,7374	0,6963
S	96	1	0,7017	0,8101	0,7520	0,4494	0,8101	0,6713
T	96	2	0,7896	0,6790	0,7301	0,7109	0,6790	0,6913
U	96	3	0,7015	0,8056	0,7499	0,4525	0,8056	0,6696
V	96	4	0,6863	0,8449	0,7574	0,3834	0,8449	0,6672
W	96	5	0,7541	0,7323	0,7431	0,6189	0,7323	0,6886
X	96	6	0,8123	0,6534	0,7242	0,7592	0,6534	0,6941

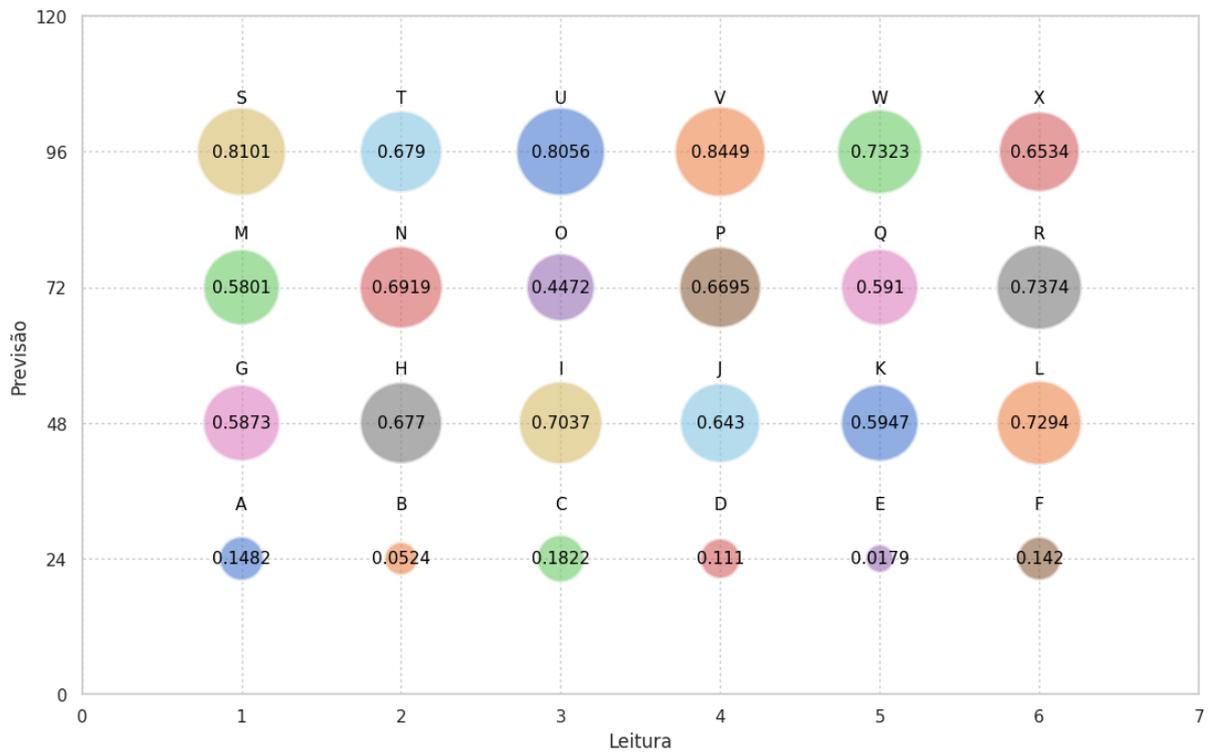
Fonte: Elaborado pelo autor.

Considerando o cenário industrial, é desejável basear na métrica de verdadeiro negativo (TN), que identifica corretamente a ocorrência de falha. No entanto, a métrica de falso negativo (FN) deve ser levada em consideração, pois embora indique um falso alerta, permite que a equipe operacional e de manutenção realize uma verificação preventiva no equipamento. O que não é desejado são os Falsos Positivos (FP), onde o modelo identifica uma situação normal, mas que, na realidade, é uma falha não detectada que pode comprometer a operação.

Assim sendo, a métrica de **especificidade** é a melhor métrica a ser considerada, uma vez que considera o impacto da quantidade de falsos positivos no cálculo desta métrica.

A Figura 13 representa graficamente os dados dos modelos, valores de leitura, previsão e a especificidade, conforme demonstrados na Tabela 3.

Figura 13 – Representação da acurácia de cada modelo.



Fonte: Elaborado pelo autor.

O modelo V é o melhor modelo obtido, com valor de especificidade igual a 0,8449 para uma janela de previsão de 96 horas de antecedência com uma janela de leitura de 4 horas.

A Figura 14 apresenta os melhores hiperparâmetros encontrados da melhor rede obtida através da busca exaustiva da função *search* da biblioteca *Keras Tuner*.

Figura 14 – Melhores hiperparâmetros do Modelo V.

