

UNIVERSIDADE DO ESTADO DO AMAZONAS

Escola Superior de Tecnologia

Graduação em Engenharia Mecânica

Wigson de Souza Bastos

**CONSTRUÇÃO DE *SCRIPT* DE PREDIÇÃO DE FALHAS EM FERRAMENTAS DE
USINAGEM UTILIZANDO O ALGORITMO DE APRENDIZAGEM DE MÁQUINA K-
VIZINHOS-MAIS PRÓXIMOS**

MANAUS

2023

WIGSON DE SOUZA BASTOS

**CONSTRUÇÃO DE *SCRIPT* DE PREDIÇÃO DE FALHAS EM FERRAMENTAS DE
USINAGEM UTILIZANDO O ALGORITMO DE APRENDIZAGEM DE MÁQUINA K-
VIZINHOS-MAIS PRÓXIMOS**

Trabalho de Conclusão de Curso de Engenharia Mecânica da Universidade do Estado do Amazonas – UEA – Campus Escola Superior de Tecnologia, como requisito para a obtenção do título de Graduação em Engenharia Mecânica

Universidade do Estado do Amazonas

Escola Superior de Tecnologia

Orientador: Prof. Dr. João Evangelista Neto

MANAUS

2023

Ficha Catalográfica

Ficha catalográfica elaborada automaticamente de acordo com os dados fornecidos pelo(a) autor(a).
Sistema Integrado de Bibliotecas da Universidade do Estado do Amazonas.

W662cc Souza Bastos, Wigson de
Construção de script de predição de falhas em ferramentas
de usinagem utilizando o algoritmo de aprendizagem de
máquina k-vizinhos-mais próximos / Wigson de Souza
Bastos. Manaus : [s.n], 2023.
36 f.: color.; 30 cm.

TCC - Graduação em Engenharia Mecânica -
Universidade do Estado do Amazonas, Manaus, 2023.
Inclui bibliografia
Orientador: Dr. João Evangelista Neto

1. Manutenção preditiva. 2. Aprendizagem de
Máquina. 3. Usinagem. I. Dr. João Evangelista Neto
(Orient.). II. Universidade do Estado do Amazonas. III.
Construção de script de predição de falhas em ferramentas de
usinagem utilizando o algoritmo de aprendizagem de
máquina k-vizinhos-mais próximos

Elaborado por Jeane Macelino Galves - CRB-11/463

WIGSON DE SOUZA BASTOS

**CONSTRUÇÃO DE *SCRIPT* DE PREDIÇÃO DE FALHAS EM FERRAMENTAS DE
USINAGEM UTILIZANDO O ALGORITMO DE APRENDIZAGEM DE MÁQUINA K-
VIZINHOS-MAIS PRÓXIMOS**

Trabalho de Conclusão de Curso de
Engenharia Mecânica da Universidade do
Estado do Amazonas – UEA – Campus
Escola Superior de Tecnologia, como
requisito para a obtenção do título de
Graduação em Engenharia Mecânica

Manaus (AM), 31 de Março de 2023

Banca de Avaliação



Prof. Dr. João Evangelista Neto

Orientador



Prof. Dr. Aristides Rivera Torres

Membro



Prof. Dr. Gilberto Garcia Del Pino

Membro

AGRADECIMENTOS

Agradeço primeiro a Deus, que me deu a oportunidade de estar vivo hoje mais um dia para que eu possa servi-lo para toda sua honra e sua glória.

Agradeço ao meu pai que meu deu todas as oportunidades necessárias para que eu pudesse chegar até aqui. Foi através de seus conselhos que descobri o valor do estudo.

Agradeço também ao meu professor orientador João Evangelista e coordenador do curso de Engenharia Mecânica que me ajudou em tudo que foi possível para que este trabalho fosse executado.

Agradeço, por fim, a todos aqueles amigos que estiveram presentes em minha vida, seja dando conselhos ou apenas me ouvindo nos momentos de dificuldades. Muitas das vezes precisamos apenas de um ouvido que possa ouvir as nossas dores e que tornaram os meus dias de dificuldade menos angustiantes.

*“As raízes do estudo são amargas, mas
seus frutos são doces.” Aristóteles*

RESUMO

Este trabalho apresenta o desenvolvimento de um algoritmo de predição de manutenção para falhas em ferramentas de usinagem com o objetivo de evitar paradas de processo por conta de quebras não previstas, melhorar a rotina de manutenção e diminuir custos de manutenções corretivas. O sistema foi desenvolvido utilizando conceitos de inteligência artificial, Inteligência de negócios, conceitos de manutenções preditivas e aprendizagem de máquina

O projeto foi desenvolvido utilizando Linguagem R para a execução do algoritmo, os dados utilizados foram baseados no banco de dados do Centro de Aprendizagem de Máquina e Sistemas Inteligentes da Universidade da Califórnia. Para a predição de falhas foram utilizados os modelos de aprendizagem supervisionado do tipo K-Vizinhos-Mais Próximos. Os resultados obtidos são apresentados.

Palavras-chave: Manutenção preditiva, aprendizado de máquina, usinagem.

ABSTRACT

This paper presents the development of a maintenance prediction algorithm for failures in machining tools with the aim of avoiding process stops due to unforeseen breakdowns, improving maintenance routines, and reducing corrective maintenance costs. The system was developed using concepts of artificial intelligence, business intelligence, predictive maintenance, and machine learning.

The project was developed using the R language to execute the algorithm, and the data used were based on the database of the Machine Learning and Intelligent Systems Learning Center at the University of California. To predict failures, supervised K-Nearest-Neighbors learning models were used. The obtained results are presented.

Keywords: *Predictive maintenance, machine learning, machining.*

LISTA DE ABREVIATURAS E SIGLAS

ABNT – Associação Brasileira de Normas Técnicas

FN – *False Negative* (Falso Negativo)

FP – *False Positive* (Falsa Positivo)

GANs – *Generative Adversarial Networks* (Redes Generativas Adversárias)

IA – Inteligência Artificial

IoT – *Internet of Things* (Internet das Coisas)

Knn – *K-Nearest-Neighbors* (k-Vizinhos-Mais Próximos)

ML – *Machine Learning* (Aprendizado de Máquina)

PCA – *Principal Component Analysis* (Análise do Componente Principal)

SVM – *Support Vectors Machine* (Máquina de Vetores de Suporte)

TN – *True Negative* (Verdadeiro Negativo)

TP – *True Positive* (Verdadeiro Positivo)

TPM – (Manutenção Preventiva Total)

UCI – *University California Irvine* (Universidade da Califórnia Irvine)

LISTA DE FIGURAS

| | |
|---|----|
| Figura 1 - Matriz de confusão..... | 15 |
| Figura 2 - Importando o dataset | 17 |
| Figura 3 - Visualização dos dados | 17 |
| Figura 4 - Dataset com os dados tratados e selecionados..... | 18 |
| Figura 5 - Carregamento da biblioteca e divisão dos dados | 18 |
| Figura 6 - Criando o modelo..... | 18 |
| Figura 7 - Aplicando a matriz de confusão ao modelo criado..... | 19 |
| Figura 8 - Matriz de confusão do modelo criado | 19 |

