

Inteligência Artificial

SLTINTA

Profº José W. R. Pereira
jose.pereira@ifsp.edu.br
josewrpereira.github.io/docs



Índice

- Inteligência Artificial e Aprendizado de Máquina
- Histórico e Evolução
- Propósitos e Métodos na Indústria
- Métodos na Indústria - Manutenção Preditiva (PdM)
- Desvendando o aprendizado de máquina
- Conceitos Iniciais de Aprendizado de Máquina
- Ecossistema Python
- Aprendizado de Máquina no Mundo Real

Inteligência Artificial e Aprendizado de Máquina (ML - *Machine Learning*)

Inteligência Artificial - Machine Learning (ML)

Aprendizado de Máquina é o motor tecnológico atual, ferramenta essencial para converter o vasto volume de dados brutos gerados pela sociedade em **conhecimento estratégico e previsões acionáveis**, ou seja, que permitam a tomada de decisão direta, útil e estratégica.

Contexto, a natureza e a abrangência dessa tecnologia:

1. **A Magnitude do "Dilúvio de Dados"**: Lidar com um volume massivo de informações produzidas, estimado em **2,5 quintilhões de bytes diariamente**.
2. **Mecanismo de Funcionamento**: ML baseia-se em **algoritmos que detectam padrões de forma automática**, permitindo a predição de eventos futuros ou resultados de interesse sem a necessidade de programação explícita para cada tarefa.
3. **Versatilidade e Aplicabilidade**: A tecnologia é **essencial e multidisciplinar**, com aplicações práticas que variam desde domínios científicos complexos, como a **biologia molecular**, até áreas da engenharia, como a **robótica**.

ML: Histórico e Evolução

Década de 1940

O nascimento da ideia

- Warren McCulloch e Walter Pitts (1943) criaram o conceito de neurônio artificial, estabelecendo a base lógica para a atividade nervosa.


(MCCULLOCH; PITTS, 1943)



Warren McCulloch



Walter Pitts



O neurônio artificial:
base da computação cognitiva

Décadas de 1940/50

Da ideia ao aprendizado

- Donald Hebb (1949) propôs que conexões entre neurônios se fortalecem com o uso.
- Frank Rosenblatt (1957) desenvolveu o Perceptron, o primeiro modelo capaz de aprender pesos de forma automática para classificação.


(GÉRON, 2019; ROSENBLATT, 1958)



Donald Hebb



Frank Rosenblatt



Perceptron: aprende pesos
para classificar dados

ML: Histórico e Evolução

Lacunas e “Invernos”

- O interesse na IA diminuiu após 1969, quando Minsky e Papert provaram que modelos lineares simples não resolviam problemas complexos como o XOR (MURPHY, 2022).

(MURPHY, 2022)



Marvin
Minsky



Seymour
Papert

Exemplo: problema XOR

x_1	x_2	XOR (y)
0	0	0
0	1	1
1	0	1
1	1	0

Modelos lineares
não conseguem
resolver o XOR

Renascimento

- Em 1986, o algoritmo de *backpropagation* tornou possível treinar redes neurais com múltiplas camadas ocultas, abrindo caminho para modelos mais poderosos.

(GÉRON, 2019; RUMELHART; HINTON; WILLIAMS, 1986)




David
Rumelhart



Geoffrey
Hinton



Ronald
Williams



Backpropagation: treina redes com múltiplas camadas

ML: Histórico e Evolução

Atualidade – A Revolução do Deep Learning

- Atualmente, vivemos a “revolução do Deep Learning”, viabilizada pela abundância de dados e pelo poder de processamento massivo das GPUs, que permitem treinar modelos cada vez mais profundos e capazes.


(GÉRON, 2019)



Abundância
de Dados



Poder de Processamento
das GPUs




Modelos Profundos
Mais Inteligentes

Propósitos e Métodos na Indústria

O Aprendizado de Máquina (**ML**) tem se mostrado **fundamental** na indústria moderna, atuando como um dos elementos centrais da **Indústria 4.0** ao **transformar grandes volumes de dados em ganhos de eficiência, segurança e lucratividade**.

A **manutenção preditiva (PdM - *Predictive Maintenance*)** é um cenário real onde a aplicação dessa tecnologia gerou resultados expressivos ao utilizar sensores e algoritmos para **prever falhas** antes que elas ocorressem, calculando a **Vida Útil Restante (RUL - *Remaining Useful Life*)** dos componentes.

