



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



Predição do nível de vibração máximo de um redutor mecânico em uma janela de tempo futura

Heitor André Nunes

João Monlevade, MG
2024

Heitor André Nunes

**Predição do nível de vibração máximo de um redutor
mecânico em uma janela de tempo futura**

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. Paganini Barcellos de Oliveira
Coorientador: Prof. Dr. Thiago Augusto de Oliveira Silva

João Monlevade, MG

2024

SISBIN - SISTEMA DE BIBLIOTECAS E INFORMAÇÃO

N972p Nunes, Heitor André.

Predição do nível de vibração máximo de um redutor mecânico em uma janela de tempo futura. [manuscrito] / Heitor André Nunes. - 2024. 34 f.

Orientador: Prof. Dr. Paganini Barcellos de Oliveira.

Coorientador: Prof. Dr. Thiago Augusto de Oliveira Silva.

Produção Científica (Especialização). Universidade Federal de Ouro Preto. Departamento de Engenharia de Produção.

1. Previsão (Estatística). 2. Redes neurais (Computação). 3. Vibração - Medição. I. Oliveira, Paganini Barcellos de. II. Silva, Thiago Augusto de Oliveira. III. Universidade Federal de Ouro Preto. IV. Título.

CDU 519.2:004.8

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



FOLHA DE APROVAÇÃO

Heitor André Nunes

Predição do nível de vibração máximo de um redutor mecânico em uma janela de tempo futura

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

Aprovada em 05 de junho de 2024

Membros da banca

Doutor - Paganini Barcellos de Oliveira - Orientador - Universidade Federal de Ouro Preto
Doutor - Thiago Augusto de Oliveira Silva - Coorientador - Universidade Federal de Ouro Preto
Doutor - Carlos Henrique Gomes Ferreira - Universidade Federal de Ouro Preto
Mestre - Geraldo Magela Pereira Filho - CENIBRA (Celulose Nipo-Brasileira S.A.)

Paganini Barcellos de Oliveira, orientador do trabalho, aprovou a versão final e autorizou seu depósito na Biblioteca Digital de Trabalhos de Conclusão de Curso da UFOP em 24/06/2024



Documento assinado eletronicamente por **Paganini Barcellos de Oliveira, PROFESSOR DE MAGISTERIO SUPERIOR**, em 24/06/2024, às 12:47, 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 **0720453** e o código CRC **C8A1A8FB**.

Resumo

Este trabalho teve como objetivo a proposição de uma rede neural recorrente do tipo *Long Short-Term Memory* (LSTM) para a predição do valor máximo de vibração de um equipamento, em uma janela de tempo futura. Os dados utilizados neste trabalho correspondem aos níveis de vibração de um redutor mecânico de velocidade pertencente a uma empresa produtora de celulose. As funções *Rolling* e *Shift* da biblioteca Pandas foram utilizadas para o deslocamento da base de dados para um janela temporal em horas. Como métrica para avaliação e comparação do desempenho das diferentes configurações redes neurais LSTM testadas, utilizou-se o cálculo dos erros absoluto médio e quadrático médio. Como resultado, a configuração de rede LSTM que apresentou o melhor desempenho no processo de validação obteve um erro absoluto médio de 0,00409 e um erro quadrático médio de 0,00074, considerando uma janela temporal de 16 horas e que considera os 18 dados de nível global de vibração anteriores.

Palavras-chaves: Redutor mecânico. Rede neural LSTM. Predição.

Abstract

This study proposes a Long Short-Term Memory (LSTM) recurrent neural network for predicting the maximum vibration value of equipment in a future time window. The data used in this study correspond to the vibration levels of a mechanical speed reducer belonging to a cellulose production company. The Rolling and Shift functions of the Pandas library were used to shift the database to a temporal window in hours. As a metric for evaluating and comparing the performance of the different LSTM neural network configurations tested, the calculation of the mean absolute error and mean squared error was used. As a result, the LSTM network configuration that showed the best performance in the validation process achieved a mean absolute error of 0.00409 and a mean squared error of 0.00074, considering a temporal window of 16 hours and 18 previous vibration data points.

Keywords: Mechanical reducer. LSTM neural network. Prediction.

Lista de ilustrações

Figura 1 – Exemplo de curva PF	7
Figura 2 – Fluxograma do processo para elaboração e validação da rede neural LSTM .	10
Figura 3 – Série de dados de vibração referente ao período de 01/09/2022 a 11/04/2023	12
Figura 4 – Comparação entre os valores real e predito no período de 01/09/2022 a 11/04/2023, considerando a melhor configuração de rede LSTM, com $R&S = 16$ e $k = 18$	17
Figura 5 – Comparação entre os dados de treinamento e validação da rede LSTM com $R&S = 16$ e $k = 18$, para 1000 épocas	19
Figura 6 – Comparação entre os valores real e predito no período de 01/07/2023 a 11/05/2024, considerando a configuração de rede LSTM que possui $R&S = 16$ e $k = 18$	19

Lista de tabelas

Tabela 1 – Melhores resultados das redes LSTM para cada k e $R\&S$	16
Tabela 2 – Melhores hiperparâmetros	18

Lista de quadros

Quadro 1 – Variáveis do modelo	12
Quadro 2 – Faixas de calibração dos hiperparâmetros da rede LSTM	14

Sumário

1	INTRODUÇÃO	1
1.1	Objetivo geral	2
1.1.1	Objetivos específicos	2
1.2	Justificativa	3
1.3	Organização do trabalho	4
2	REVISÃO DA LITERATURA	5
2.1	Manutenção industrial	5
2.1.1	Manutenção preditiva	6
2.2	Técnicas de aprendizagem de máquina e aplicações em manutenção preditiva	7
3	METODOLOGIA	9
3.1	Classificação metodológica da pesquisa	9
3.2	Procedimentos metodológicos	10
3.2.1	Coleta e tratamento dos dados	10
3.2.2	Construção da rede neural LSTM	13
3.2.3	Avaliação e análise dos resultados do modelo	14
3.3	Ambiente e recursos computacionais	15
4	RESULTADOS E DISCUSSÃO	16
5	CONSIDERAÇÕES FINAIS	21
	REFERÊNCIAS	22

1 Introdução

Uma das principais causas de falhas nas estruturas, máquinas e seus componentes de um setor produtivo industrial é o nível elevado de vibração destes equipamentos (KATAKE *et al.*, 2023). A vibração em níveis elevados pode ser tratada como um movimento indesejado em relação a um funcionamento natural, estabelecido por meio de uma posição de referência e que é causado por uma determinada força (CHU *et al.*, 2024). Quando um objeto rotativo desloca de sua posição original e retorna de maneira abrupta (razão milimétrica), gera-se uma força de deslocamento, acarretando em um impacto que produz o efeito vibracional (KATAKE *et al.*, 2023).

A vibração pode ser coletada através de um transdutor (sensor), como um acelerômetro capaz de captar o sinal ao longo do tempo, que possui um grau de sensibilidade específico e faixas de frequência (CHU *et al.*, 2024). Os dados da vibração coletados servem como *inputs* para os sistemas de gestão de manutenção das empresas, que, por sua vez, se apropriam de uma ou mais técnicas de análise e interpretação dos dados, o que caracteriza um procedimento de manutenção preditiva (KATAKE *et al.*, 2023). Essas técnicas são amplamente empregadas em indústrias de grande porte, tendo como foco indicar o *status* atual da máquina e de seus componentes (KATAKE *et al.*, 2023).

Dentre as diversas máquinas e equipamentos industriais que passam por esse processo de acompanhamento e análise preditiva, pode-se citar os redutores de velocidade (caixas de engrenagens). Tratam-se de máquinas empregadas para a redução (ou aumento) de velocidade e ampliação (ou redução) do torque, que pode ser gerado por meio de um motor elétrico, turbinas a vapor, motores hidráulicos ou motores a combustão (HE *et al.*, 2023). Essas máquinas são comumente empregadas nas indústrias modernas, em especial, para sistemas que necessitam maiores níveis de torque sob baixa rotação (HE *et al.*, 2023).

Como os redutores podem ser equipamentos importantes dentro da dinâmica de operação de um sistema, a proposição de soluções que permitam antever as possibilidades de falhas nestes equipamentos se mostram desejáveis dentro da perspectiva da manutenção preditiva. Neste contexto, Xu, Zou e Shan (2023) afirmam que a predição de falhas em equipamentos pode ser baseada em duas categorias: confiabilidade e em modelo de dados.

A previsão de falha baseada na confiabilidade é calculada por meio de dados estatísticos de eventos passados, gerando assim o índice de confiabilidade da máquina ou seus componentes (XU; ZOU; SHAN, 2023). A previsão de falha orientada por modelo de dados, requer um historiador de dados, capaz de armazenar alguns dados do equipamento ao longo do tempo, que, quando processados e interpretados por meio de algoritmos de aprendizagem de máquina, se tornam capazes de prever uma falha para uma janela de tempo futura (XU; ZOU; SHAN, 2023).

Além disso, conforme relatado por Wang, Zhu e Zhao (2024), como as técnicas de manutenção preditiva se baseiam em planos de manutenção proativa, a possibilidade de predição de falhas emerge como uma alternativa-chave para a realização de um diagnóstico mais preciso em relação à perda de eficiência das máquinas e seus componentes. Em adição, o uso de sensores de monitoramento on-line do sistema e o desenvolvimento de tecnologias baseadas em Internet das Coisas (IoT), permitem gerar informações relevantes, em tempo real, para que o tomadores de decisão possam intervir no processo, em tempo hábil, visando reduzir o tempo de inatividade das máquinas (WANG; ZHU; ZHAO, 2024).