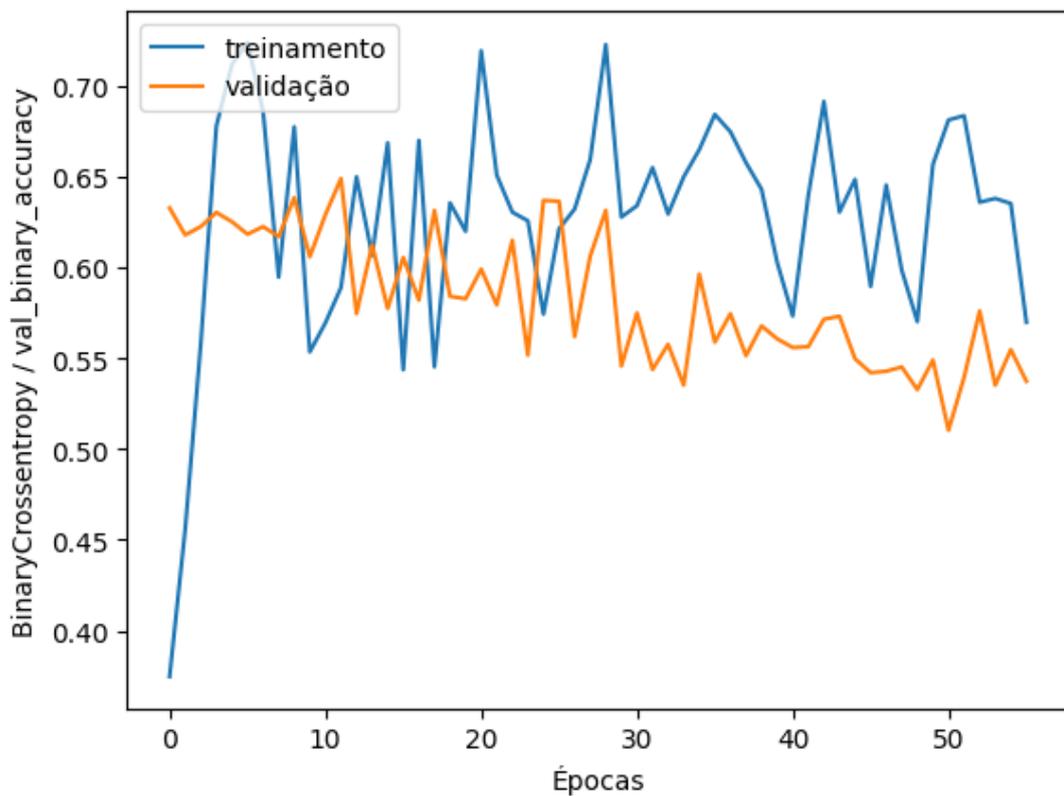
Layer (type)	Output Shape	Param #
lstm_0 (LSTM)	(None, 1, 410)	701,920
lstm_1 (LSTM)	(None, 1, 660)	2,827,440
lstm_2 (LSTM)	(None, 1, 310)	1,204,040
lstm_3 (LSTM)	(None, 1, 410)	1,182,440
lstm_4 (LSTM)	(None, 1, 610)	2,491,240
lstm_5 (LSTM)	(None, 1, 510)	2,286,840
dropout_1 (Dropout)	(None, 1, 510)	0
dense_1 (Dense)	(None, 1, 1)	511

Total params: 10,694,431 (40.80 MB)
 Trainable params: 10,694,431 (40.80 MB)
 Non-trainable params: 0 (0.00 B)

Fonte: Elaborado pelo autor.

A Figura 15 apresentada a curva de desempenho da rede baseado nas configurações obtidas.

Figura 15 – Curva de desempenho do modelo V.



Fonte: Elaborado pelo autor.

O modelo foi ajustado considerando 55 épocas e alcançou uma acurácia de validação em torno de 52%.

O modelo V foi obtido com janela de previsão de 96 horas e janela de leitura de 4 horas. Na Tabela 4 observa-se as amostras das categorias, nas bases de treinamento e teste, para melhor entendimento dos resultados da matriz de confusão.

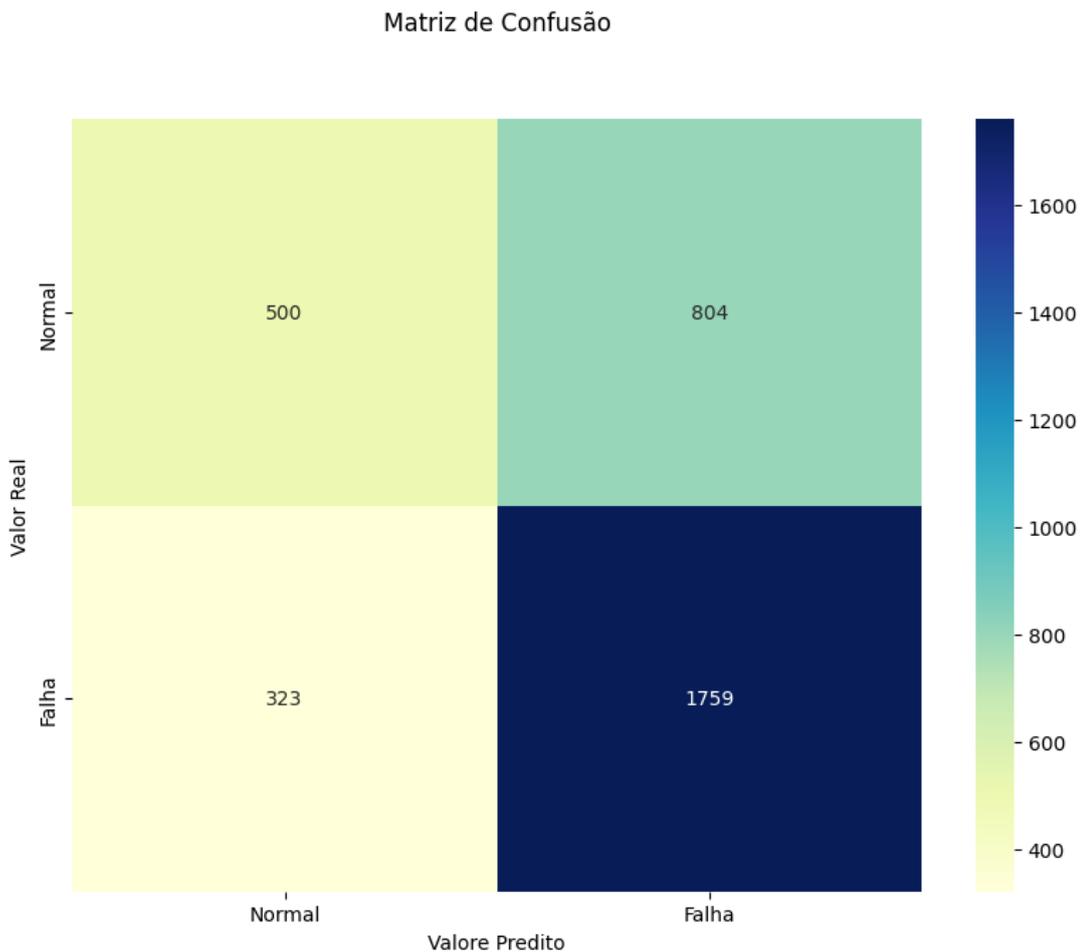
Tabela 4 – Quantidade de amostras das classes nas bases de treinamento e teste.