LISTA DE TABELAS

| | |
|--|----|
| Tabela 1 - Interpretação do modelo | 21 |
|--|----|

SUMÁRIO

| | |
|---|-----------|
| 1. INTRODUÇÃO | 2 |
| 1.1 Objetivo | 3 |
| 1.2 Justificativa..... | 4 |
| 2. REFERENCIAL TEÓRICO..... | 5 |
| 2.1 Manutenção Industrial | 5 |
| 2.1.1 Manutenção corretiva | 5 |
| 2.1.2 Manutenção preventiva..... | 6 |
| 2.1.3 Manutenção preditiva..... | 7 |
| 2.2 Usinagem industrial | 7 |
| 2.2.1 Principais técnicas de usinagem e suas ferramentas..... | 8 |
| 2.3 MACHINE LEARNING (ML) | 9 |
| 2.3.1 Conceito | 9 |
| 2.3.2 Tipos de Machine Learning | 9 |
| 2.3.3 Algoritmos de Machine Learning | 11 |
| 2.3.4 Desafios para aplicação de Machine Learning | 13 |
| 2.3.5 Validação e testes | 14 |
| 3. DESENVOLVIMENTO | 15 |
| 3.1 Obtenção dos dados | 15 |
| 3.1.1 Características dos dados contidos dentro do dataset | 15 |
| 3.2 Predição de falhas..... | 16 |
| 3.2.1 Classificação: kNN (k-Nearest-Neighbors)..... | 17 |
| 4. RESULTADOS..... | 19 |
| 4.1 Problemas enfrentados..... | 19 |
| 4.2 Como interpretar a matriz de confusão..... | 20 |
| 4.3 Interpretando o resultado para o nosso modelo | 20 |
| 5. CONCLUSÃO | 22 |
| 6.REFERÊNCIAS BIBLIOGRÁFICAS | 23 |

1. INTRODUÇÃO

A manutenção de equipamentos industriais sempre foi uma preocupação para as indústrias, desde os tempos mais antigos, quando a manutenção era realizada de forma reativa, ou seja, apenas quando algo quebrava ou falhava. Com o passar do tempo, a manutenção evoluiu para uma abordagem mais preventiva, e posteriormente para uma abordagem proativa.

Uma das primeiras vertentes de manutenção a ser desenvolvida foi a manutenção corretiva, que consiste em reparar um equipamento apenas quando ele falha. Essa abordagem era muito comum no início da revolução industrial, quando os equipamentos eram menos complexos e mais fáceis de consertar.

Na década de 1950, com o aumento da complexidade dos equipamentos industriais, começou a surgir a manutenção preventiva, que consiste em realizar inspeções e reparos programados em equipamentos antes que ocorra uma falha. Essa abordagem foi desenvolvida em resposta à necessidade de aumentar a confiabilidade dos equipamentos e reduzir o tempo de parada.

Outra vertente importante de manutenção é a manutenção preditiva, que consiste em utilizar técnicas de análise de dados e monitoramento de equipamentos para prever falhas antes que ocorram. Essa abordagem foi desenvolvida na década de 1960, com o advento da tecnologia de sensores e computação.

Na década de 1970, com o aumento da concorrência global, surgiu a manutenção produtiva total (TPM), uma abordagem holística que envolve toda a organização na manutenção dos equipamentos. O TPM é baseado na ideia de que a manutenção é responsabilidade de todos os envolvidos no processo de produção.

Nos dias atuais, a manutenção de equipamentos industriais evoluiu ainda mais, com a introdução de tecnologias como a Internet das Coisas (IoT) e a análise de big data. Essas tecnologias permitem uma abordagem ainda mais preditiva, com o monitoramento em tempo real de equipamentos e a previsão de falhas com base em análises estatísticas.

Os sistemas de manutenção baseados em inteligência artificial (IA) são uma evolução natural dessa tendência. Esses sistemas utilizam algoritmos de aprendizado de máquina para identificar padrões em grandes conjuntos de dados e prever falhas

com maior precisão. A IA também pode ser usada para otimizar a programação de manutenção, reduzindo o tempo de parada dos equipamentos e aumentando a eficiência geral do processo produtivo.

Alguns dos principais criadores de abordagens de manutenção incluem:

- Manutenção corretiva: desconhecido
- Manutenção preventiva: o engenheiro norte-americano H. Paul Barringer é frequentemente creditado como o criador da abordagem de manutenção preventiva.
- Manutenção preditiva: a abordagem foi desenvolvida em grande parte pelo engenheiro alemão Helmut Götze.
- Manutenção produtiva total: a abordagem foi desenvolvida no Japão por um grupo de empresas liderado pela Toyota.

Em resumo, a manutenção de equipamentos industriais evoluiu de uma abordagem reativa para uma abordagem proativa, com o desenvolvimento de várias vertentes de manutenção ao longo do tempo. Atualmente, a manutenção está mais integrada do que nunca com a tecnologia, permitindo uma abordagem ainda mais preditiva e eficiente. Sendo assim, o presente trabalho apresentará uma proposta de algoritmo de aprendizagem de máquina para previsão de falhas de ferramentas de usinagem.

1.1 Objetivo

O objetivo do projeto é desenvolver um algoritmo com inteligência artificial para previsão de falhas de ferramentas de usinagem utilizando parâmetros já informados em uma planilha. Com isto, criaremos um primeiro modelo de previsão que posteriormente poderá ser otimizado em futuros estudos para evitar paradas de processo, redução de custos de manutenção em ferramental e melhorar rotina da equipe de manutenção e operadores.

Os objetivos específicos do trabalho estão descritos resumidamente abaixo:

- Selecionar quais parâmetros serão utilizados para aplicar no algoritmo, realizar a limpeza dos dados e normalização;
- Desenvolver a lógica de programação utilizando linguagem R e documentar o passo-a-passo do código;

- Interpretar a matriz de confusão e apresentar o resultado.

1.2 Justificativa

A manutenção preditiva é uma abordagem importante para garantir a operação confiável e contínua de máquinas e equipamentos industriais. Com base em dados históricos e em tempo real, essa abordagem utiliza técnicas de análise de dados para identificar potenciais falhas antes que elas ocorram, permitindo que a manutenção seja realizada de forma proativa e eficaz.

As ferramentas de usinagem são um componente crítico em muitos processos industriais, e qualquer falha pode levar a paradas inesperadas, redução da eficiência ou mesmo danos ao equipamento. Portanto, é importante desenvolver um sistema de manutenção preditiva para ferramentas de usinagem que possa detectar e prever possíveis falhas.

O algoritmo de aprendizado de máquina K-Vizinhos-Mais Próximos (KNN) é uma técnica popular em aprendizado de máquina que pode ser aplicada à manutenção preditiva. Ele funciona identificando padrões em dados históricos e utilizando esses padrões para prever possíveis falhas futuras.