Mais especificamente, em se tratando do contexto atual de uma fábrica de celulose, local de realização do presente estudo, o diagnóstico de falhas em redutores se baseia no acompanhamento periódico do estado dos equipamentos por meio de inspeções visuais. Adicionalmente, a empresa faz um levantamento de um conjunto de dados dos redutores por meio de sensores, o que inclui o levantamento dos níveis globais de vibração e seus espectros. Por outro lado, até então, esses dados não são utilizados como recursos para auxílio na predição de falhas nestes equipamentos, o que se mostra uma oportunidade de pesquisa que é explorada neste trabalho.

1.1 Objetivo geral

O objetivo geral desse trabalho consiste na construção de um modelo de rede neural artificial (RNA) do tipo *Long Short-Term Memory*¹ (LSTM) para predição do nível global máximo de vibração de um redutor mecânico de velocidade, utilizado no processo de branqueamento de uma fábrica de celulose, em uma janela de tempo futura.

1.1.1 Objetivos específicos

O objetivo geral pode ser desdobrado nos seguintes objetivos específicos:

1. Levantar, organizar e tratar os dados de vibração mecânica de um redutor do processo de branqueamento de celulose;

¹ Rede neural recorrente comumente empregada que em diversos problemas de processamento de linguagem natural. Disponível em: <https://keras.io/api/layers/recurrent_layers/lstm/>. Acesso em 25 abr. 2024.

2. Construir e ajustar os parâmetros da rede neural LSTM, para predição do nível máximo de vibração do equipamento, dentro de uma janela de tempo futura preestabelecida;
3. Realizar um conjunto de testes computacionais com foco na validação da RNA, considerando os erros absoluto e quadrático médio.

1.2 Justificativa

No contexto da manutenção preditiva, um de seus desafios encontra-se na dificuldade imposta pela interpretação do grande volume de dados históricos de séries temporais provenientes de sensores de monitoramento (JAENAL; RUIZ-SARMIENTO; GONZALEZ-JIMENEZ, 2024). Assim, o uso de técnicas computacionais de aprendizado de máquina, mostram-se ferramentas promissoras e para a compreensão automática de um volume grande de dados por meio de modelos parametrizados (JAENAL; RUIZ-SARMIENTO; GONZALEZ-JIMENEZ, 2024), o que justifica a escolha dessa abordagem neste trabalho.

Como uma segunda justificativa para a realização deste trabalho, pode-se dizer que a equipe responsável pelo sistema de manutenção e inspeção preditiva dos equipamentos do processo de branqueamento da empresa foco deste estudo considera muito importante a utilização de técnicas para o auxílio no diagnóstico de falhas nos equipamentos.

Neste contexto, espera-se que o uso de ferramentas de aprendizagem de máquina, sejam capazes de auxiliar nos processos de tomadas de decisão dos inspetores, em especial, no monitoramento e controle on-line do funcionamento de alguns equipamentos-chave do processo, visando a antecipação de falhas. Ademais, é de se esperar que o uso de tais tecnologias possa melhorar o quesito de assertividade do processo de manutenção e redução de falhas humanas.

Por fim, mas não menos importante, há também uma motivação pessoal do autor deste trabalho, que atua no setor de manutenção da empresa e que visualizou junto à sua equipe de trabalho uma oportunidade para aplicar, na prática, alguns dos conhecimentos adquiridos no curso de Ciência de Dados.

1.3 Organização do trabalho

Além deste capítulo de introdução sobre o tema do problema de pesquisa aqui estudado, este trabalho inclui outros cinco capítulos. O Capítulo 2 revisa alguns conceitos necessários para a realização do trabalho, bem como discute a relevância do assunto conforme destacado por diferentes autore(a)s. O Capítulo 3 apresenta os procedimentos metodológicos adotados na pesquisa e destaca algumas de suas limitações em relação ao contexto real do problema. O Capítulo 4 organiza e expõe os resultados obtidos a partir da implementação e execução do modelo de rede neural proposto em ambiente computacional. O Capítulo 4 discute também as saídas do modelo em relação a indicadores de desempenho estatísticos com foco na validação do modelo. Por fim, o Capítulo 5 destaca as principais conclusões obtidas e sugere alguns caminhos para pesquisa futuras.

2 Revisão da Literatura

Este capítulo sumariza um conjunto de conceitos utilizados ao longo da pesquisa. Inicia-se destacando o que se tem na literatura sobre manutenção de equipamentos industriais e a evolução das estratégias de manutenção, ao longo do tempo, em especial, focada na manutenção preditiva. Na sequência são destacadas algumas técnicas de aprendizagem de máquina, conhecidas pelo termo em inglês *Machine Learning* (ML), baseadas em séries temporais, com foco na previsão de valores futuros associados a questões vinculadas aos sistemas de manutenção preditiva.

2.1 Manutenção industrial

As indústrias de manufatura são responsáveis pela produção de muitas mercadorias dos mais variados mercados, servindo de matéria-prima para outras indústrias de transformação (produtos ou serviços) ou para o consumo final de pessoas físicas e jurídicas (PINCIROLI; BARALDI; ZIO, 2023). Em se tratando das indústrias manufatureiras de grande porte, por serem responsáveis pela produção de um volume elevado de produtos em um curto espaço de tempo, é de se esperar que se tenha diferentes abordagens de planos de manutenção de cada uma das máquinas e equipamentos do processo, que variam em função do tipo e do grau de importância do recurso no contexto produtivo e também dos custos associados ao processo de manutenção (FRANCIOSI *et al.*, 2020).

Inevitavelmente, os ativos industriais vão sendo degradados pelo uso. Questões de obsolescência de seus componentes e seu desgaste natural, ao longo do tempo, impactam diretamente na disponibilidade destes equipamentos na linha de produção, na segurança de pessoas e na qualidade do produto acabado (PINCIROLI; BARALDI; ZIO, 2023). Historicamente, o processo de manutenção vem passando por evoluções desde a primeira geração, pós guerra mundial, quando se tinha equipamentos simples, passando pela segunda geração, quando se passou a foca em produtividade e confiabilidade dos sistemas, e chegando à terceira geração, focada no monitoramento e controle (PINTO; XAVIER, 2009).

Mais recentemente, uma quarta geração da manutenção ampliou o uso de sistemas de manutenção preditiva baseados em ferramentas computacionais (PINTO; XAVIER, 2009). Além disso, os avanços na digitalização, impulsionados pela chegada e adoção mais frequente de tecnologias da Indústria 4.0, levaram a substituição de boa parte dos equipamentos eletromecânicos para o contexto digital (ZHONG *et al.*, 2024).

Esse avanço na digitalização dos processos, permitiu o levantamento de grandes volumes de dados vinculados ao processo de monitoramento e controle dos equipamentos (ZHONG *et al.*, 2024). Por outro lado, ao levantar um conjunto de dados faz-se necessário estabelecer algum tipo de estratégia para transformá-los em informação, o que remete a ideia da Indústria 5.0 (LONGO; PADOVANO; UMBRELLO, 2020).

Assim, os sistemas que integram os conceitos da Indústria 5.0 se baseiam no uso de inteligência artificial (IA) para melhor aproveitamento dos dados levantados ao longo do tempo (MIAO *et al.*, 2024). Essas características do sistemas de gestão de manutenção modernos tem tornado a manutenção preditiva cada vez mais difundida em diversos setores (PINCIROLI; BARALDI; ZIO, 2023).

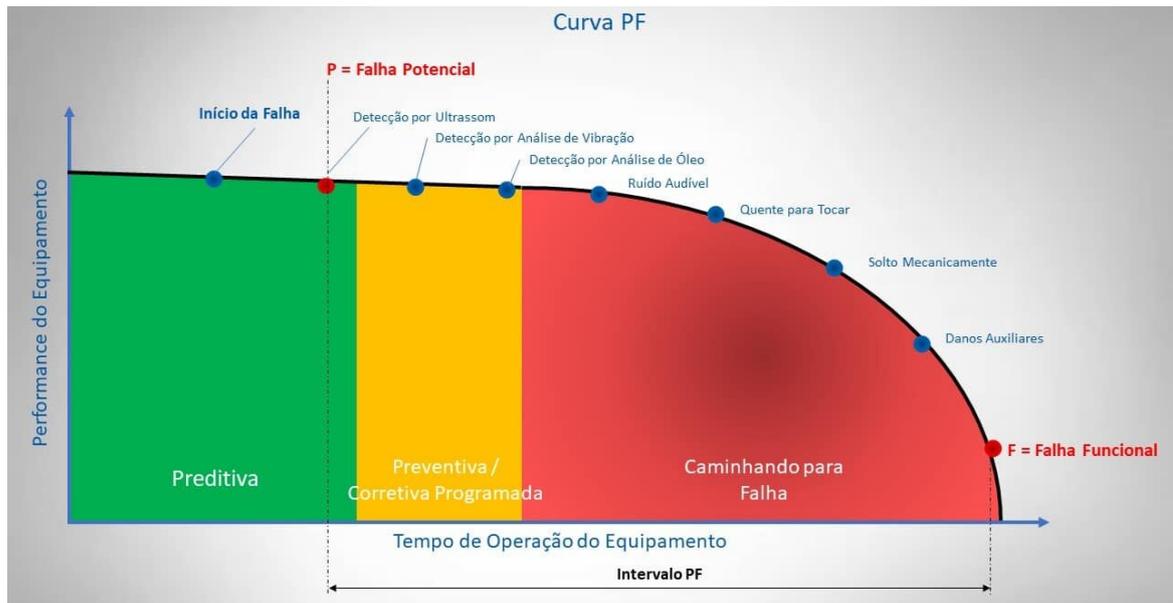
2.1.1 Manutenção preditiva

A manutenção preditiva, também conhecida como manutenção sob condição ou manutenção baseada no estado do equipamento, é caracterizada por realizar a manutenção do item somente quando uma potencial falha (PF) for detectada em sua condição de funcionamento (GREGÓRIO; SILVEIRA, 2018). Esse tipo de manutenção é estruturada de maneira sistêmica e se baseia em técnicas de análise e monitoramento dos ativos, que, no caso dos equipamentos rotativos, permite detectar alterações nos níveis de vibração, contaminação de lubrificantes, níveis de pressão, trincas em equipamentos estáticos, entre outros tipos de falhas (GREGÓRIO; SILVEIRA, 2018).