Modelo	Base	Total de amostras	Categoria Normal	Categoria Falha
V	Treinamento	7915	4576	3339
	Teste	3386	1304	2082

Fonte: Elaborado pelo autor.

A Figura 16 mostra a matriz de confusão para o melhor modelo obtido a partir dos dados de testes.

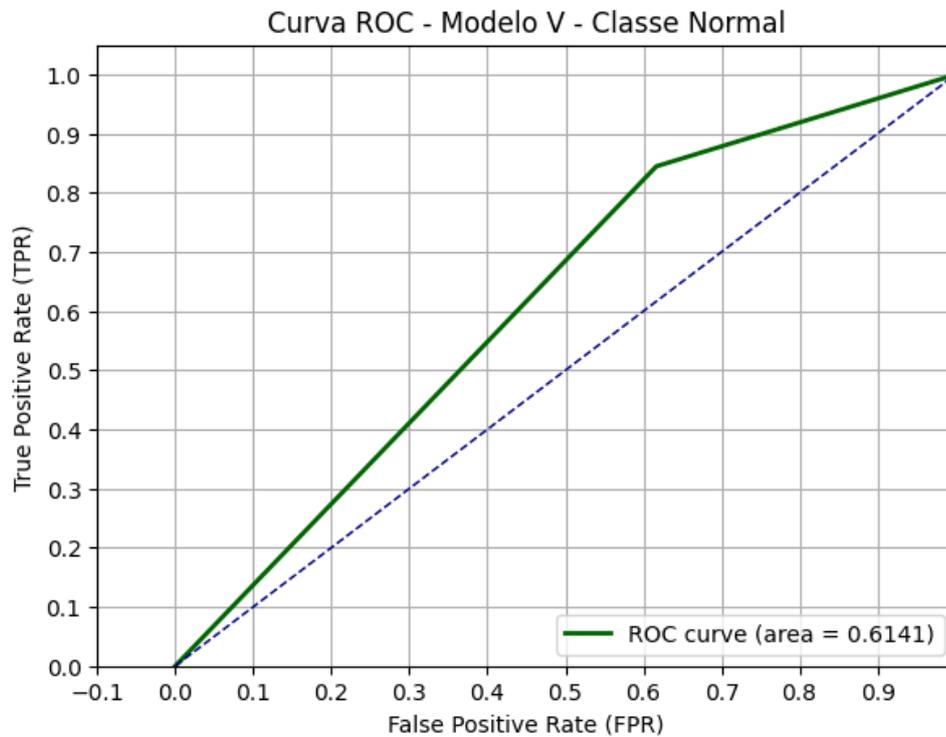
Figura 16 – Matriz de confusão do modelo V.



Fonte: Elaborado pelo autor.