Ao desenvolver um trabalho deste escopo sobre um sistema de manutenção preditiva de falhas em ferramentas de usinagem utilizando o algoritmo KNN, o estudante terá a oportunidade de explorar em detalhes a aplicação dessa técnica em um contexto industrial específico. Além disso, ele poderá contribuir para a melhoria da eficiência e confiabilidade das operações de usinagem, reduzindo custos e aumentando a competitividade das empresas que utilizam esses equipamentos.

2. REFERENCIAL TEÓRICO

O objetivo deste capítulo é apresentar os fundamentos teóricos para compreensão do trabalho. Serão abordados conceitos como Manutenção Industrial, Usinagem industrial e Aprendizagem de Máquina.

2.1 Manutenção Industrial

Manutenção industrial é definida como "o conjunto de ações necessárias para manter ou restabelecer uma peça, um equipamento, um conjunto ou até mesmo uma instalação em condições de realizar suas funções com eficiência e eficácia".

Nesse sentido, a manutenção industrial tem como objetivo garantir o bom funcionamento dos equipamentos e máquinas industriais, prevenindo falhas, paradas inesperadas, reduzindo custos e aumentando a produtividade. Essas ações podem ser preventivas, corretivas ou preditivas, dependendo das necessidades específicas de cada equipamento e do tipo de operação em que estão inseridos.

A manutenção industrial é fundamental para garantir a segurança dos trabalhadores e o cumprimento das normas e regulamentações ambientais, além de maximizar o tempo de vida útil dos equipamentos e minimizar os custos de reparo e substituição. Por isso, é importante que as empresas tenham uma estratégia clara e bem definida de manutenção, incluindo planos de manutenção preventiva e preditiva, para garantir a eficiência e a competitividade no mercado industrial (ALMEIDA, 2014).

2.1.1 Manutenção corretiva

De acordo com a Associação Brasileira de Normas Técnicas - ABNT (1994, p. 7), manutenção corretiva é "manutenção efetuada após a ocorrência de uma pane destinada a recolocar um item em condições de executar uma função requerida".

A manutenção corretiva é uma ação corretiva que busca corrigir falhas ou defeitos em equipamentos ou máquinas industriais que já apresentaram problemas, com o objetivo de restabelecer sua funcionalidade normal. Em outras palavras, a manutenção corretiva ocorre após a ocorrência de um problema ou falha, e é realizada com o intuito de corrigir o problema e trazer o equipamento de volta à sua condição operacional normal.

A manutenção corretiva é geralmente realizada quando ocorrem falhas imprevisíveis e inesperadas em equipamentos ou máquinas, e pode ser classificada em dois tipos: manutenção corretiva não programada, que é realizada em caráter emergencial para corrigir uma falha inesperada, e manutenção corretiva programada,

que é realizada após uma falha ter sido identificada e avaliada, mas que pode ser agendada para um momento mais oportuno.

Embora a manutenção corretiva possa ser uma solução rápida para problemas imediatos, ela pode gerar altos custos e interrupções na produção, uma vez que é realizada de forma reativa, após a ocorrência de uma falha ou problema. Por isso, é importante que as empresas tenham uma estratégia de manutenção preventiva e preditiva bem estruturada, com o objetivo de minimizar a necessidade de manutenção corretiva e garantir a operação contínua e eficiente dos equipamentos e máquinas industriais

2.1.2 Manutenção preventiva

De acordo com a ABNT (1994, p. 7), manutenção preventiva é “manutenção realizada em intervalos pré-determinados, ou de acordo com critérios prescritos, destinada a reduzir a probabilidade de falha ou a degradação do funcionamento de um item”.

A manutenção preventiva é uma ação planejada e sistemática realizada em equipamentos ou máquinas industriais com o objetivo de prevenir ou evitar falhas, paradas inesperadas e outros problemas relacionados ao seu funcionamento.

Diferentemente da manutenção corretiva, que é realizada após a ocorrência de uma falha ou problema, a manutenção preventiva é feita de forma programada e antecipada, com base em critérios de desempenho e de tempo de vida útil dos equipamentos.

A manutenção preventiva pode ser realizada de forma periódica ou condicional, de acordo com as características dos equipamentos e das operações industriais. Na manutenção preventiva periódica, são estabelecidos planos e cronogramas para a realização de inspeções, testes e outras atividades de manutenção em intervalos regulares, independentemente do desempenho ou condições de operação dos equipamentos.

Na manutenção preventiva condicional, por outro lado, as atividades de manutenção são realizadas com base em critérios de desempenho e condições de operação dos equipamentos, como o número de horas de uso, a temperatura, a vibração, a pressão, entre outros indicadores. Assim, as atividades de manutenção são realizadas apenas quando os equipamentos atingem determinados limites ou apresentam sinais de desgaste ou degradação.

A manutenção preventiva tem como objetivo maximizar o tempo de vida útil dos equipamentos, reduzir os custos de manutenção e evitar interrupções na produção, aumentando a eficiência e a competitividade das operações industriais. Por isso, é uma estratégia importante para garantir a operação segura e eficiente dos equipamentos e máquinas industriais.

2.1.3 Manutenção preditiva

De acordo com a ABNT (1994, p. 7), manutenção preditiva é “manutenção que permite garantir uma qualidade de serviço desejada, com base na aplicação sistemática de técnicas de análise, utilizando-se de meios de supervisão centralizados ou de amostragem, para reduzir ao mínimo a manutenção preventiva e diminuir a manutenção corretiva”.

A manutenção preditiva é uma técnica de manutenção que utiliza dados e informações coletadas por sensores e sistemas de monitoramento em tempo real para prever falhas ou problemas em equipamentos e máquinas industriais.

Essa técnica permite a realização de intervenções de manutenção de forma planejada e antecipada, evitando paradas inesperadas e reduzindo os custos de manutenção.

A manutenção preditiva utiliza técnicas de análise de dados e algoritmos de aprendizado de máquina para identificar padrões de desempenho dos equipamentos e prever possíveis falhas ou degradações em seu funcionamento.

Dessa forma, a manutenção preditiva é uma técnica avançada de manutenção que permite a maximização do tempo de vida útil dos equipamentos e a melhoria da eficiência e da produtividade das operações industriais.

2.2 Usinagem industrial

Usinagem industrial é um processo de fabricação em que uma peça é moldada ou cortada a partir de um material bruto utilizando uma variedade de ferramentas e técnicas especializadas, como tornos, fresadoras, retificadoras, brochadoras, entre outras. Esse processo é comumente utilizado na produção de peças metálicas e plásticas com alta precisão e qualidade (BEZERRA, 2009).

2.2.1 Principais técnicas de usinagem e suas ferramentas

2.2.1.1 Torneamento

É uma técnica de usinagem que envolve a rotação da peça enquanto uma ferramenta de corte é aplicada para remover o material. É usado para produzir peças cilíndricas, como eixos, buchas e engrenagens. A ferramenta de corte utilizada no torneamento é a pastilha de metal duro, que pode ser usada em alta velocidade e possui diferentes geometrias para diferentes tipos de operações.