De acordo com Engeteles (2017), uma falha potencial pode ser melhor representada por uma curva de PF, que permite monitorar o comportamento do equipamento até sua falha efetiva, conforme mostrado na Figura 1. Esse tipo de abordagem tem se mostrado efetiva com relação à otimização dos custos de manutenção e aumento da vida útil das máquinas e seus componentes (MALLIORIS; AIVAZIDOU; BECHTSIS, 2024).

Neste sentido, pode-se dizer que a manutenção preditiva visa otimizar os custos de manutenção sob dois horizontes: *i*) identificar o momento certo para realizar a manutenção, evitando falhas graves que podem deixar a máquina inoperante por um período, e *ii*) reduzir o tempo de inatividade da máquina quando uma PF é detectada, evitando manutenções desnecessárias, com base na interpretação dos dados do ativo (HURTADO *et al.*, 2023).

Figura 1 – Exemplo de curva PF



Fonte: Engeteles (2017, p. 1)

2.2 Técnicas de aprendizagem de máquina e aplicações em manutenção preditiva

Os algoritmos de IA, em especial, no âmbito da ciência de dados, estão atraindo cada vez mais atenção de estudiosos em diversas áreas do conhecimento (DAOUTIDIS *et al.*, 2024). A capacidade destes algoritmos de interpretar grandes volumes de dados, o poder de processamento e a possibilidade de análises rápidas dos dados, tem impulsionado o uso de tais recursos pelas empresa, visando auxiliar nos processos de tomadas de decisão (DAOUTIDIS *et al.*, 2024).

No contexto da manutenção preditiva, em que, boa parte dos dados são organizados de maneira estruturada em séries temporais, a utilização destas ferramentas de IA para análise de padrões e detecção de falhas tem se mostrado promissora (STRUYE; LATRÉ, 2020). Para a predição de séries temporais, a construção de modelos de regressão lineares ou não lineares, baseados no uso de redes neurais artificiais (RNAs), tem sido bastantes comuns na literatura (STRUYE; LATRÉ, 2020)

Dentre os tipos de RNAs mais empregadas, destaque para as conhecidas como redes neurais recorrentes (RNNs), utilizadas para modelar, aprender e prever dados temporais (STRUYE; LATRÉ, 2020). Esse tipo de rede, apesar de fornecer resultados bem sucedidos para dados de curto prazo, não costuma apresentar bons resultados para dados de longo prazo (DUDUKCU *et al.*, 2023).

Por outro lado, as RNNs baseadas na estrutura de um modelo LSTM, caracterizam-se pela introdução de células de memória de longos períodos, capazes de armazenar e recuperar informações de longos intervalos sequenciais de tempo (DEHGHAN SHOORKAND; NOURELFATH; HAJJI, 2024). Por este motivo, redes LSTM têm sido empregadas e estudadas em diferentes contextos de aplicações em manutenções preditivas, em função da sua capacidade de aprendizado e retenção de memória de longo prazo da série de dados (HESABI; NOURELFATH; HAJJI, 2022).

Segundo Arafat, Hossain e Alam (2024) boa parte das estratégias de manutenções preditivas são focadas na detecção antecipada de falhas ou predição de valores próximos para um determinada série temporal, com base nos dados coletados por meio de sensores instalados nas máquinas. Arena *et al.* (2024) destacam que o sucesso no uso dos algoritmos de ML na manutenção preditiva depende da qualidade e robustez do sistema de coleta e monitoramento que suporta o processo.

Em suma, pode-se dizer que, com o auxílio de programas computacionais, uma estrutura de ML na manutenção preditiva pode ser incorporada ao sistema de manutenção de uma empresa, desde que, sejam utilizados, adequadamente, um conjunto de dados históricos capazes de realizar a previsão sequencial da série de dados futuras (ARENA *et al.*, 2024).

3 Metodologia

3.1 Classificação metodológica da pesquisa

A proposta desta pesquisa se baseia em uma abordagem quantitativa em que serão utilizadas técnicas de ML capazes de prever os dados de saída de um problema a partir das características dos dados de entrada, que variam ao longo do tempo (ARAFAT; HOSSAIN; ALAM, 2024). Segundo Cauchick-Miguel *et al.* (2018), quando se investigam relações causais, uma das preocupações da abordagem quantitativa é observar a influência do fator tempo (histórico das variáveis de entrada), para a caracterização dos dados de saída, principalmente em pesquisas de levantamento e quase experimentos.

Esta pesquisa também pode ser classificada como empírico-normativa sob a perspectiva dos objetivos (CAUCHICK-MIGUEL *et al.*, 2018). Conforme descrito por Bertrand e Fransoo (2002), a pesquisa empírica e normativa está interessada no desenvolvimento de políticas e estratégias para melhorar uma situação atual, sendo impulsionada principalmente por descobertas empíricas e medições reais de dados.

Assim, a classificação como empírico-normativa se dá em função da construção de modelos de RNAs para a predição dos níveis máximos de vibração de um equipamento mecânico, para um horizonte de tempo futuro preestabelecido. Neste contexto, pode-se dizer que, a ferramenta desenvolvida a partir desta pesquisa poderá, no futuro, auxiliar nos processos de análises de dados e monitoramento dos redutores mecânicos pertencentes a um setor produtivo da empresa.

Em adição, conforme destacado por Cauchick-Miguel *et al.* (2018), para a realização adequada de uma pesquisa científica é necessário assegurar questões de mensurabilidade, causalidade, repetibilidade, e generalização. Para esta pesquisa, o levantamento dos dados de entrada e a análise estatística dos dados numéricos de saída da rede neural terão relações diretas com as questões de mensurabilidade da pesquisa.

Como a pesquisa se limita em modelar problemas com base em bibliotecas do pacote Keras², em linguagem Python³, para predição dos níveis máximos de vibração futuros do redutor mecânico de velocidade, pode-se dizer que a metodologia proposta pode ser estendida (generalizada) para outras famílias de equipamentos, porém, com seus respectivos ajustes nos dados de entrada e calibração dos parâmetros de referência, visando estabelecer as relações de causa e efeito do problema.

² Biblioteca de rede neural de código aberto escrita em Python. Disponível em: <<https://keras.io/>>. Acesso em 15 abr. 2024.

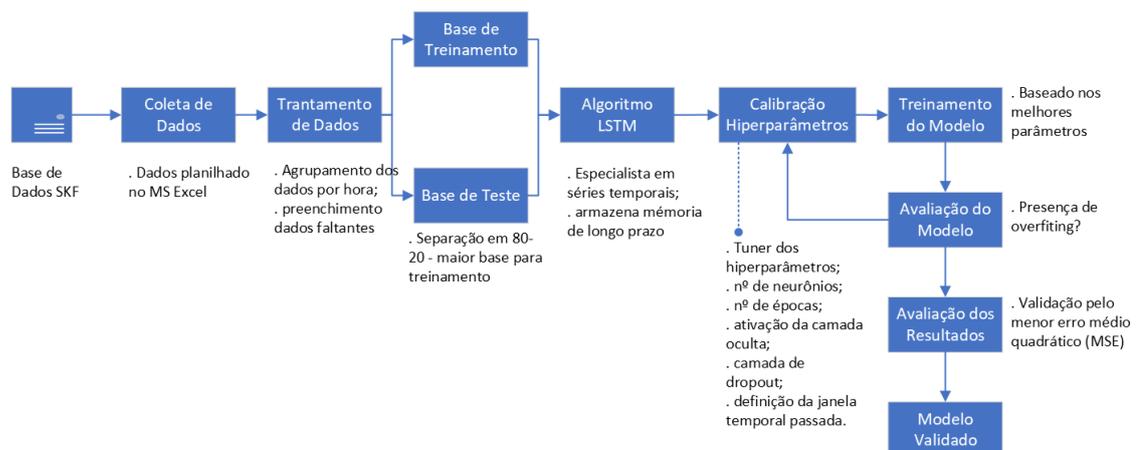
³ Linguagem de programação utilizada a modelagem da rede neural deste trabalho. Disponível em: <<https://www.python.org/>>. Acesso em 15 abr. 2024.