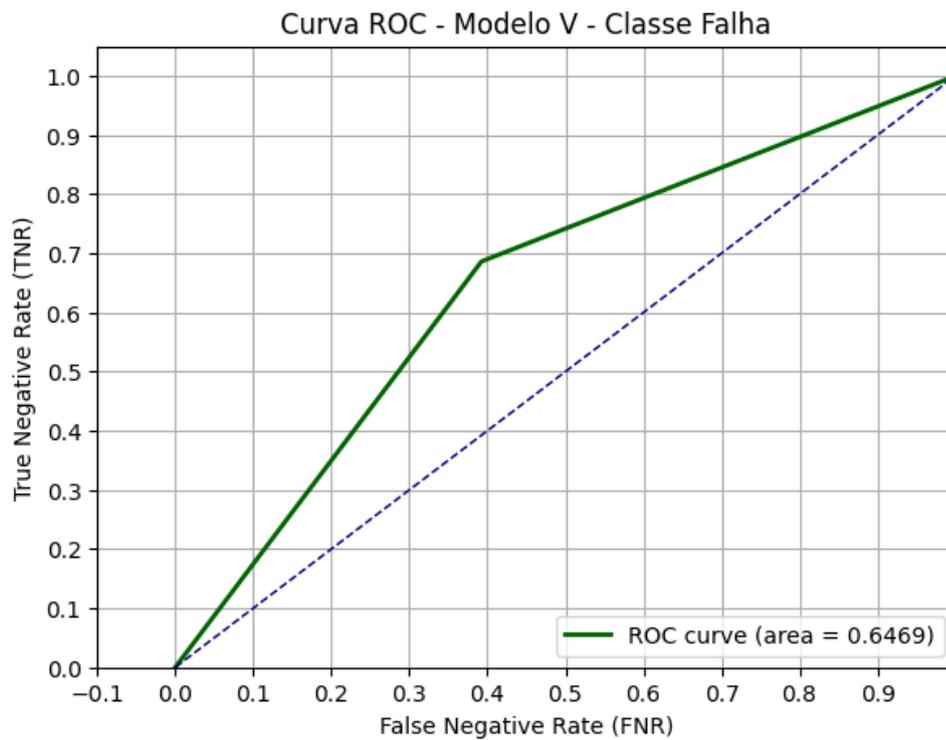
Nas Figuras 17 e 18 são apresentadas as Curvas ROC do modelo V para classe normal e falha, respectivamente.

Figura 17 – Curva ROC do modelo V - Classe Normal.



Fonte: Elaborado pelo autor.

Figura 18 – Curva ROC do modelo V - Classe Falha.



Fonte: Elaborado pelo autor.

Foi treinado uma rede do tipo MLP para comparação com o melhor modelo obtido do tipo LSTM.

Para o treinamento do modelo MLP, foi utilizados os hiperparâmetros conforme Quadro 4.1.

Quadro 4.1 – Espaço de busca dos hiperparâmetros da rede MLP.

Parâmetro	Valor	Passo (step)
Números de neurônio na camada de entrada	10 a 1.000	50
Camadas ocultas	0 a 5	1
Números de neurônio na camada oculta	10 a 1.000	50
Camada de <i>dropout</i>	0.20	-
Funções de ativação	tanh, sigmoid, relu	-
Otimizador	adam	-
Taxa de aprendizagem	0.001	-
Função de perda	BinaryCrossentropy	-
Funções de ativação camada saída	sigmoid	-

Fonte: Elaborado pelo autor.

Adicionalmente, os dados de treinamento e teste utilizadas para a rede MLP foram geradas aplicando as funções de *batch_size* e *shuffle*, disponíveis na biblioteca *tensorflow* e com a utilização do método *tf.data.Dataset.from_tensor_slices* (TUNG, 2021).

Foram definidos os valores dos parâmetros *batch_size* = 150 e *buffer_size* = 100.

O conjunto de treinamento foi gerado conforme apresentado no Algoritmo 2.

Algoritmo 2: Dataset para treinamento

input : x_train e y_train

output : tran_data

- 1 **início**
 - 2 cria um dataset a partir dos dados de entrada e rótulo
 - 3 armazena os dados em cache para acelerar o acesso
 - 4 embaralha os dados para garantir aleatoriedade
 - 5 agrupa os dados em lotes
 - 6 repete o dataset para suportar várias épocas de treinamento
 - 7 **retorna** train_data
-

O conjunto de teste foi gerado conforme o Algoritmo 3.

Algoritmo 3: Dataset para teste

input : x_test e y_test

output : test_data

- 1 **início**
 - 2 cria um dataset a partir dos dados de entrada e rótulo
 - 3 agrupa os dados em lotes
 - 4 **retorna** test_data
-

Na Tabela 5 é demonstrado o resultado do modelo MLP obtido.

Tabela 5 – Modelo MLP obtido com seus indicadores.

Modelo	Previsão	Leitura	Loss	Binary_accuracy	Val_Loss	Val_binary_accuracy	Accuracy
MLP	96	4	0,5042	0,8071	0,7568	0,5563	0,5422

Fonte: Elaborado pelo autor.

Métricas de desempenho para o modelo MLP obtido foram calculadas, conforme demonstrado na Tabela 6.

Tabela 6 – Métricas de desempenho calculadas para o modelo MLP obtido.

Modelo	Previsão	Leitura	Precisão	Recall	F1-Score	Sensibilidade	Especificidade	Acurácia
MLP	96	4	0,6350	0,5800	0,5000	0,7801	0,4940	0,5422

Fonte: Elaborado pelo autor.

A Figura 19 apresenta os melhores hiperparâmetros encontrados da melhor rede obtida através da busca exaustiva da função *search* da biblioteca *Keras Tuner*. Entretanto, o desempenho do modelo MLP mostrado na Figura 20 indica claramente que houve *overfitting*.

Figura 19 – Melhores hiperparâmetros do Modelo MLP.