2.2.1.2 Fresamento

É uma técnica de usinagem que envolve o movimento rotativo de uma ferramenta de corte em alta velocidade para remover o material da peça. É usado para produzir superfícies planas, contornos e cavidades. As ferramentas de corte utilizadas no fresamento são as fresas, que podem ter diferentes geometrias e revestimentos para diferentes tipos de operações.

2.2.1.3 Furação

É uma técnica de usinagem que envolve a perfuração de um furo na peça utilizando uma broca de corte. É usado para produzir furos de diferentes diâmetros e profundidades em peças de diversos materiais. As brocas de corte são feitas de aço rápido ou metal duro e possuem diferentes geometrias para diferentes tipos de materiais e operações.

2.2.1.4 Rosqueamento

É uma técnica de usinagem que envolve a produção de roscas em peças cilíndricas. É usado para produzir peças com roscas internas ou externas, como parafusos e porcas. As ferramentas de corte utilizadas no rosqueamento são as machos e cossinetes, que possuem diferentes geometrias e tamanhos para diferentes tipos de roscas.

2.2.1.5 Mandrilhamento

É uma técnica de usinagem que envolve a perfuração de um furo em uma peça já usinada para produzir um furo com maior precisão dimensional. As ferramentas de corte utilizadas no mandrilhamento são as brocas de mandrilar, que possuem diferentes geometrias para diferentes tipos de operações.

Essas são apenas algumas das principais técnicas de usinagem e ferramentas de corte utilizadas na indústria. É importante ressaltar que a escolha da técnica e da

ferramenta de corte correta depende do material da peça, das dimensões e tolerâncias requeridas, e do tipo de operação que se deseja realizar.

2.3 MACHINE LEARNING (ML)

2.3.1 Conceito

Machine Learning, ou em português, Aprendizado de Máquina, é uma subárea da Inteligência Artificial que permite que as máquinas aprendam a partir de dados e experiências passadas sem serem explicitamente programadas para fazê-lo. Em outras palavras, ela se baseia em algoritmos que permitem que um sistema possa aprender com exemplos e experiências, reconhecer padrões e tomar decisões a partir dessas informações.

As vantagens da Aprendizagem de Máquina são muitas e podem ser aplicadas em diversas áreas da vida cotidiana e da indústria. Algumas das vantagens mais importantes incluem:

- **Maior precisão:** os sistemas de Aprendizagem de Máquina são capazes de analisar grandes quantidades de dados e, a partir deles, encontrar padrões e fazer previsões com uma precisão muito maior do que um ser humano seria capaz de fazer.
- **Automatização:** a Aprendizagem de Máquina permite que as tarefas repetitivas e rotineiras sejam automatizadas, liberando tempo para outras atividades mais importantes.
- **Tomada de decisão mais rápida:** a partir da análise de dados e padrões, os sistemas de Aprendizagem de Máquina podem tomar decisões com mais rapidez e eficiência do que um ser humano seria capaz.
- **Redução de custos:** a Aprendizagem de Máquina pode ajudar a reduzir os custos em diversas áreas, como no monitoramento de processos industriais e na previsão de falhas em equipamentos.
- **Personalização:** a Aprendizagem de Máquina permite a personalização de produtos e serviços, como na recomendação de produtos em sites de compras ou na criação de *playlists* personalizadas em serviços de *streaming* de música.

2.3.2 Tipos de Machine Learning

São classificados em três principais categorias segundo Géron (2017):

- **Aprendizagem Supervisionada (*Supervised Learning*):** nesse tipo de aprendizagem, o algoritmo é treinado com dados rotulados, ou seja, o modelo é alimentado com exemplos de entrada e saída esperada. A partir desses dados, ele aprende a mapear as entradas para as saídas e pode fazer previsões em novos dados. Exemplos de algoritmos de Aprendizagem Supervisionada incluem Regressão Linear, Árvores de Decisão e Redes Neurais Artificiais.
- **Aprendizagem Não Supervisionada (*Unsupervised Learning*):** nesse tipo de aprendizagem, o algoritmo é treinado com dados não rotulados, ou seja, não há informações prévias sobre as saídas esperadas. O objetivo é descobrir padrões, estruturas ou relações nos dados. Exemplos de algoritmos de Aprendizagem Não Supervisionada incluem *Clustering* (Agrupamento), Análise de Componentes Principais (PCA) e Redução de Dimensionalidade.
- **Aprendizagem por Reforço (*Reinforcement Learning*):** nesse tipo de aprendizagem, o algoritmo aprende a partir da interação com um ambiente e recebe recompensas ou penalidades de acordo com suas ações. O objetivo é maximizar a recompensa ao longo do tempo. Exemplos de aplicações de Aprendizagem por Reforço incluem jogos, robótica e controle de processos industriais.

2.3.2.1 Aprendizagem Supervisionada

A Aprendizagem Supervisionada é uma das formas de Aprendizagem de Máquina, em que o modelo é treinado com um conjunto de dados rotulados. Esse conjunto de dados consiste em exemplos de entrada e saída correspondente, e o objetivo do modelo é aprender a mapear essas entradas para suas respectivas saídas. O processo de treinamento pode ser dividido em duas etapas principais:

- Fase de treinamento: O modelo é alimentado com o conjunto de dados de treinamento e ajusta seus parâmetros para minimizar a diferença entre as saídas previstas e as saídas desejadas. Essa fase é importante para que o modelo possa generalizar e fazer previsões precisas em novos dados;
- Fase de teste: O modelo é avaliado em um conjunto de dados de teste que não foi utilizado no treinamento. O objetivo é medir o desempenho

do modelo em dados não vistos anteriormente e verificar se ele é capaz de generalizar.

Os principais modelos de Aprendizagem Supervisionada incluem:

- Regressão Linear;
- Árvores de decisão;
- Redes Neurais Artificiais;
- Máquinas de Vetores de Suporte (SVM);
- K-Vizinhos-Mais Próximos (k-NN).

2.3.2.2 Aprendizagem Não Supervisionada

A Aprendizagem Não Supervisionada é outra forma de Aprendizagem de Máquina em que o modelo é treinado com um conjunto de dados não rotulados, ou seja, não há informação sobre as saídas desejadas. O objetivo dessa abordagem é encontrar estruturas ou padrões ocultos nos dados, que podem ser usados para agrupar ou segmentar os dados. Ao contrário da Aprendizagem Supervisionada, o modelo não recebe feedback explícito sobre sua saída, e o processo de treinamento é mais exploratório.

Os principais modelos de Aprendizagem Não Supervisionada incluem:

- Agrupamento (*Clustering*);
- Análise de Componentes Principais (PCA);
- *Autoencoders*;
- Regras de Associação;
- Redes Geradoras Adversárias (GANs).