Sob a perspectiva da repetibilidade, a ideia é que a descrição dos procedimentos metodológicos apresentados neste capítulo, somados aos resultados da pesquisa, documentados no capítulo seguinte, sejam suficiente para replicação futura deste estudo. Em suma, espera-se que a análise de dados empírico-normativa proposta neste trabalho, possa contribuir na identificação antecipada e monitoramento da evolução dos problemas que levam a falhas mecânicas nos redutores.

3.2 Procedimentos metodológicos

A Figura 2 sumariza o fluxo do processo de construção da rede neural, que se inicia a partir da coleta e tratamento dos dados, seguido pela construção do modelo baseado no algoritmo LSTM. Na sequência, a base de dados é dividida para as etapas de teste e treinamento da rede. Em seguida, são ajustados os hiperparâmetros, que, por sua vez levarão às etapas de treinamento e avaliação do modelo. Por fim, é necessário realizar uma avaliação dos resultados com foco na validação do modelo proposto, em função dos indicadores e critérios mínimos preestabelecidos.

Figura 2 – Fluxograma do processo para elaboração e validação da rede neural LSTM



Fonte: Elaborado pelo autor.

As subseções a seguir apresentam, de forma resumida, algumas particularidades do processo de coleta e tratamento de dados, construção do modelo, calibração de parâmetros e indicadores para avaliação dos resultados do modelo.

3.2.1 Coleta e tratamento dos dados

Para a elaboração da rede neural LSTM utilizou-se os dados dos níveis globais de vibração do redutor de velocidade do equipamento conhecido como Raspador de Fundo do Estágio P-Final do Branqueamento de Celulose. Esse equipamento possui monitoramento de vibração on-line com sensores instalados em sua carcaça e armazenamento dos dados em software específico.

O redutor possui oito variáveis monitoradas, sendo quatro distribuídas no eixo de entrada e outras quatro no eixo de saída, com intervalo de coleta de dados de aproximadamente oito horas. As situações de falha do redutor acarretam na parada de pelo menos 18 horas no Digestor, etapa subsequente do processo de Branqueamento, na perda de produção de aproximadamente 1.584 toneladas de celulose, e em custos de manutenção. O tempo de parada inclui a mobilização da equipe de manutenção, do maquinário e do ferramental para o reparo ou substituição redutor.

O processo de manutenção preditiva em estudo possui dois tipos de coleta de dados, off-line e on-line. Para os equipamentos com coleta off-line é necessário o deslocamento do inspetor até o equipamento e o uso de um aparelho para coleta dos dados. No momento da coleta, o inspetor, por meio do visor do aparelho, verifica se a máquina possui alguma anomalia, e, em caso de constatação de um potencial defeito, analisa de maneira mais detalhada os espectros de vibração da máquina em software específico. Este procedimento de manutenção possui grande intervalo entre os dados coletados, sendo em média 35 dias.

No caso dos equipamentos que possuem sensores de monitoramento on-line, o inspetor adota uma rotina semanal para realizar as análises de vibração, tendo como referência os limites preestabelecidos. Neste caso, o inspetor verifica se algum dos alarmes do equipamento foi acionado. Embora a periodicidade de acompanhamento no procedimento de coleta on-line seja maior, há casos em que não é possível a identificação prévia de uma situação da falha.

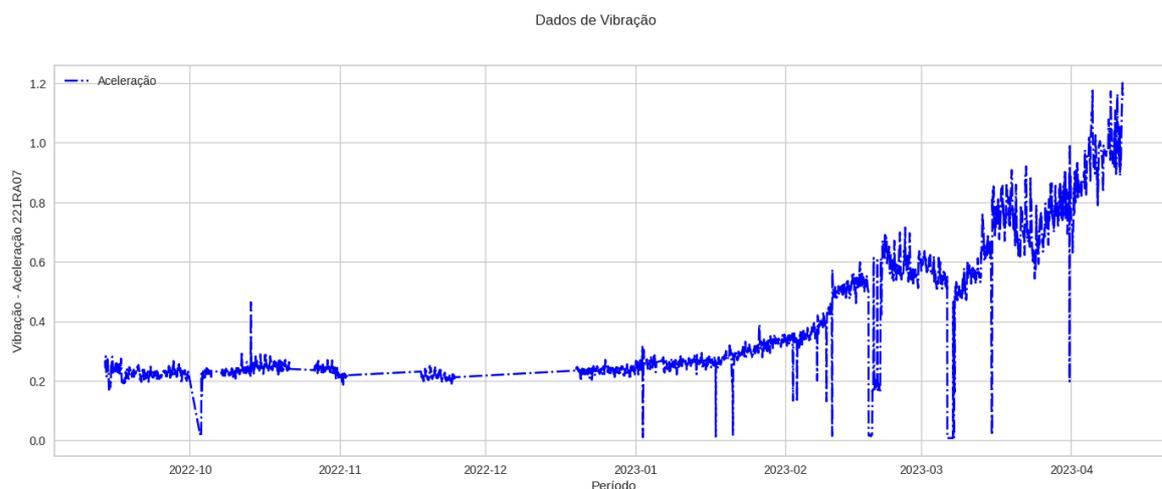
Para este trabalho, os dados dos equipamentos com monitoramento on-line, que ficam armazenados no historiador de dados do sistema SKF @ptitude Analyst⁴, são utilizados para analisar as tendências de variação dos níveis de vibração em uma janela de tempo. Conforme destacado por Walliman (2015), a validação de dados históricos pode ser um processo complexo, sendo normalmente executado por especialistas. Assim, o levantamento de dados foi realizado sob a supervisão e consulta aos especialistas e responsáveis pelo processo de manutenção, em especial, nos momentos de interpretação de situações atípicas nos dados do período estudado.

A proposta inicial do trabalho era utilizar uma base de dados com 5 anos de histórico. Por outro lado, devido às limitações, advindas de inconstâncias nas coletas dos dados on-line, os dados utilizados na pesquisa ficaram restritos ao período de 01/09/2022 a 11/04/2023. Tais inconsistências ocorrem por falhas no sensor, danos em cabos ou falha na comunicação do *hub* com o servidor de dados. A Figura 3 mostra a série de dados de vibração estudada.

Para amenizar a falta de dados e a despadronização da escala da série, existem diversas técnicas para imputação de dados no conjunto de dados, desde as mais simples a mais complexas (SALAMANIS *et al.*, 2023). A estratégia adotada para lidar com os dados faltantes consistiu em utilizar a média dos cinco últimos valores válidos dos dados para preencher essas lacunas.

⁴ Software que oferece armazenamento, análise e recuperação de dados on-line de ativos. Disponível em: <<https://www.skf.com/br/products/condition-monitoring-systems/software/aptitude-analyst>>. Acesso em: 02 mai. 2024.

Figura 3 – Série de dados de vibração referente ao período de 01/09/2022 a 11/04/2023



Fonte: Elaborado pelo autor.

Neste contexto, pode-se dizer que a escolha do horizonte de tempo se deu pelo fato de se tratar do período com maior confiabilidade e consistência dos dados levantados, e por apresentar pelo menos uma situação de falha no período. A situação de falha ocorre, efetivamente, quando o nível de vibração atinge o valor de 1,0 mm/s ou superior. Assim, no contexto do problema real, a empresa utiliza de dois níveis de alarme, sendo um primeiro que indica atenção/alerta, quando o nível vibração atinge o valor de 0,5 mm/s e um segundo que aponta uma situação de perigo, quando o valor atinge o nível de 1,0 mm/s.

O Quadro 1 mostra as duas variáveis de entrada foram levantadas e utilizadas no modelo.

Quadro 1 – Variáveis do modelo

Variável	Tipo	Unidade
Data	<i>datetime</i>	hora e data (12 am/pm - dd/mm/aaaa)
Aceleração	<i>float</i>	milímetro por segundo (mm/s)

No Quadro 1 a aceleração é medida por um acelerômetro que se baseia na coleta da unidade de força causada por uma vibração ou alteração do movimento da massa, medida em milímetros por segundo. Em se tratando do âmbito computacional, ao realizar o carregamento dos dados no ambiente do Google Colab⁵ foi realizada a análise exploratória dos dados, com foco na eliminação dos dados inconsistentes.

Alguns *outliers* identificado, isto é, pontos discrepantes ou fora da curva de uma amostra (SICSÚ; SAMARTINI; BARTH, 2023), são mantidos no processo de construção do modelo, uma vez que, como o objetivo é a predição dos níveis máximos de vibração, definir uma faixa de corte poderia prejudicar o treinamento do modelo em relação seus dados históricos.

⁵ Plataforma on-line que fornece um ambiente de um computador interativo e colaborativo para codificação e execução de algoritmos. Disponível em: <<https://colab.research.google.com/>>. Acesso em 02 mai. 2024.

Após a interpretação e tratamentos dos dados, foi realizada a separação dos dados em dois conjuntos, um conjunto de treinamento outro de teste. O conjunto de treinamento é usado para modelar o algoritmo de predição dos níveis globais de vibração do redutor, enquanto o conjunto de teste é usado para verificar a consistência do modelo (ARUNADEVI *et al.*, 2023).

Conforme destacado por Sicsú, Samartini e Barth (2023), não há uma regra específica para separação do conjunto de dados em treinamento e teste. Portanto, as rodadas do algoritmo serão realizadas com a separação 80-20, sendo 80% dos dados da série temporal separados para treinamento e 20% dos dados restantes da série separados para teste.