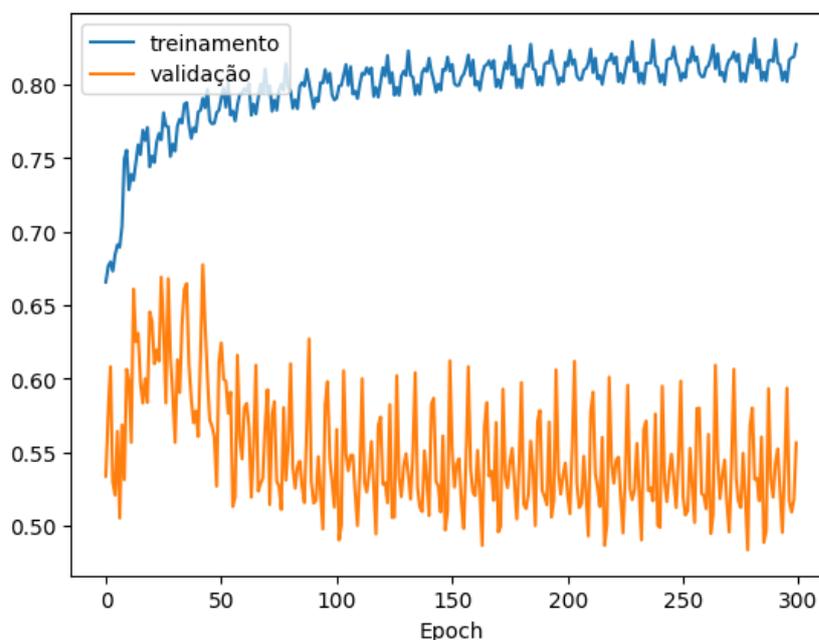
Layer (type)	Output Shape	Param #
dense (Dense)	(None, 1, 110)	1,980
dropout (Dropout)	(None, 1, 110)	0
dense_1 (Dense)	(None, 1, 1)	111

Total params: 2,091 (8.17 KB)
 Trainable params: 2,091 (8.17 KB)
 Non-trainable params: 0 (0.00 B)

Fonte: Elaborado pelo autor.

A Figura 20 apresentada a curva de desempenho da rede baseado nas configurações obtidas.

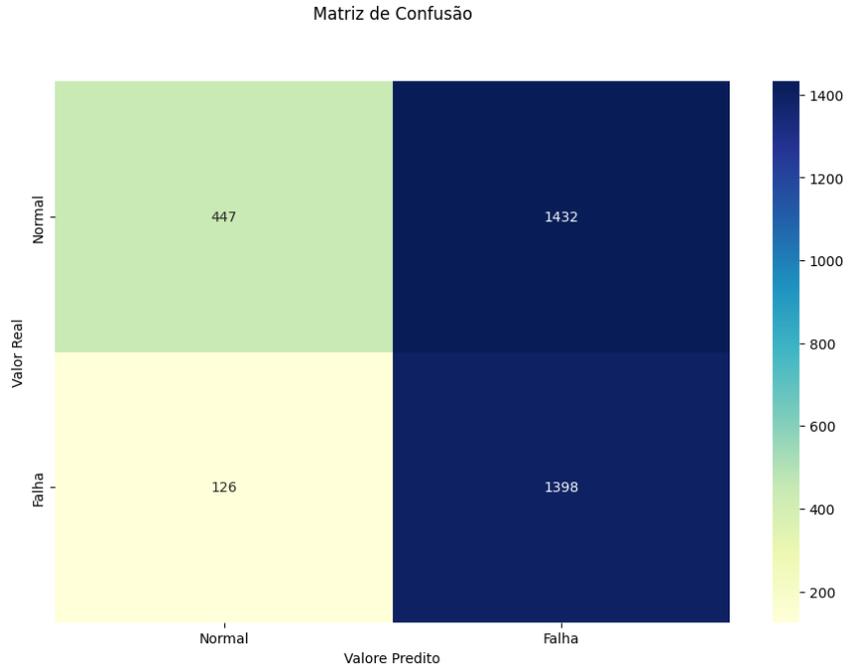
Figura 20 – Curva de desempenho do modelo MLP.



Fonte: Elaborado pelo autor.

A Figura 21 mostra a matriz de confusão para o modelo MLP obtido a partir dos dados de testes.

Figura 21 – Matriz de confusão do modelo MLP.



Fonte: Elaborado pelo autor.

A Tabela 6 apresenta o comparativo entre o melhor modelo LSTM obtido (modelo V) e o modelo MLP.

Tabela 7 – Comparativo das métricas de desempenho dos Modelos LSTM e MLP.

Modelo	V (LSTM)	MLP
Precisão	0,6863	0,6350
Recall	0,8449	0,5800
F1-Score	0,7574	0,5000
Sensibilidade	0,3834	0,7801
Especificidade	0,8449	0,4940
Acurácia	0,6672	0,5422

Fonte: Elaborado pelo autor.

Usando como métrica a especificidade, o Modelo V baseado na rede RNR tipo LSTM foi o que obteve melhor desempenho em comparação ao modelo MLP.

5 Considerações Finais

A bomba de cavacos desempenha um papel fundamental no processo de cozimento da celulose, sendo um ativo de extrema importância. No entanto, sua operação está sujeita a falhas, o que pode resultar em impactos significativos no processo produtivo. Portanto, a capacidade de prever essas falhas é essencial para minimizar tais impactos e otimizar o tempo de reparo.

Foi obtidos neste trabalho o modelo V com uma especificidade de 84,48% de classificação de previsão futura de falha com 96 horas de antecedência.

Essa previsibilidade oferece suporte significativo às equipes de operação e manutenção, permitindo que tomem medidas proativas para evitar falhas imprevistas na bomba de cavacos. Além disso, os benefícios são tangíveis: estima-se que a implementação desse modelo possa reduzir as perdas de produção em até 20%, equivalente a 500 toneladas de celulose, e redução de custos com recuperação de aproximadamente R\$ 150.000,00.