Métodos na Indústria - Manutenção Preditiva (PdM)




Métodos na Indústria - Manutenção Preditiva (PdM)

1 Caso Bosch (2016)

A empresa investiu cerca de R\$ 46 mil no monitoramento inteligente de sete linhas de produção. O resultado foi um retorno financeiro de R\$ 65 mil logo no primeiro ano, superando o investimento inicial através da prevenção de paradas.

(INDUSTRIA 4.0, 2020)



Investimento

R\$ 46 mil



Retorno (1º ano)

R\$ 65 mil



Resultado

Retorno maior
que o investimento
e prevenção
de paradas



Métodos na Indústria - Manutenção Preditiva (PdM)

2 Indústria de Embalagens Plásticas

Um sistema de IA identificou uma falha iminente com 62 dias de antecedência via e-mail. Isso permitiu que a equipe técnica emitisse uma ordem de serviço planejada, evitando uma interrupção catastrófica e inesperada na produção.

(INDUSTRIA 4.0, 2020)



- ✓ Detecção antecipada com 62 dias
- ✓ Ordem de serviço planejada
- ✓ Evita interrupção catastrófica
- ✓ Menor impacto na produção

Métodos na Indústria - Manutenção Preditiva (PdM)

3 Monitoramento de Equipamentos Rotativos

Empresas como a Encopel utilizam análise de vibração e temperatura para identificar desalinhamentos e falhas em rolamentos. Isso resulta no aumento da vida útil das máquinas, redução do estoque de peças sobressalentes e eliminação de horas extras para reparos emergenciais.

(ENCOPEL ROLAMENTOS, 2020)



- ✓ Identificação de desalinhamentos e falhas em rolamentos
- ✓ Aumento da vida útil das máquinas
- ✓ Redução do estoque de peças
- ✓ Eliminação de horas extras e reparos emergenciais

Ganhos de Produção e Controle de Qualidade

Além de prever falhas, o ML é utilizado para otimizar processos e garantir a qualidade dos produtos com o mínimo de desperdício.

- **Detecção de Defeitos por Visão Computacional:** estratégia de "zero defeitos".
- **Competitividade e Produtividade:** preços menores devido ao uso de tecnologias 4.0 produzem **ganho de produtividade**.
- **Diagnóstico de Falhas em Plantas Industriais:** Modelos probabilísticos aplicados para diagnosticar falhas em sistemas complexos de tanques e tubulações, identificando vazamentos ou bloqueios através de medições ruidosas de fluxo e pressão.

Aplicações em Robótica e Dispositivos Médicos

- **Controle de Braços Robóticos:** Modelos de regressão não-linear são usados para prever o torque exato que cada articulação de um robô deve aplicar para alcançar um ponto no espaço, otimizando o movimento e a precisão (MURPHY, 2012).
- **Próteses e Dispositivos de Saúde:** Pesquisas brasileiras demonstram o uso de ML para o **controle de próteses robóticas de membros superiores** através de sinais de EEG, atingindo 90% de precisão (SANTOS et al., 2025). Além disso, sistemas embarcados inteligentes são usados para o controle fisiológico de **dispositivos de assistência ventricular** (bombas cardíacas) (SANTOS et al., 2025).

Direcionamento Futuro

Manutenção Prescritiva: Evoluir da predição para a prescrição.

AutoML: A automação do próprio design de sistemas de ML para reduzir a dependência de intervenção humana constante.

IA Ética e Alinhamento: Foco em resolver o "**problema do alinhamento**", garantindo que os objetivos dos algoritmos estejam em total conformidade com os valores e a segurança humana.


Resultados Industriais: No Brasil, estima-se que apenas **1,6% das indústrias** estejam plenamente inseridas na Revolução 4.0, indicando um vasto campo para crescimento.

Desvendando o Aprendizado de Máquina

Desvendando o aprendizado de máquina


1 Camada de Borda e Instrumentação

- Extração de sinais físicos (temperatura, vibração) dos ativos.
- ESP32 + programação em C++.
- Conversão analógico-digital (ADC) e calibração dos sensores.
- Serialização dos dados em JSON: garantia da fidelidade da telemetria antes do envio para a nuvem.