Esses modelos são usados em várias áreas, incluindo processamento de linguagem natural, visão computacional, biologia e finanças. A Aprendizagem Não Supervisionada é particularmente útil quando não há rotulagem disponível ou quando a rotulagem é cara ou demorada de se obter.

2.3.3 Algoritmos de *Machine Learning*

Os algoritmos de Aprendizagem de Máquina são métodos computacionais que permitem que um modelo aprenda a partir dos dados de entrada para realizar tarefas específicas, como classificação, regressão, agrupamento, entre outras. A seguir,

vamos focar no algoritmo de Classificação, que é utilizado para separar os dados em diferentes classes ou categorias.

2.3.3.1 k-vizinhos mais próximos (k-Nearest Neighbors – kNN)

É um algoritmo de classificação que faz uso da distância entre as instâncias para classificar novas instâncias. O algoritmo armazena todos os dados de treinamento e, ao receber uma nova instância, calcula a distância dela para cada uma das instâncias de treinamento e seleciona as k instâncias mais próximas. A classe da nova instância é determinada pela maioria das classes das k instâncias mais próximas. É utilizado em diversas áreas, como classificação de imagens, previsão de preços de imóveis, diagnóstico médico, entre outros. Neste trabalho utilizaremos para classificar as falhas em ferramentas de usinagem.

O passo a passo do algoritmo KNN pode ser descrito da seguinte maneira:

- Coleta dos dados: é necessário coletar e armazenar um conjunto de dados para ser usado como conjunto de treinamento. O conjunto de dados consiste em um conjunto de instâncias com atributos e rótulos (ou classes).
- Escolha do valor K: o valor K é o número de vizinhos mais próximos que serão utilizados para determinar a classe da nova instância a ser classificada. O valor de K pode ser escolhido empiricamente ou por meio de técnicas de validação cruzada.
- Cálculo das distâncias: o próximo passo é calcular a distância entre a nova instância e todas as outras instâncias do conjunto de treinamento. A distância pode ser calculada utilizando várias métricas, como a distância euclidiana, a distância de Manhattan, a distância de Minkowski, entre outras.
- Identificação dos K vizinhos mais próximos: após o cálculo das distâncias, o algoritmo identifica os K vizinhos mais próximos da nova instância. Esses vizinhos são os pontos que estão mais próximos da nova instância no espaço de atributos.
- Atribuição da classe da nova instância: por fim, a classe da nova instância é determinada por meio de uma votação majoritária dos rótulos das K instâncias mais próximas. Por exemplo, se a maioria dos vizinhos

próximos é da classe "A", a nova instância será classificada como sendo da classe "A".

O algoritmo KNN é simples e fácil de implementar, mas pode ser computacionalmente custoso para grandes conjuntos de dados.

2.3.4 Desafios para aplicação de *Machine Learning*

Embora o *Machine Learning* tenha se mostrado uma técnica poderosa em diversas aplicações, ainda existem alguns desafios para sua aplicação em algumas situações, como:

- **Qualidade dos dados:** a qualidade dos dados é crucial para a eficácia do *Machine Learning*. Dados imprecisos, incompletos ou mal estruturados podem prejudicar a qualidade do modelo e resultar em previsões incorretas.
- **Interpretabilidade:** muitos modelos de *Machine Learning* são complexos e difíceis de interpretar, o que pode dificultar a explicação dos resultados para os usuários.
- **Overfitting e underfitting:** o *overfitting* ocorre quando um modelo é muito complexo e ajusta-se demais ao conjunto de treinamento, levando a previsões incorretas em novos dados. O *underfitting*, por sua vez, ocorre quando um modelo é muito simples e não consegue capturar a complexidade dos dados.
- **Escalabilidade:** o *Machine Learning* pode exigir grande quantidade de recursos computacionais, o que pode tornar difícil a aplicação em larga escala.
- **Viés e discriminação:** os modelos de *Machine Learning* podem refletir o viés dos dados de treinamento e, portanto, podem ser discriminatórios em relação a certos grupos.
- **Privacidade e segurança:** o *Machine Learning* pode envolver a coleta e processamento de dados sensíveis, o que pode colocar em risco a privacidade e segurança das pessoas.
- **Regulamentação e ética:** a aplicação de *Machine Learning* pode envolver questões éticas e regulatórias, como privacidade, discriminação e responsabilidade.

É importante que esses desafios sejam abordados e considerados na aplicação de *Machine Learning* para garantir que os modelos sejam eficazes, confiáveis e éticos.

2.3.5 Validação e testes

Segundo Géron (2017), os métodos de validação e testes em *Machine Learning* são usados para avaliar o desempenho de um modelo e garantir que ele seja capaz de fazer previsões precisas em novos dados. O objetivo é avaliar a capacidade do modelo de generalizar e não apenas memorizar o conjunto de dados de treinamento.

Os métodos de validação mais comuns são a validação cruzada e a divisão do conjunto de dados em treinamento e teste. Na validação cruzada, o conjunto de dados é dividido em k subconjuntos (*k-fold cross-validation*), e o modelo é treinado e testado k vezes, usando cada um dos subconjuntos como conjunto de teste em uma das k iterações. Na divisão do conjunto de dados em treinamento e teste, uma parte do conjunto de dados é usada para treinar o modelo e a outra parte para testar o modelo.

As principais métricas de avaliação em modelos de classificação são:

- **Acurácia (*accuracy*):** é a proporção de previsões corretas em relação ao número total de previsões. É a métrica mais simples e comum, mas pode ser enganosa quando as classes são desbalanceadas.
- **Precisão (*precision*):** é a proporção de verdadeiros positivos (TP) em relação ao número total de previsões positivas (TP + FP). A precisão mede a capacidade do modelo de fazer previsões positivas corretas.
- **Revocação (*recall*):** é a proporção de verdadeiros positivos (TP) em relação ao número total de amostras positivas (TP + FN). A revocação mede a capacidade do modelo de identificar corretamente as amostras positivas.
- **F1-Score:** é a média harmônica entre precisão e revocação. É uma métrica útil quando a precisão e a revocação têm pesos iguais.
- **Matriz de confusão:** é uma tabela que mostra a contagem de previsões corretas e incorretas do modelo para cada classe. Ela permite calcular as métricas de avaliação mencionadas acima. A matriz de confusão tem

quatro elementos: verdadeiros positivos (TP), falsos positivos (FP), verdadeiros negativos (TN) e falsos negativos (FN). Os valores são dispostos na tabela da seguinte forma:

| | Classe Positiva | Classe Negativa |
|-----------------------|------------------------|------------------------|
| Prev. Positiva | TP | FP |
| Prev. Negativa | FN | TN |

Figura 1 - Matriz de confusão

A partir da matriz de confusão, pode-se calcular a acurácia, a precisão, a revocação e o F1-Score.

Neste trabalho, a métrica utilizada foi a Matriz de confusão.

3. DESENVOLVIMENTO

Para o desenvolvimento do trabalho foram necessárias algumas etapas como criação da lógica de programação do *script*, tratamento e análise dos dados do *dataset*, predição da falha e interpretação do resultado.