Os resultados deste estudo não apenas demonstram a eficácia da abordagem adotada na previsão de falhas da bomba de cavacos, mas também destacam seu potencial impacto positivo na eficiência operacional e financeira da planta de celulose.

5.1 Trabalhos futuros

Como sugestões de trabalhos futuros:

- Implementar o melhor modelo obtido no ambiente industrial da CENIBRA;
- Gerar modelos de outros equipamentos críticos, elevando a Manutenção Preditiva com a utilização de classificação futura de previsibilidade de falhas.
- Gerar modelos de predição de falhas em equipamentos.
- Gerar modelos que possam realizar a previsibilidade futura de classificação multiclasse baseado nos modos de falhas dos equipamentos e prescrever ações para eliminar ou mitigar suas falhas, elevando a maturidade da manutenção com implementação da estratégia de manutenção prescritiva.

Referências

- ARUNRAJ, N.; MAITI, J. Risk-based maintenance—techniques and applications. **Journal of Hazardous Materials**, v. 142, n. 3, p. 653–661, 2007. ISSN 0304-3894. Papers Presented at the 2005 Symposium of the Mary Kay O’Connor Process Safety Center. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0304389406007345>>. Acesso em: 29 nov. 2023.
- BELAGOUNE, S.; BALI, N.; BAKDI, A.; BAADJI, B.; ATIF, K. Deep learning through lstm classification and regression for transmission line fault detection, diagnosis and location in large-scale multi-machine power systems. **Measurement**, v. 177, p. 109330, 2021. ISSN 0263-2241. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0263224121003286>>. Acesso em: 21 mai. 2024.
- BERTRAND, J. W. M.; FRANSOO, J. C. Operations management research methodologies using quantitative modeling. **International Journal of Operations & Production Management**, MCB UP Ltd, v. 22, n. 2, p. 241–264, 2002. ISSN 0144-3577. Disponível em: <<https://doi.org/10.1108/01443570210414338>>. Acesso em: 13 nov. 2023.
- BRAHIMI, L.; HADROUG, N.; IRATNI, A.; HAFIFA, A.; COLAK, I. Advancing predictive maintenance for gas turbines: An intelligent monitoring approach with anfis, lstm, and reliability analysis. **Computers & Industrial Engineering**, v. 191, p. 110094, 2024. ISSN 0360-8352. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0360835224002158>>. Acesso em: 09 mai. 2024.
- CAO, J.; MA, J.; HUANG, D.; YU, P.; WANG, J.; ZHENG, K. Method to enhance deep learning fault diagnosis by generating adversarial samples. **Applied Soft Computing**, v. 116, p. 108385, 2022. ISSN 1568-4946. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1568494621011492>>. Acesso em: 15 dez. 2023.
- CHENG, C.; BAI, E.-W. Ranking the importance of variables in nonlinear system identification. **Automatica**, v. 103, p. 472–479, 2019. ISSN 0005-1098. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0005109819300834>>. Acesso em: 29 nov. 2023.
- CHUNG, E.; PARK, K.; KANG, P. Fault classification and timing prediction based on shipment inspection data and maintenance reports for semiconductor manufacturing equipment. **Computers & Industrial Engineering**, v. 176, p. 108972, 2023. ISSN 0360-8352. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0360835222009603>>. Acesso em: 27 nov. 2023.
- CHUNG, E.; PARK, K.; KANG, P. Fault classification and timing prediction based on shipment inspection data and maintenance reports for semiconductor manufacturing equipment. **Computers & Industrial Engineering**, v. 176, p. 108972, 2023. ISSN 0360-8352. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0360835222009603>>. Acesso em: 22 mai. 2024.
- CORREIA, F. M. **Métodos Estatísticos e Redes Neurais Aplicados a Modelos Preditivos em Digestor Contínuo de Celulose Kraft de Eucalipto**. Tese (Doutorado) — Universidade Estadual de Campinas, Faculdade de Engenharia Química, 2016. Acesso em: 22 abr. 2024.

DREYER, E. Cost-effective prevention of equipment failure in the mining industry. **International Journal of Pressure Vessels and Piping**, v. 61, n. 2, p. 329–347, 1995. ISSN 0308-0161. Failures '94 An International Symposium on Risk, Economy and Safety, Failure Minimisation and Analysis. Disponível em: <<https://www.sciencedirect.com/science/article/pii/030801619400114X>>. Acesso em: 15 dez. 2023.

GALAR, M.; FERNANDEZ, A.; BARRENECHEA, E.; BUSTINCE, H.; HERRERA, F. A review on ensembles for the class imbalance problem: Bagging-, boosting-, and hybrid-based approaches. **IEEE Transactions on Systems, Man and Cybernetics Part C: Applications and Reviews**, v. 42, n. 4, p. 463 – 484, 2012. Cited by: 2099. Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84862515469&doi=10.1109%2fTSMCC.2011.2161285&partnerID=40&md5=9551df7a9c6f631c55a381949c440bd6>>. Acesso em: 22 mai. 2024.

GORDON, C. A. K.; BURNAK, B.; ONEL, M.; PISTIKOPOULOS, E. N. Data-driven prescriptive maintenance: Failure prediction using ensemble support vector classification for optimal process and maintenance scheduling. **Industrial & Engineering Chemistry Research**, v. 59, n. 44, p. 19607–19622, 2020. Disponível em: <<https://doi.org/10.1021/acs.iecr.0c03241>>. Acesso em: 25 nov. 2023.