De forma complementar, foram utilizadas as funções *rolling*⁶ e *shift*⁷ para mover janelas de dados na série temporal. O uso das funções *rolling* e *shift* no conjunto de dados basearam-se nas documentações públicas disponíveis na biblioteca do Pandas⁸. A função *rolling* permite a aplicação de operações de janela deslizante, facilitando a análise de tendências e padrões em dados ao longo do tempo. A função *shift* possibilita o deslocamento de valores temporais, permitindo calcular diferenças entre períodos e criar séries temporais deslocadas para frente ou para trás.

3.2.2 Construção da rede neural LSTM

A escolha do algoritmo mais adequado para o aprendizado de máquina é uma das tarefas complexas e exigem a atenção do pesquisador para evitar retrabalho no processo de construção de um modelo de rede neural (GÉRON, 2021). Questões como quantidade insuficiente de dados de treinamento, dados de treinamento não representativos, baixa qualidade dos dados, características irrelevantes ou sobre/subajustes dos dados de treinamento são exemplos de aspectos que se deve considerar ao construir a rede (GÉRON, 2021).

Embora existam diversos modelos de algoritmos de ML nas bibliotecas do Python, conforme destacado no Capítulo 2, o algoritmo escolhido para a pesquisa foi o modelo de rede neural do tipo LSTM. Trata-se de uma técnica que se baseia na memória de longo prazo, ideal para modelos baseados em séries temporais, sendo capaz de transmitir informações através das sequências dos dados, em que o contexto de entradas anteriores guia a estimativa do padrão de saída esperado (DEGHAN SHOORKAND; NOURELFATH; HAJJI, 2024).

Bui Tien *et al.* (2024) acrescentam que a rede LSTM é capaz de reter informações de longo prazo sem exigir treinamento específico, sendo que sua arquitetura interna permite memorizações sem a intervenção externa na rede. Além disso, ao estruturar a rede LSTM é necessário estabelecer um conjunto mínimo de hiperparâmetros do modelo.

⁶ Biblioteca Pandas descrevendo recursos da função *Rolling* para uma janela temporal deslizante. Disponível em: <<https://bit.ly/4bl6fGE>>. Acesso em 1 mai. 2024.

⁷ Biblioteca Pandas descrevendo recursos da função *Shift* para deslocamento de valores para cima ou para baixo ao longo do índice. Disponível em: <<https://bit.ly/3JHdvkn>>. Acesso em 1 mai. 2024.

⁸ Biblioteca de análise e manipulação de dados em linguagem Python. Disponível em: <<https://pandas.pydata.org/>>. Acesso em 1 mai. 2024.

Uma boa escolha dos hiperparâmetros pode levar a um menor esforço computacional e melhorar o ajuste do modelo. A calibração dos hiperparâmetros neste trabalho foi realizada por meio de um algoritmo KerasTuner⁹ capaz de executar um conjunto de configurações, dentro de intervalos e possibilidades preestabelecidas, em uma sequência de testes e comparações estatísticas entre eles.

Para este trabalho foram testadas as variações dos hiperparâmetros vinculados ao tamanho da janela, ao número de camadas do LSTM, ao número de neurônios e de camadas ocultas seu seus neurônios, às funções de ativação dos neurônios e do otimizador do modelo. O Quadro 2 mostra as faixas de valores para os hiperparâmetros calibrados na rede LSTM, por meio do KerasTuner.

Quadro 2 – Faixas de calibração dos hiperparâmetros da rede LSTM

Hiperparâmetro	Faixa
Variações de k	1 a 30
Número de neurônios 1ª camada	10 a 300
Funções ativação 1ª camada	relu, tanh, sigmoid
Número de camadas ocultas	1 a 3
Número de neurônios camada oculta	10 a 500
Funções ativação camadas ocultas	tanh e sigmoid
Rate da camada de Dropout	0.25
Learning rate	1e-2, 1e-3 e 1e-4
Otimizador	Adam
Função de perda (loss)	MAE
Métrica de validação	MSE

3.2.3 Avaliação e análise dos resultados do modelo

Conforme destacado por Demšar (2006), não existe um procedimento único e dominante para comparar e avaliar os resultados dos algoritmos de predição. Assim, sugere-se a utilização de testes estatísticos como o erro quadrático médio (*Mean Squared Error* - MSE) o erro absoluto médio (*Mean Absolute Error* - MAE), ou comparações empíricas, por exemplo (DEMŠAR, 2006).

O procedimento para análise e avaliação dos resultados deste trabalho foi realizado a partir de um conjunto de testes computacionais, que incluem a escolha dos hiperparâmetros da rede LSTM, considerando os valores de MAE e MSE obtidos em cada rodada de execução completa do algoritmo, frente aos dados de treinamento e teste da rede, e calculados conforme as Equações (3.1) e (3.2), respectivamente.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3.1)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3.2)$$

⁹ Algoritmo para calibração dos hiperparâmetros da rede LSTM. Disponível em: <https://keras.io/guides/keras_tuner/>. Acesso em 02 mai. 2024.

Nas Equações (3.1) e (3.2) o valor de n representa o número total de observações, y_i indica os valores reais e \hat{y}_i é o valor previsto.

Para comparar o desempenho das diferentes configurações de redes neurais propostas, será adotado o cálculo do MSE vinculado aos dados de teste (20%). De acordo com Liu *et al.* (2024), as métricas de validação pelo MSE são comumente utilizadas para validação dos algoritmos baseados em redes neurais, não se restringindo às redes recorrentes.

3.3 Ambiente e recursos computacionais

O ambiente computacional utilizado para coleta, tratamento de dados, modelagem e calibração de parâmetros, bem como organização dos resultados são apresentados a seguir:

- SKF @ptitude Analyst (versão 9.0.2060.2 MR2): software responsável pelo monitoramento on-line de vibração dos equipamentos industriais, que é utilizado como o historiador de dados da empresa;
- SAP S4/HANA¹⁰ (versão 1909): sistema de planejamento de recursos adotado pela empresa para o armazenamento dos dados de vibração e outros dados da empresa;
- Google Colab: software de aplicação em nuvem da empresa Google disponibilizado em versão gratuita para desenvolvimento de algoritmos em Python (versão 3) com memória RAM do sistema de 12.7GB e 107.7GB de disco.

¹⁰ Sistema de planejamento de recursos empresariais (*Enterprise Resource Planning* - ERP). Disponível em: <<https://www.sap.com/brazil/products/technology-platform/hana/what-is-sap-hana.html>>. Acesso em 02 mai. 2024.

4 Resultados e discussão

Este capítulo apresenta os resultados e discussões acerca da metodologia proposta para a predição dos níveis máximos de vibração dos redutores mecânicos, para uma janela de tempo futura. As configurações de algoritmos LSTM testadas combinam as funções *rolling* (R) e *shift* (S), responsáveis pelo deslocamento das janelas de dados, para três diferente configurações, com $R\&S = \{8, 16, 24\}$ horas. Como a empresa planeja e divide suas operações em três turnos de trabalho, optou-se pela escolha dos valores de $R\&S$ em múltiplos de 8 horas, limitado a um dia de trabalho.

Além do parâmetro $R\&S$, o modelo proposto também requer a definição do valor de um parâmetro k , que indica o número de horas que o algoritmo irá olhar para trás (passado) para treinar a rede LSTM. Os valores de k testados variam de 1 a 30 horas para treinamento e teste. Para cada combinação de k e $R\&S$ são realizadas 59 rodadas do *Tuner* para a escolha dos melhores hiperparâmetros, gerando assim no total 5.310 modelos de redes LSTM. A Tabela 1 apresenta o melhor resultado para cada combinação de k e $R\&S$, baseadas na separação 80/20 da base de dados, cujo treinamento dos modelos é parametrizado para 300 épocas.