O desenvolvimento do projeto levou ao todo seis meses, onde foi realizada toda a pesquisa, obtenção do *dataset*, estudos sobre o algoritmo utilizado neste trabalho até a fase de construção do *script* e finalizando com a interpretação do resultado na matriz de confusão.

O detalhamento das etapas estão descritas a seguir.

3.1 Obtenção dos dados

Os dados foram obtidos no repositório de aprendizagem de máquina da Universidade da Califórnia. Particularmente, como citado no website, o *dataset* possui base sintética porém reflete os dados reais obtidos na indústria.

Neste projeto foram analisadas 10000 instâncias.

3.1.1 Características dos dados contidos dentro do *dataset*

Segundo o próprio *website* da UCI, segue as informações traduzidas para o português brasileiro:

"O conjunto de dados consiste em 10.000 pontos de dados armazenados como linhas com 14 recursos em colunas.

- ID: identificador exclusivo variando de 1 a 10000
- productID: composto por uma letra L, M ou H para baixa (50% de todos os produtos), média (30%) e alta (20%) como variantes de qualidade do produto e um número de série específico da variante.
- temperatura do ar [K]: gerada usando um processo de caminhada aleatória posteriormente normalizado para um desvio padrão de 2 K em torno de 300 K
- temperatura do processo [K]: gerada usando um processo de caminhada aleatória normalizado para um desvio padrão de 1 K, adicionado à temperatura do ar mais 10 K.
- velocidade de rotação [rpm]: calculada a partir de uma potência de 2860 W, sobreposta com um ruído distribuído normalmente.
- torque [Nm]: os valores de torque são distribuídos normalmente em torno de 40 Nm com um $\bar{f} = 10$ Nm e sem valores negativos.
- desgaste da ferramenta [min]: As variantes de qualidade H/M/L adicionam 5/3/2 minutos de desgaste da ferramenta à ferramenta usada no processo e um rótulo de 'falha da máquina' que indica se a máquina falhou neste ponto de dados específico para qualquer um dos seguintes modos de falha são verdadeiros".

3.2 Predição de falhas

Após a etapa da obtenção dos dados, foi iniciado o desenvolvimento de um modelo de predição de falha que pudesse auxiliar na tomada de decisão da equipe de manutenção sobre a necessidade de realizar uma manutenção na ferramenta de usinagem ou não.

Para isso, foram utilizados os dados com os parâmetros numéricos oferecidos no *dataset*, além do algoritmo de predição proposto nesse trabalho.

Para o desenvolvimento do algoritmo foi utilizada a linguagem R com o auxílio de uma plataforma de visualização chamada *RStudio*, ambas de código aberto e uma das linguagens muito utilizadas por Cientistas de Dados para realizar análise de dados e aplicações de algoritmos de *Machine Learning*.

3.2.1 Classificação: kNN (k-Nearest-Neighbors)

Para a construção do algoritmo de classificação foram utilizadas as bibliotecas `class` e `gmodels`.

Estas bibliotecas podem ser carregadas no início do desenvolvimento do algoritmo ou conforme o passo a passo da execução do algoritmo. Prefiro declarar somente depois, no passo a passo, para facilitar a documentação do *script*.

Abaixo, na Fig. 02, podemos verificar a primeira etapa que consiste na importação dos dados para dentro do algoritmo para começarmos a realizar o tratamento dos dados antes de procedermos com a aplicação do algoritmo.

```

1 # Predição de falha em ferramenta de usinagem
2
3 setwd("D:/TCC/estruturacao/DataSet")
4 getwd()
5
6 ## Etapa 1 - coletando os dados
7
8 dados <- read.csv("dados.csv", stringsAsFactors = FALSE)
9 str(dados)
10 view(dados)

```

Figura 2 - Importando o dataset

Na Fig. 02 podemos visualizar uma pequena amostra dos dados carregados através da função de visualização `View()`.

| | I.ID | Product.ID | Type | Air.temperature..K. | Process.temperature..K. | Rotational.speed..rpm. | Torque..Nm. | Tool.wear..min. | Target | Failure.Type |
|---|------|------------|------|---------------------|-------------------------|------------------------|-------------|-----------------|--------|--------------|
| 1 | 1 | M14860 | M | 298.1 | 308.6 | 1551 | 42.8 | 0 | 0 | No Failure |
| 2 | 2 | L47181 | L | 298.2 | 308.7 | 1408 | 46.3 | 3 | 0 | No Failure |
| 3 | 3 | L47182 | L | 298.1 | 308.5 | 1498 | 49.4 | 5 | 0 | No Failure |
| 4 | 4 | L47183 | L | 298.2 | 308.6 | 1433 | 39.5 | 7 | 0 | No Failure |
| 5 | 5 | L47184 | L | 298.2 | 308.7 | 1408 | 40.0 | 9 | 0 | No Failure |
| 6 | 6 | M14865 | M | 298.1 | 308.6 | 1425 | 41.9 | 11 | 0 | No Failure |
| 7 | 7 | L47186 | L | 298.1 | 308.6 | 1558 | 42.4 | 14 | 0 | No Failure |
| 8 | 8 | L47187 | L | 298.1 | 308.6 | 1527 | 40.2 | 16 | 0 | No Failure |
| 9 | 9 | M14868 | M | 298.3 | 308.7 | 1667 | 28.6 | 18 | 0 | No Failure |

Figura 3 - Visualização dos dados

Para que o modelo de predição seja o mais confiável possível, foi realizado o tratamento dos dados como seleção dos atributos necessários, ajuste da *tag* da variável *algo*, transformação dos tipos de variáveis numéricas para "fator", além da normalização dos dados numéricos.

Na Fig. 04 pode-se observar uma amostra do *dataset* com os dados tratados e com as variáveis selecionadas para realizarmos o treinamento do modelo.

| | Air.temperature..K. | Process.temperature..K. | Rotational.speed..rpm. | Torque..Nm. | Tool.wear..min. |
|----|---------------------|-------------------------|------------------------|-------------|-----------------|
| 1 | 0.3043478 | 0.3580247 | 0.22293364 | 0.53571429 | 0.000000000 |
| 2 | 0.3152174 | 0.3703704 | 0.13969732 | 0.58379121 | 0.011857708 |
| 3 | 0.3043478 | 0.3456790 | 0.19208382 | 0.62637363 | 0.019762846 |
| 4 | 0.3152174 | 0.3580247 | 0.15424913 | 0.49038462 | 0.027667984 |
| 5 | 0.3152174 | 0.3703704 | 0.13969732 | 0.49725275 | 0.035573123 |
| 6 | 0.3043478 | 0.3580247 | 0.14959255 | 0.52335165 | 0.043478261 |
| 7 | 0.3043478 | 0.3580247 | 0.22700815 | 0.53021978 | 0.055335968 |
| 8 | 0.3043478 | 0.3580247 | 0.20896391 | 0.50000000 | 0.063241107 |
| 9 | 0.3260870 | 0.3703704 | 0.29045402 | 0.34065934 | 0.071146245 |
| 10 | 0.3478261 | 0.4074074 | 0.33352736 | 0.33241758 | 0.083003953 |
| 11 | 0.3369565 | 0.3950617 | 0.35739232 | 0.27609890 | 0.094861660 |
| 12 | 0.3586957 | 0.4197531 | 0.14842841 | 0.55631868 | 0.114624506 |