GUMA, T. N.; OZOEKWE, N. C. W.; ODITA, K. V. An overview of approaches and techniques used in failure analysis of engineering system. **Arid Zone Journal of Engineering, Technology and Environment**, v. 16, n. 3, p. 587–604, 2020. Disponível em: <<https://www.ajol.info/index.php/azojete/article/view/242657>>. Acesso em: 29 nov. 2023.

HAKIMI, A. A. A.; KAMRANRAD, R. Robust approaches for monitoring logistic regression profiles under outliers. **International Journal of Quality and Reliability Management**, v. 34, n. 4, p. 494–507, 2017. Disponível em: <<https://doi-org.ez28.periodicos.capes.gov.br/10.1108/IJQRM-04-2015-0053>>. Acesso em: 20 nov. 2023.

HAN, S.-R.; KIM, Y.-S. A fault identification method using lstm for a closed-loop distribution system protective relay. **International Journal of Electrical Power & Energy Systems**, v. 148, p. 108925, 2023. ISSN 0142-0615. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0142061522009218>>. Acesso em: 21 mai. 2024.

HURTADO, J.; SALVATI, D.; SEMOLA, R.; BOSIO, M.; LOMONACO, V. Continual learning for predictive maintenance: Overview and challenges. **Intelligent Systems with Applications**, v. 19, p. 200251, 2023. ISSN 2667-3053. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2667305323000765>>. Acesso em: 15 abr. 2024.

JIN, Y.; GENG, J.; LV, C.; CHI, Y.; ZHAO, T. A methodology for equipment condition simulation and maintenance threshold optimization oriented to the influence of multiple events. **Reliability Engineering & System Safety**, v. 229, p. 108879, 2023. ISSN 0951-8320. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0951832022004963>>. Acesso em: 02 dez. 2023.

KAREEM, B.; JEWOW, A. Development of a model for failure prediction on critical equipment in the petrochemical industry. **Engineering Failure Analysis**, v. 56, p. 338–347, 2015. ISSN 1350-6307. The Sixth International Conference on Engineering Failure Analysis. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1350630715000254>>. Acesso em: 15 dez. 2023.

- KARUPPIAH, K.; SANKARANARAYANAN, B.; ALI, S. M. On sustainable predictive maintenance: Exploration of key barriers using an integrated approach. **Sustainable Production and Consumption**, v. 27, p. 1537–1553, 2021. ISSN 2352-5509. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2352550921000968>>. Acesso em: 30 nov. 2023.
- KHALDI, R.; El Afia, A.; CHIHEB, R.; TABIK, S. What is the best rnn-cell structure to forecast each time series behavior? **Expert Systems with Applications**, v. 215, p. 119140, 2023. ISSN 0957-4174. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0957417422021583>>. Acesso em: 15 abr. 2024.
- LAN, X.; LI, Y.; SU, Y.; MENG, L.; KONG, X.; XU, T. Performance degradation prediction model of rolling bearing based on self-checking long short-term memory network. **Measurement Science and Technology**, IOP Publishing, v. 34, n. 1, p. 015016, oct 2022. Disponível em: <<https://dx.doi.org/10.1088/1361-6501/ac90dc>>. Acesso em: 15 abr. 2024.
- LAN XIAOSHENG E XU, T. Splstm: Um modelo de previsão de falhas operacionais em máquinas rotativas. **Diário de Sensores IEEE**, v. 24, p. 10447–10461, 2024. Disponível em: <<https://ieeexplore-ieee-org.ez28.periodicos.capes.gov.br/document/10430079>>. Acesso em: 15 abr. 2024.
- LEUKEL, J.; GONZÁLEZ, J.; RIEKERT, M. Machine learning-based failure prediction in industrial maintenance: improving performance by sliding window selection. **International Journal of Quality & Reliability Management**, v. 40, n. 6, p. 1449–1462, 2023. Disponível em: <<https://www-emerald.ez28.periodicos.capes.gov.br/insight/content/doi/10.1108/IJQRM-12-2021-0439/full/html>>. Acesso em: 08 abr. 2024.
- LI, Z.; KRISTOFFERSEN, E.; LI, J. Deep transfer learning for failure prediction across failure types. **Computers & Industrial Engineering**, v. 172, p. 108521, 2022. ISSN 0360-8352. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0360835222005344>>. Acesso em: 08 abr. 2024.
- LIN, S.-W. K. W.-C.; TSAI, C.-F. Top 10 data mining techniques in business applications: a brief survey. **Kybernetes**, v. 46, n. 7, p. 1158–1170, 2017. Disponível em: <<https://doi-org.ez28.periodicos.capes.gov.br/10.1108/K-10-2016-0302>>. Acesso em: 20 nov. 2023.
- LUQUE, A.; CARRASCO, A.; MARTÍN, A.; de las Heras, A. The impact of class imbalance in classification performance metrics based on the binary confusion matrix. **Pattern Recognition**, v. 91, p. 216–231, 2019. ISSN 0031-3203. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0031320319300950>>. Acesso em: 29 nov. 2023.
- LÓPEZ, V.; FERNÁNDEZ, A.; GARCÍA, S.; PALADE, V.; HERRERA, F. An insight into classification with imbalanced data: Empirical results and current trends on using data intrinsic characteristics. **Information Sciences**, v. 250, p. 113–141, 2013. ISSN 0020-0255. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0020025513005124>>. Acesso em: 22 mai. 2024.