Tabela 1 – Melhores resultados das redes LSTM para cada k e $R\&S$

k	$R\&S = 8$			$R\&S = 16$			$R\&S = 24$		
	MAE	MSE	val_MSE	MAE	MSE	val_MSE	MAE	MSE	val_MSE
1	0,00418	0,00023	0,01184	0,00402	0,00018	0,03424	0,00304	0,00012	0,00614
2	0,00530	0,00025	0,00907	0,00958	0,00028	0,00217	0,00163	0,00014	0,00270
3	0,00478	0,00023	0,01557	0,00665	0,00023	0,00376	0,00236	0,00011	0,00868
4	0,00298	0,00020	0,00574	0,00372	0,00017	0,00531	0,00910	0,00040	0,01292
5	0,00304	0,00020	0,01361	0,00376	0,00017	0,01629	0,00332	0,00012	0,02656
6	0,00602	0,00026	0,01351	0,00538	0,00023	0,00406	0,00195	0,00013	0,00486
7	0,00316	0,00019	0,00780	0,00732	0,00026	0,00317	0,00600	0,00019	0,03127
8	0,00810	0,00033	0,00275	0,00348	0,00016	0,00639	0,00213	0,00011	0,00559
9	0,01117	0,00039	0,00215*	0,00397	0,00019	0,01109	0,00407	0,00014	0,01163
10	0,24475	0,07091	0,65718	0,00485	0,00020	0,00654	0,00298	0,00009	0,01300
11	0,00789	0,00033	0,00332	0,00368	0,00017	0,00612	0,00578	0,00015	0,00524
12	0,00335	0,00020	0,01060	0,00464	0,00017	0,00643	0,00567	0,00015	0,00525
13	0,00689	0,00026	0,00427	0,00307	0,00015	0,01844	0,01097	0,00060	0,01375
14	0,00688	0,00027	0,02416	0,00297	0,00013	0,00763	0,00356	0,00010	0,00841
15	0,00313	0,00020	0,00451	0,06948	0,01410	0,35775	0,00178	0,00009	0,01265
16	0,00681	0,00028	0,01435	0,00382	0,00020	0,00544	0,00205	0,00009	0,01639
17	0,00428	0,00020	0,00935	0,25165	0,07529	0,68043	0,00214	0,00013	0,00484
18	0,24482	0,07097	0,65718	0,00409	0,00027	0,00074*	0,00304	0,00017	0,00099*
19	0,00398	0,00020	0,00671	0,00314	0,00015	0,00744	0,00160	0,00008	0,00657
20	0,00339	0,00019	0,00555	0,00537	0,00020	0,00355	0,00288	0,00012	0,01843
21	0,00389	0,00019	0,00604	0,00314	0,00014	0,00685	0,00406	0,00012	0,00714
22	0,00538	0,00018	0,00678	0,00336	0,00021	0,12836	0,00574	0,00014	0,00363
23	0,00613	0,00027	0,00787	0,00266	0,00015	0,00631	0,00379	0,00025	0,02920
24	0,00369	0,00023	0,00801	0,00687	0,00092	0,00725	0,00154	0,00008	0,01011
25	0,00483	0,00017	0,00702	0,00581	0,00024	0,01408	0,74385	0,56586	0,04977
26	0,01184	0,00041	0,00216	0,00402	0,00017	0,00704	0,00220	0,00009	0,01083
27	0,00475	0,00022	0,00944	0,00325	0,00017	0,02605	0,00213	0,00008	0,01234
28	0,00457	0,00022	0,00611	0,00274	0,00020	0,00415	0,01094	0,00047	0,01719
29	0,00333	0,00022	0,00600	0,00190	0,00014	0,00705	0,00231	0,00010	0,00475
30	0,00452	0,00020	0,01977	0,00269	0,00016	0,01107	0,00830	0,00020	0,00293

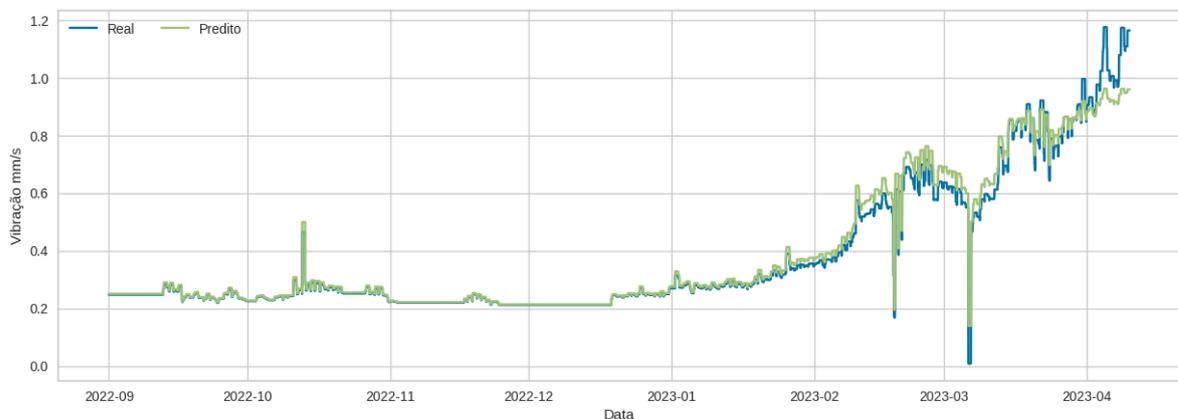
* Melhor resultado com base no val_MSE.

Na Tabela 1 as colunas **MAE** indicam o erro absoluto médio de cada configuração de rede neural testada, o que representa o quão bem a função de perda do algoritmo está performando na base de treinamento. As colunas **MSE** mostram o erro quadrático médio da base de treinamento (80% dos dados), enquanto as colunas **val_MSE** indicam o erro quadrático médio da base de validação (20% dos dados).

Para identificar as melhores configurações de rede neural LSTM para cada valor de $R&S$ são observados os menores valores de **val_MSE**, que, na Tabela 1 estão destacados em negrito e com um asterisco (*). Entre todas as configurações de rede LSTM avaliadas, quando $R&S$ é igual a 16 e k é igual a 18 obtém-se o menor **val_MSE**. Em outras palavras, a melhor configuração obtida do modelo aconteceu para uma janela temporal futura de 16 horas, ao observar as últimas 18 horas anteriores, resultando em um erro quadrático médio de 0,00074, o que corresponde a um erro de 7,07% dos valores preditos frente aos valores reais.

Para validar os resultados, foi realizada a comparação entre os valores reais e preditos, para a melhor configuração de rede LSTM, cujo valor de $R&S$ é igual a 16 e k é igual a 18. O gráfico da Figura 4 mostra que a distância entre as curvas das duas séries de dados, real e predito, que indicam os máximos valores dentro da janela temporal.

Figura 4 – Comparação entre os valores real e predito no período de 01/09/2022 a 11/04/2023, considerando a melhor configuração de rede LSTM, com $R&S = 16$ e $k = 18$



Fonte: Elaborado pelo autor.

Pela Figura 4 observa-se que a série dos valores predito, possui pouca diferença em relação à série de dados dos valores reais, acompanhando as tendências da curva da série de dados dos valores reais. Por outro lado, ao final da série, nos dois últimos picos dos valores reais, é possível observar que houve um distanciamento maior entre as curvas, o que pode indicar a necessidade de inclusão de novas variáveis ou a realização de ajustes para se obter um modelo mais fidedigno.

Em adição, considerando uma condição mais favorável para a empresa, o cenário mais adequado seria quando $R\&S$ é igual 24, uma vez que, a rede LSTM teve valores de val_MSE relativamente baixos. Em sua melhor configuração, com $R\&S$ é igual 24 e k igual a 18, a rede neural resultou em val_MSE 33,78% superior em relação à melhor entre todas configurações de rede LSTM, cujo $R\&S$ é setado em 16. Poder antever um cenário com maior prazo é uma condição que favorece o decisor, porém é de se esperar que a tentativa de previsão para uma janela temporal maior dificulte a capacidade de predição da rede neural.

De forma complementar, a Tabela 2 sumariza as melhores configurações de hiperparâmetros das redes LSTM, selecionadas durante a execução da função *Tuner* da biblioteca *Keras*, para cada valor de $R\&S$ avaliado. É possível notar que apenas o hiperparâmetro *learning_rate* é comum entre as melhores configurações testadas.

Tabela 2 – Melhores hiperparâmetros

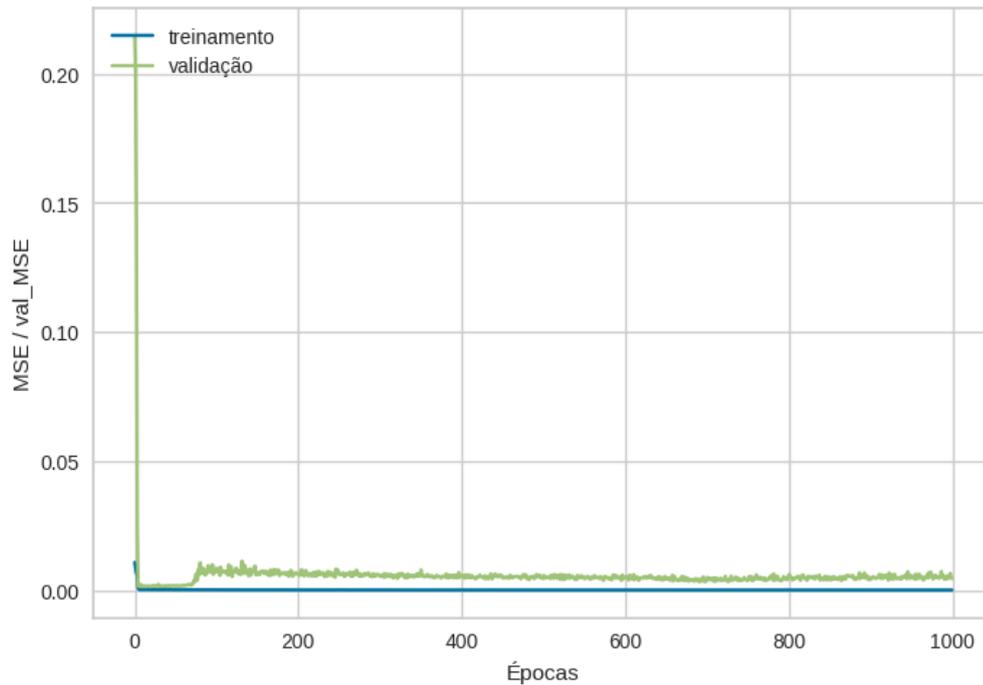
Hiperparâmetro	$R\&S$		
	8	16	24
Melhor k	9	18	18
<i>lstm_units</i>	160	60	180
<i>lstm_activation</i>	sigmoid	relu	relu
<i>num_layers</i>	3	1	1
<i>layer_0</i>	410	200	370
<i>activation</i>	tanh	sigmoid	sigmoid
<i>dropout</i>	true	false	false
<i>learning_rate</i>	0.0001	0.0001	0.0001
<i>layer_1</i>	360	-	-
<i>layer_2</i>	330	-	-

Assim, de posse dos melhores hiperparâmetros da rede LSTM que possui $R\&S$ igual a 16 e k igual a 18 (2ª coluna da Tabela 2), aumentou-se o número de épocas para 1000 e o *batch size* para 50. Como resultado, obteve-se um MAE igual a 0.002854 e val_MSE de 0.004535. O gráfico da Figura 5 mostra o processo de validação do treinamento deste experimento com base nos valores de val_MSE .