Figura 4 - Dataset com os dados tratados e selecionados

A partir deste momento entraremos na próxima etapa de treinamento do modelo. Mas antes disso iremos separar os dados em dados de treino e dados de teste conforme o *script* da Fig. 05. Aproveitamos esta etapa e já carregamos a biblioteca *class* que contém o nosso algoritmo de classificação.

```
## Etapa 3: Treinando o modelo com KNN
# Carregando o pacote "class". Este pacote contém a função do algoritmo knn
# install.packages("class")
?class
library(class)

# Criando dados de treino e dados de teste
dados_treino <- dados_norm[1:7000, ]
dados_teste <- dados_norm[7001:10000, ]

# Criando os labels para os dados de treino e de teste
dados_treino_labels <- dados[1:7000, 6]
dados_teste_labels <- dados[7001:10000, 6]
length(dados_treino_labels)
length(dados_teste_labels)
```

Figura 5 - Carregamento da biblioteca e divisão dos dados

Agora iremos criar o modelo utilizando a função *knn()*. Na Fig. 06 podemos verificar o *script*.

```
69 # Criando o modelo
70 modelo_knn_v1 <- knn(train = dados_treino,
71                       test = dados_teste,
72                       cl = dados_treino_labels,
73                       k = 21)
```

Figura 6 - Criando o modelo

Com o modelo criado, agora iremos avaliar e interpretar o modelo.

Na Fig. 07 iremos carregar a biblioteca *gmodels* que contém a função *CrossTable()* que é justamente a nossa matriz de confusão.

```

77 ## Etapa 4: Avaliando e Interpretando o Modelo
78
79 # Carregando o gmodels
80 library(gmodels)
81 ??gmodels
82 # Criando uma tabela cruzada dos dados previstos x dados atuais
83 # Usaremos amostra com 3000 observações: length(dados_teste_labels)
84 CrossTable(x = dados_teste_labels, y = modelo_knn_v1, prop.chisq = FALSE)

```

Figura 7 - Aplicando a matriz de confusão ao modelo criado

Abaixo, na Fig. 08 observamos a matriz de confusão gerada pela função.

| dados_teste_labels | modelo_knn_v1 | | Row Total |
|--------------------|---------------|--------|-----------|
| | Falha | sFalha | |
| Falha | 5 | 56 | 61 |
| | 0.082 | 0.918 | 0.020 |
| | 0.714 | 0.019 | |
| | 0.002 | 0.019 | |
| sFalha | 2 | 2937 | 2939 |
| | 0.001 | 0.999 | 0.980 |
| | 0.286 | 0.981 | |
| | 0.001 | 0.979 | |
| Column Total | 7 | 2993 | 3000 |
| | 0.002 | 0.998 | |

Figura 8 - Matriz de confusão do modelo criado

Os Resultados das análises e discussões serão detalhadas no próximo capítulo.

4. RESULTADOS

Neste capítulo será descrito os problemas enfrentados como interpretar a matriz de confusão e o resultado do modelo na matriz.

4.1 Problemas enfrentados

Primeiramente o modelo seria desenvolvido a partir de dados reais de uma empresa no pólo de duas rodas. Porém, esses dados estavam sendo disponibilizados de forma inviável para aplicação do modelo, além da falta de suporte do setor de usinagem para que o projeto fosse realizado.

Com o problema acima citado, buscou-se uma forma de obter dados reais de outra forma na web ou através de um *dataset* que fosse o mais próximo possível de uma aplicação real. Sendo assim, graças a Universidade da Califórnia que disponibiliza dados para estudo, foi possível que esse projeto fosse dado prosseguimento.

4.2 Como interpretar a matriz de confusão

Segundo Géron (2017), uma matriz de confusão é uma tabela que mostra a frequência de acertos e erros de um modelo de classificação em relação aos dados de teste. Geralmente, ela é usada para avaliar o desempenho de um algoritmo de aprendizado de máquina ou para comparar diferentes modelos.

A matriz de confusão é dividida em quatro quadrantes: verdadeiros positivos (TP), falsos positivos (FP), falsos negativos (FN) e verdadeiros negativos (TN).

- TP: número de amostras que foram classificadas corretamente como positivas.
- FP: número de amostras que foram classificadas incorretamente como positivas.
- FN: número de amostras que foram classificadas incorretamente como negativas.
- TN: número de amostras que foram classificadas corretamente como negativas.

A interpretação da matriz de confusão depende do problema específico que está sendo analisado. No entanto, algumas métricas comuns podem ser derivadas dela, como a acurácia, a precisão, o recall e o F1-score.

No caso do nosso problema específico utilizaremos como métrica do nosso modelo, a acurácia.

4.3 Interpretando o resultado para o nosso modelo

Retomando a tabela do nosso modelo temos abaixo na tabela 1:

Tabela 1 - Interpretação do modelo

| dados_teste_labels | modelo_knn_v1 | | Row Total |
|--------------------|------------------------------|---------------------------------|---------------|
| | Falha | SFalha | |
| Falha | 5 0.082 0.714 0.002 | 56 0.918 0.019 0.019 | 61 0.020 |
| SFalha | 2 0.001 0.286 0.001 | 2937 0.999 0.981 0.979 | 2939 0.980 |
| Column Total | 7 0.002 | 2993 0.998 | 3000 |

A tabela cruzada mostra 4 possíveis valores que representam os falso/verdadeiro positivo e negativo. Temos duas colunas listando os *labels* originais nos dados observados, além de duas linhas listando os *labels* dos dados de teste.

Com isso, temos:

- Cenário 1: Célula Falha (Observado) x Falha (Previsto) - 5 casos - *true positive*
- Cenário 2: Célula Falha (Observado) x SFalha (Previsto) - 2 casos - *false positive* (o modelo errou)
- Cenário 3: Célula SFalha (Observado) x Falha (Previsto) - 56 casos - *false negative* (o modelo errou)
- Cenário 4: Célula SFalha (Observado) x SFalha (Previsto) - 2937 casos - *true negative*

Lendo a *Confusion Matrix* (Perspectiva de ter ou não uma falha):

- *True Negative* = nosso modelo previu que a ferramenta NÃO iria falhar e os dados mostraram que realmente a ferramenta não falhou
- *False Positive* = nosso modelo previu que a ferramenta iria falhar e os dados mostraram que NÃO, a ferramenta não falhou

- *False Negative* = nosso modelo previu que a ferramenta NÃO iria falhar e os dados mostraram que SIM, a ferramenta falhou
- *True Positive* = nosso modelo previu que a ferramenta iria falhar e os dados mostraram que SIM, a ferramenta falhou

Falso Positivo - Erro Tipo I

Falso Negativo - Erro Tipo II

Taxa de acerto do Modelo: 98% (acertou 2942 em 3000), ou seja, teve uma acurácia de 98%, o que é uma taxa bem alta para um modelo de predição.