MI, S.; FENG, Y.; ZHENG, H.; WANG, Y.; GAO, Y.; TAN, J. Prediction maintenance integrated decision-making approach supported by digital twin-driven cooperative awareness and interconnection framework. **Journal of Manufacturing Systems**, v. 58, p. 329–345, 2021. ISSN 0278-6125. Digital Twin towards Smart Manufacturing and Industry 4.0. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0278612520301345>>. Acesso em: 30 nov. 2023.

MOHAMMED, A. Data driven-based model for predicting pump failures in the oil and gas industry. **Engineering Failure Analysis**, v. 145, p. 107019, 2023. ISSN 1350-6307. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1350630722009864>>. Acesso em: 22 nov. 2023.

MURAINA, I. Ideal dataset splitting ratios in machine learning algorithms: general concerns for data scientists and data analysts. **Molecules**, v. 26, n. 4, p. 1111, 2022. Disponível em: <<https://www.researchgate.net/publication/358284895>>. Acesso em: 22 nov. 2023.

NAIK, P.; NAIK, G.; PATIL, M. **Conceptualizing Python in Google COLAB**. Chhattisgarh: India: Shashwat Publication, 2021. 329 p. ISBN 9789393557438.

NAYAK, S.; MISRA, B. B.; BEHERA, H. S. Impact of data normalization on stock index forecasting. **International Journal of Computer Information Systems and Industrial Management Applications**, v. 6, n. 2014, p. 257–269, 2014. Disponível em: <http://www.mirlabs.org/ijcisim/regular_papers_2014/IJCISIM_24.pdf>. Acesso em: 27 nov. 2023.

OHELLA, S.; SHAFIEE, M.; SANSOM, C. Adopting machine learning and condition monitoring p-f curves in determining and prioritizing high-value assets for life extension. **Expert Systems with Applications**, v. 176, p. 114897, 2021. ISSN 0957-4174. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0957417421003389>>. Acesso em: 23 abr. 2024.

OHSAKI, M.; WANG, P.; MATSUDA, K.; KATAGIRI, S.; WATANABE, H.; RALESCU, A. Confusion-matrix-based kernel logistic regression for imbalanced data classification. **IEEE Transactions on Knowledge and Data Engineering**, v. 29, n. 9, p. 1806–1819, 2017. Disponível em: <<https://doi.org/10.1108/01443570210414338>>. Acesso em: 13 nov. 2023.

RACZ, A.; BAJUSZ, D.; HEBERGER, K. Effect of dataset size and train/test split ratios in qsar/qspr multiclass classification. **Molecules**, v. 26, n. 4, p. 1111, 2021. Disponível em: <<https://www.mdpi.com/1420-3049/26/4/1111>>. Acesso em: 22 nov. 2023.

ROH, Y.; HEO, G.; WHANG, S. E. A survey on data collection for machine learning: A big data - ai integration perspective. **IEEE Transactions on Knowledge and Data Engineering**, v. 33, n. 4, p. 1328–1347, 2021. Disponível em: <<https://ieeexplore.ieee.org/abstract/document/8862913>>. Acesso em: 27 nov. 2023.

RUBY, U.; YENDAPALLI, V. Binary cross entropy with deep learning technique for image classification. **Int. J. Adv. Trends Comput. Sci. Eng**, v. 9, n. 10, 2020. Disponível em: <<http://www.warse.org/IJATCSE/static/pdf/file/ijatcse175942020.pdf>>. Acesso em: 27 mai. 2024.

- RUIZ, L. M.; PEREZ, J. I.; GOMEZ, M. A. Practical review of modelling and simulation applications at full-scale wastewater treatment plants. **Journal of Water Process Engineering**, v. 56, p. 104477, 2023. ISSN 2214-7144. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2214714423009972>>. Acesso em: 02 dez. 2023.
- SINGH, K.; UPADHYAYA, S. Outlier detection: applications and techniques. **International Journal of Computer Science Issues (IJCSI)**, Citeseer, v. 9, n. 1, p. 307, 2012. Disponível em: <<https://citeseerx.ist.psu.edu/document?repid=rep1&type=pdf&doi=4f5844c9e7db68af7c2c5b918082636c3307cef9>>. Acesso em: 27 nov. 2023.
- TUNG, K. **TensorFlow 2 Pocket Reference**. [S.l.]: O'Reilly Media, 2021.
- VALERO-CARRERAS, D.; ALCARAZ, J.; LANDETE, M. Comparing two svm models through different metrics based on the confusion matrix. **Computers & Operations Research**, v. 152, p. 106131, 2023. ISSN 0305-0548. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0305054822003616>>. Acesso em: 09 mai. 2024.
- ZHANG, J.; CHEN, Y.; LI, N.; ZHAI, J.; HAN, Q.; HOU, Z. A weak fault identification method of micro-turbine blade based on sound pressure signal with lstm networks. **Aerospace Science and Technology**, v. 136, p. 108226, 2023. ISSN 1270-9638. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1270963823001232>>. Acesso em: 21 mai. 2024.
- ZHAO, H.; SUN, S.; JIN, B. Sequential fault diagnosis based on lstm neural network. **IEEE Access**, v. 6, p. 12929–12939, 2018. Disponível em: <<https://ieeexplore-ieee-org.ez28.periodicos.capes.gov.br/document/8272354>>. Acesso em: 15 abr. 2024.