Pela Figura 5 é possível notar que o modelo convergiu rapidamente para seus menores índices de val_MSE , para o treinamento e para a validação. Pouco depois, a curva de validação mostra uma perda em sua capacidade de generalização, embora ainda demonstre consistência no processo de predição, por apresentar baixos índices de erros.

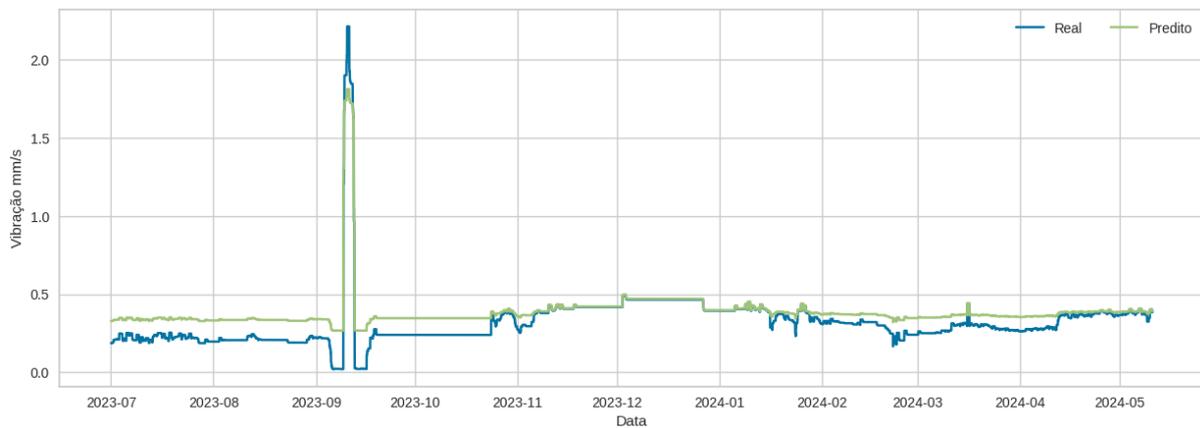
Por fim, uma última rodada de testes computacionais foi realizada com o objetivo de avaliar a capacidade de predição do modelo frente a outros dados, que correspondem a coletas mais recentes de vibração dos redutores. O período de dados levantando correspondente ao intervalo entre as datas de 01/07/2023 a 11/05/2024. A Figura 6 mostra uma comparação entre valores preditos e os valores reais, no referido período, para a rede LSTM ($R\&S = 16$ e $k = 18$).

Figura 5 – Comparação entre os dados de treinamento e validação da rede LSTM com $R\&S = 16$ e $k = 18$, para 1000 épocas



Fonte: Elaborado pelo autor.

Figura 6 – Comparação entre os valores real e predito no período de 01/07/2023 a 11/05/2024, considerando a configuração de rede LSTM que possui $R\&S = 16$ e $k = 18$



Fonte: Elaborado pelo autor.

Neste último teste obteve-se um MAE de 0.069822 e um val_MSE de 0.008225, o que representa 27,82% de erro. Apesar do modelo apresentar um erro maior, frente aos novos dados, ainda assim, ele demonstra uma boa capacidade de previsão da rede LSTM. Observa-se que a série dos valores preditos foi capaz de acompanhar as linhas de tendência, embora esteja um pouco mais distante da série dos dados reais.

Baseado nestes resultados, é possível dizer que o uso da rede LSTM proposta neste trabalho, permitirá, no futuro, que as equipes de manutenção preditiva da empresa possam se antecipar em relação à previsão de falhas nos redutores. Esse tipo de informação permite uma melhoria no planejamento da manutenção do equipamento, levando a menos situações de manutenção corretiva e, conseqüentemente, uma tendência a redução dos custos de manutenção.

5 Considerações finais

Este trabalho teve como objetivo a construção de uma rede neural artificial, capaz de prever os níveis máximos de vibração futuros, dentro de uma janela temporal preestabelecida, vinculados aos redutores mecânicos de uma empresa produtora de celulose. O modelo de algoritmo utilizado foi o modelo de rede neural recorrente do tipo LSTM, que é comumente empregado para dados de séries temporais.

Para a construção do modelo foi necessária a aplicação combinada das funções *rolling* (R) e *shift* (S) da biblioteca do Pandas, codificadas em Python, responsáveis pelo deslocamento dos dados de treinamento para três diferentes janela temporais, com R & S de 8, 16 e 24 horas. Além disso, foi utilizado *Tuner* da biblioteca do Keras, para ajustar os hiperparâmetros da rede LSTM, considerando diferentes valores do parâmetro k (variando de 1 a 30), responsável por estabelecer quantas horas deve-se olhar para trás na base de dados.

Para avaliar e comparar o desempenho das diferentes configurações de rede LSTM, utilizou-se como referência o erro quadrático médio (val_MSE) e o erro absoluto médio (MAE) em experimentos com 300 épocas. O modelo que apresentou o melhor desempenho resultou em um val_MSE de 0,00074 e um MAE de 0,00409, considerando a fixação dos parâmetros R & S e k em 16 e 18, respectivamente, o que representa um erro de 7,07% em relação ao contexto real.

Em uma rodada de testes final, ao explorar uma nova base de dados, com dados mais recentes do equipamento, foi possível perceber que o modelo se mostrou consistente ao apresentar valores de val_MSE de 0.008225 e MAE 0.069822, para os testes com 1.000 épocas, o que representa um erro de 27,82%.

Com base nos resultados obtidos, pode-se dizer que a rede LSTM se mostrou eficaz e promissora, considerando os baixos níveis de erros. Desse modo, entende-se que o uso de tal ferramenta, em um momento futuro, possa auxiliar no processo de manutenção preditiva da empresa, agilizando nas tomadas de decisão vinculadas ao processo de manutenção dos redutores, e, conseqüentemente, acarretar em redução dos custos da organização.

Por fim, como sugestão para trabalhos futuros, fica a incorporação de múltiplas variáveis ao modelo de dados de vibração, bem como o uso de dados de processo e “sub-dados” oriundos dos espectros de vibração. A impossibilidade de utilização destes dados nesta pesquisa se deu em função de restrições técnicas de acesso a essas bases de dados. Outra oportunidade de pesquisa futura é a replicação da metodologia proposta para outros equipamentos vinculados ao processo de manutenção da empresa.

Referências

- ARAFAT, M. Y.; HOSSAIN, M.; ALAM, M. M. Machine learning scopes on microgrid predictive maintenance: potential frameworks, challenges, and prospects. **Renewable and Sustainable Energy Reviews**, v. 190, p. 114088, 2024. ISSN 1364-0321. Disponível em: <<https://doi.org/10.1016/j.rser.2023.114088>>. Acesso em: 21 nov. 2023.
- ARENA, S.; FLORIAN, E.; SGARBOSSA, F.; SØLVBERG, E.; ZENNARO, I. A conceptual framework for machine learning algorithm selection for predictive maintenance. **Engineering Applications of Artificial Intelligence**, v. 133, p. 108340, 2024. ISSN 0952-1976. Disponível em: <<https://doi.org/10.1016/j.engappai.2024.108340>>. Acesso em: 15 abr. 2024.
- ARUNADEVI, M.; RANI, M.; SIBINRAJ, R.; CHANDRU, M.; DURGA PRASAD, C. Comparison of k-nearest neighbor & artificial neural network prediction in the mechanical properties of aluminum alloys. **Materials Today: Proceedings**, 2023. ISSN 2214-7853. Disponível em: <<https://doi.org/10.1016/j.matpr.2023.09.111>>. Acesso em: 11 fev. 2024.
- BERTRAND, J. W. M.; FRANSOO, J. C. Operations management research methodologies using quantitative modeling. **International Journal of Operations & Production Management**, v. 22, n. 2, p. 241–264, 2002. ISSN 0144-3577. Disponível em: <<https://doi.org/10.1108/01443570210414338>>. Acesso em: 03 jan. 2024.
- BUI TIEN, T.; VU QUANG, T.; NGUYEN NGOC, L.; TRAN NGOC, H. Time series data recovery in SHM of large-scale bridges: Leveraging GAN and Bi-LSTM networks. **Structures**, v. 63, p. 106368, 2024. ISSN 2352-0124. Disponível em: <<https://doi.org/10.1016/j.istruc.2024.106368>>. Acesso em: 01 mai. 2024.
- CAUCHICK-MIGUEL, P. A.; FLEURY, A.; MELLO, C. H. P.; NAKANO, D. N. **Metodologia de pesquisa em engenharia de produção e gestão de operações**. 3. ed. Rio de Janeiro: Elsevier, 2018. 244 p. ISBN 9788535291346.
- CHU, T.; NGUYEN, T.; YOO, H.; WANG, J. A review of vibration analysis and its applications. **Heliyon**, v. 10, n. 5, p. e26282, 2024. ISSN 2405-8440. Disponível em: <<https://doi.org/10.1016/j.heliyon.2024.e26282>>. Acesso em: 6 abr. 2024.
- DAOUTIDIS, P.; LEE, J. H.; RANGARAJAN, S.; CHIANG, L.; GOPALUNI, B.; SCHWEIDTMANN, A. M.; HARJUNKOSKI, I.; MERCANGÖZ, M.; MESBAH, A.; BOUKOUVALA, F.; LIMA, F. V.; CHANONA, A. del R.; GEORGAKIS, C. Machine learning in process systems engineering: challenges and opportunities. **Computers & Chemical Engineering**, v. 181, p. 108523, 2024. ISSN 0098-1354. Disponível em: <<https://doi.org/10.1016/j.compchemeng.2023.108523>>. Acesso em: 11 fev. 2024.
- DEGHAN SHOORKAND, H.; NOURELFATH, M.; HAJJI, A. A hybrid CNN-LSTM model for joint optimization of production and imperfect predictive maintenance planning. **Reliability Engineering & System Safety**, v. 241, p. 109707, 2024. ISSN 0951-8320. Disponível em: <<https://doi.org/10.1016/j.ress.2023.109707>>. Acesso em: 15 abr. 2024.
- DEMŠAR, J. Statistical comparisons of classifiers over multiple data sets. **Journal of Machine Learning Research**, v. 7, p. 1–30, 2006. Disponível em: <<https://www.jmlr.org/papers/volume7/demsar06a/demsar06a.pdf>>. Acesso em: 11 fev. 2024.