5. CONCLUSÃO

Esse trabalho propôs a criação de um algoritmo utilizando aprendizagem de máquina para a manutenção preditiva de ferramentas de usinagem para prever falhas.

Os objetivos específicos foram cumpridos. A lógica foi criada, os parâmetros adequados foram selecionados e a matriz de confusão foi interpretada.

Ainda seguirá em desenvolvimento do projeto para avaliar outras métricas de negócios como redução de custo de manutenção devido a paradas inesperadas para manutenção corretiva. Também será avaliado outros modelos de classificação para comparação se ainda pode ser melhorado o *script* de predição de falha e além disso, será proposto uma ferramenta para que o modelo seja colocado em produção (*deploy*), ou seja, que o modelo possa ser acessado e utilizado pela equipe de manutenção, via *web* ou aplicativo em um computador.

6.REFERÊNCIAS BIBLIOGRÁFICAS

ALMEIDA, P. S. **Manutenção mecânica industrial: conceitos básicos e tecnologia aplicada**. São Paulo: Editora Érica, 2014.

ALPAYDIN, Ethem. **Introduction to machine learning**. MIT press, 2020.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. ABNT NBR-5462: **Confiabilidade e Manutenibilidade**. Rio de Janeiro. 1994.

BARROS, B. A. **A Importância da Manutenção Industrial Como Ferramenta Estratégica de Competitividade**. Faculdade Redentor, Miracema – Rio de Janeiro. Disponível em:< <http://docplayer.com.br/30487605-A-importancia-da-manutencao-industrial-como-ferramenta-estrategica-de-competitividade.html> >. Acesso em 12 de agosto de 2022

BEZZERRA, M. C. T.; et al. **Processos de usinagem: usinagem convencional e CNC**. Campinas: Universidade Estadual de Campinas, Faculdade de Engenharia Mecânica, Departamento de Engenharia de Fabricação, 2009. 144 p.

BUKSH, Z. A. et al, **Predictive maintenance using tree-based classification techniques: A case of railway switches**, *Transportation Research Part C: Emerging Technologies*, Volume 101, 2019.

BUKSH, Z. A.; SAEED, A.; STIPANOVIC, I. **A machine learning approach for maintenance prediction of railway assets**. Proceedings of 7th Transport Research Arena TRA 2018, April 16-19, 2018, Vienna, Austria

CINAR, Z. M. et al. **Machine Learning in Predictive Maintenance towards Sustainable Smart Manufacturing in Industry 4.0**. 2020.

DUA, D. and Graff, C. (2019). **UCI Machine Learning Repository** Irvine, CA: University of California, School of Information and Computer Science. Disponível em: <<http://archive.ics.uci.edu/ml>>. Acesso em 12 de outubro de 2022.

FILHO, M. **As Métricas Mais Populares para Avaliar Modelos de Machine Learning** [s.d]. Disponível em: < <https://www.mariofilho.com/as-metricas-mais-populares-para-avaliar-modelos-de-machine-learning/> >. Acesso em 12 de agosto de 2022.

FOGLIATTO, F. S.; RIBEIRO, J. L. D. **Confiabilidade e Manutenção Industrial**. Rio de Janeiro: Editora Elsevier, 2009

GÉRON, A. **Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow**. 2019. Published by O'Reilly Media, Inc., 1005 Gravenstein Highway North, Sebastopol, CA 95472.

GOODFELLOW, Ian et al. **Deep learning**. MIT press, 2016.

GROOVER, Mikell P. **Fundamentos de manufatura moderna**. 4ª edição. São Paulo: Pearson Prentice Hall, 2010.

ILEOH. Introdução A Clusterização E Os Diferentes Métodos. **Portal Data Science**. 2018. Disponível em: <<https://portaldatascience.com/introducao-a-clusterizacao-e-os-diferentes-metodos/>>. Acesso em: 15 de agosto de 2022.

JAKRA A. Husain. " **Modelling of Industrial Machine Structure for Predictive Maintenance Using IoT Sensor Data and Machine Learning: A Review**." IOSR Journal of Electronics and Communication Engineering (IOSR-JECE) 14.2 (2019): 16-21.

JORDAN, Michael I.; MITCHELL, Tom M. **Machine learning: Trends, perspectives, and prospects**. Science, v. 349, n. 6245, p. 255-260, 2015.

KALATHAS, I.; PAPOUTSIDAKIS, M. **Predictive Maintenance Using Machine Learning and Data Mining: A Pioneer Method Implemented to Greek Railways**. Designs 2021

MMTEC, **Manutenção Preditiva e Industria 4.0**, Artigo técnico, MMTec Inspeções Industriais, Disponível em: <<http://www.mmtec.com.br/manutencao-preditiva-e-industria-4-0/>>, Acesso em: 20 de agosto de 2022.

MORAIS, Bruna Corrêa. **Sistema integrado de análise e predição de indicadores de desempenho de um processo industrial**. 2019. 90 f. Trabalho de Conclusão de Curso (Graduação em Engenharia de Controle e Automação) - Universidade Federal de Uberlândia, Uberlândia, 2020.

MOUSAVI, Seyed Ehsan; BOZORGMEHR, Ali; ARASHLOO, Reza Soleymani. **Condition-based maintenance decision making using machine learning algorithms: a review**. **Mechanical Systems and Signal Processing**, v. 142, p. 106783, 2021.

NAVARRO, A.F. **Gestão de Manutenção Industrial**. São Paulo: Editora Érica, 2015

PINTO, Marcela Coury. **Sistema de manutenção preditiva de falhas em válvulas em um processo industrial utilizando inteligência artificial**. 2021. 77 f. Trabalho de

Conclusão de Curso (Graduação em Engenharia de Controle e Automação) - Universidade Federal de Uberlândia, Uberlândia, 2021.

NAKAJIMA, S. **Introdução ao TPM - Total Productive Maintenance**. São Paulo: IMC Internacional Sistemas Educativos Ltda., 1989. PEREIRA, Décio Martins. **Manutenção Industrial**. São Paulo: Fundação de Apoio à Escola Técnica Centro de Ensino Técnico e Profissionalizante Quintino – E.T.E.R. – Mecânica, 2004.

SANTANA, F. **Entenda o Algoritmo K-means e Saiba como Aplicar essa Técnica. 2017. Minerando Dados**. Disponível em: <<https://minerandodados.com.br/entenda-o-algoritmo-k-means/>>. Acesso em 12 de outubro de 2022.

TEIXEIRA, Ricardo R. **Manutenção Industrial**. Rio de Janeiro: Editora Elsevier, 2017