- DUDUKCU, H. V.; TASKIRAN, M.; CAM TASKIRAN, Z. G.; YILDIRIM, T. Temporal convolutional networks with RNN approach for chaotic time series prediction. **Applied Soft Computing**, v. 133, p. 109945, 2023. ISSN 1568-4946. Disponível em: <<https://doi.org/10.1016/j.asoc.2022.109945>>. Acesso em: 15 abr. 2024.
- ENGETELES. **Curva PF, o que é e como usa?** 2017. Disponível em: <<https://engeteles.com.br/curva-pf/>>. Acesso em: 13 abr. 2024.
- FRANCIOSI, C.; VOISIN, A.; MIRANDA, S.; RIEMMA, S.; IUNG, B. Measuring maintenance impacts on sustainability of manufacturing industries: from a systematic literature review to a framework proposal. **Journal of Cleaner Production**, v. 260, p. 121065, 2020. ISSN 0959-6526. Disponível em: <<https://doi.org/10.1016/j.jclepro.2020.121065>>. Acesso em: 25 abr. 2024.
- GÉRON, A. **Mãos à obra: aprendizado de máquina com Scikit-Learn, Keras & TensorFlow: conceitos, ferramentas e técnicas para a construção de sistemas inteligentes**. 2. ed. Rio de Janeiro: Alta Books, 2021. 329 p. ISBN 9786555208146.
- GREGÓRIO, G. F. P.; SILVEIRA, A. M. **Manutenção industrial**. 1. ed. São Paulo: Sagah Educação, 2018. 182 p. ISBN 9788595026971.
- HE, B.; MA, M.; LIU, L.; WANG, W.; YU, R. Variable stiffness-based vibration prediction for full coupling model of gearbox. **Journal of Sound and Vibration**, v. 566, p. 117922, 2023. ISSN 0022-460X. Disponível em: <<https://doi.org/10.1016/j.jsv.2023.117922>>. Acesso em: 11 fev. 2024.
- HESABI, H.; NOURELFATH, M.; HAJJI, A. A deep learning predictive model for selective maintenance optimization. **Reliability Engineering & System Safety**, v. 219, p. 108191, 2022. ISSN 0951-8320. Disponível em: <<https://doi.org/10.1016/j.res.2021.108191>>. Acesso em: 15 abr. 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://doi.org/10.1016/j.iswa.2023.200251>>. Acesso em: 15 abr. 2024.
- JAENAL, A.; RUIZ-SARMIENTO, J.-R.; GONZALEZ-JIMENEZ, J. Machnet, a general deep learning architecture for predictive maintenance within the industry 4.0 paradigm. **Engineering Applications of Artificial Intelligence**, v. 127, p. 107365, 2024. ISSN 0952-1976. Disponível em: <<https://doi.org/10.1016/j.engappai.2023.107365>>. Acesso em: 25 abr. 2024.
- KATAKE, K.; RADE, K. A.; PAWAR, A. C.; KARANDE, P. Analytical approach to suppress the vibration of spur gear pair using particle damping technique. **Materials Today: Proceedings**, v. 72, p. 1386–1393, 2023. ISSN 2214-7853. 2nd International Conference and Exposition on Advances in Mechanical Engineering (ICoAME 2022). Disponível em: <<https://doi.org/10.1016/j.matpr.2022.09.336>>. Acesso em: 6 abr. 2024.
- LIU, X.; HU, Q.; LI, J.; LI, W.; LIU, T.; XIN, M.; JIN, Q. Decoupling representation contrastive learning for carbon emission prediction and analysis based on time series. **Applied Energy**, v. 367, p. 123368, 2024. ISSN 0306-2619. Disponível em: <<https://doi.org/10.1016/j.apenergy.2024.123368>>. Acesso em: 13 mai. 2024.

- LONGO, F.; PADOVANO, A.; UMBRELLO, S. Value-oriented and ethical technology engineering in industry 5.0: A human-centric perspective for the design of the factory of the future. **Applied Sciences**, v. 10, n. 12, 2020. ISSN 2076-3417. Disponível em: <<https://doi.org/10.3390/app10124182>>. Acesso em: 15 abr. 2024.
- MALLIORIS, P.; AIVAZIDOU, E.; BECHTSIS, D. Predictive maintenance in industry 4.0: A systematic multi-sector mapping. **CIRP Journal of Manufacturing Science and Technology**, v. 50, p. 80–103, 2024. ISSN 1755-5817. Disponível em: <<https://doi.org/10.1016/j.cirpj.2024.02.003>>. Acesso em: 15 abr. 2024.
- MIAO, J.; WANG, Z.; WANG, M.; GARG, S.; HOSSAIN, M. S.; RODRIGUES, J. J. P. C. Secure and efficient communication approaches for industry 5.0 in edge computing. **Computer Networks**, v. 242, p. 110244, 2024. ISSN 1389-1286. Disponível em: <<https://doi.org/10.1016/j.comnet.2024.110244>>. Acesso em: 15 abr. 2024.
- PINCIROLI, L.; BARALDI, P.; ZIO, E. Maintenance optimization in industry 4.0. **Reliability Engineering & System Safety**, v. 234, p. 109204, 2023. ISSN 0951-8320. Disponível em: <<https://doi.org/10.1016/j.ress.2023.109204>>. Acesso em: 11 abr. 2024.
- PINTO, A. K.; XAVIER, J. N. **Manutenção: função estratégica**. 3. ed. Rio de Janeiro: Qualitymark, 2009. 361 p. ISBN 9788573038989.
- SALAMANIS, A. I.; GRAVVANIS, G. A.; KOTSIANTIS, S.; GIANNOUTAKIS, K. M. A generic sparse regression imputation method for time series and tabular data. **Knowledge-Based Systems**, v. 279, p. 110965, 2023. ISSN 0950-7051. Disponível em: <<https://doi.org/10.1016/j.knosys.2023.110965>>. Acesso em: 13 mai. 2024.
- SICSÚ, A. L.; SAMARTINI, A.; BARTH, N. L. **Técnicas de machine learning**. 1. ed. São Paulo: Blucher, 2023. 394 p. ISBN 9786555063974.
- STRUYE, J.; LATRÉ, S. Hierarchical temporal memory and recurrent neural networks for time series prediction: An empirical validation and reduction to multilayer perceptrons. **Neurocomputing**, v. 396, p. 291–301, 2020. ISSN 0925-2312. Disponível em: <<https://doi.org/10.1016/j.neucom.2018.09.098>>. Acesso em: 15 abr. 2024.
- WALLIMAN, N. **Métodos de Pesquisa**. 1. ed. São Paulo: Saraiva, 2015. 192 p. (Homem Cultura e Sociedade). ISBN 9788502629857.
- WANG, L.; ZHU, Z.; ZHAO, X. Dynamic predictive maintenance strategy for system remaining useful life prediction via deep learning ensemble method. **Reliability Engineering & System Safety**, v. 245, p. 110012, 2024. ISSN 0951-8320. Disponível em: <<https://doi.org/10.1016/j.ress.2024.110012>>. Acesso em: 7 abr. 2024.
- XU, E.; ZOU, F.; SHAN, P. A multi-stage fault prediction method of continuous casting machine based on Weibull distribution and deep learning. **Alexandria Engineering Journal**, v. 77, p. 165–175, 2023. ISSN 1110-0168. Disponível em: <<https://doi.org/10.1016/j.aej.2023.06.079>>. Acesso em: 6 abr. 2024.
- ZHONG, K.; JACKSON, T.; WEST, A.; COSMA, G. Natural language processing approaches in industrial maintenance: A systematic literature review. **Procedia Computer Science**, v. 232, p. 2082–2097, 2024. ISSN 1877-0509. 5th International Conference on Industry 4.0 and Smart Manufacturing (ISM 2023). Disponível em: <<https://doi.org/10.1016/j.procs.2024.02.029>>. Acesso em: 11 abr. 2024.