2 Infraestrutura e Engenharia de Dados


- Transporte dos dados via MQTT (Publish/Subscribe).
- Gateways em Python processam fluxo assíncrono.
- Persistência cronológica em SQLite.
- Repositório estável e limpo para modelagem analítica.



Desvendando o aprendizado de máquina


3 Inteligência Artificial e Diagnóstico

- **PCA:** redução de dimensionalidade e visualização da saúde da máquina em 2D.
- **SVM e Random Forest:** classificação com classes desbalanceadas e Feature Importance.
- Identificação dos atributos que aceleram a degradação mecânica.



4 Modelagem de Falhas e Anomalias

- **LSTM:** previsão de falhas com horas de antecedência usando séries temporais.
- **Autoencoders:** detecção não supervisionada; falha quando MSE de reconstrução excede limite seguro.
- **Aprendizado por Reforço:** agentes ajustam o ESP32 usando Processos de Decisão de Markov e Equação de Bellman para maximizar eficiência com recompensas e punições.



Desvendando o aprendizado de máquina

5

Integração de Sistemas (End-to-End)

- Dashboard web em Streamlit com inferências em tempo real a partir do SQLite.
- Validação por simulações de estresse: auditoria da latência e reconexão automática do Wi-Fi diante de anomalias.



Resultado: Manutenção Preditiva Inteligente




Conceitos Iniciais de Aprendizado de Máquina

Conceitos iniciais de ML

O **Aprendizado de Máquina (Machine Learning - ML)** é definido como o campo de estudo que dá aos computadores a capacidade de aprender sem serem explicitamente programados (Samuel, 1959 apud GÉRON, 2019).

Em uma perspectiva de engenharia, um programa **aprende a partir da experiência (dados)** em relação a **uma tarefa e uma medida de desempenho, caso seu desempenho nessa tarefa melhore com a experiência** (MITCHELL, 1997 apud GÉRON, 2019).

Tipos de Aprendizado



Dados: Atributos, Amostras e Divisão

Samples


Amostras: Instância, observação

	Sepal length	Sepal width	Petal length	Petal width	Class label
1	5.1	3.5	1.4	0.2	Setosa
2	4.9	3.0	1.4	0.2	Setosa
...					
50	6.4	3.5	4.5	1.2	Versicolor
...					
150	5.9	3.0	5.0	1.8	Virginica

Features

Características: Atributos, medições, dimensões

Petal



Sepal

Class labels


Rótulos

Matriz de representação
do conjunto de dados

Dataset

$$\begin{bmatrix} x_1^{(1)} & x_2^{(1)} & x_3^{(1)} & x_4^{(1)} \\ x_1^{(2)} & x_2^{(2)} & x_3^{(2)} & x_4^{(2)} \\ \vdots & \vdots & \vdots & \vdots \\ x_1^{(150)} & x_2^{(150)} & x_3^{(150)} & x_4^{(150)} \end{bmatrix}$$

Conjuntos de Treinamento, Validação e Teste



Conjuntos de Treinamento, Validação e Teste

Conjunto de dados

Partições clássicas

Treinamento

Validação

Teste

Cross-validation

Partição 1

Partição 2

Partição 3

Partição 4

Rodada 1

Partição 1

Partição 2

Partição 3

Partição 4

Rodada 2

Partição 1

Partição 2

Partição 3

Partição 4

Rodada 3

Partição 1

Partição 2

Partição 3

Partição 4

Rodada 4

Partição 1

Partição 2

Partição 3


Partição 4

Treinamento e seleção de
hiper-parâmetros

Teste final

Teste

Fluxo de Trabalho para Sistemas de ML




Generalização, *Overfitting* e *Underfitting*

1 OVERFITTING (SOBREAJUSTE)

O modelo é muito complexo e "decora" o ruído dos dados de treinamento, mas não consegue generalizar bem para novos dados.

(MURPHY, 2012; DAUMÉ III, 2017; RASCHKA, 2015)




Alto Erro
(no teste)
Alta Variância



2 UNDERFITTING (SUBAJUSTE)

O modelo é simples demais e não consegue aprender a estrutura dos dados, resultando em baixo desempenho tanto no treino quanto no teste.

(GÉRON, 2019; DAUMÉ III, 2017)



Alto Erro
(no treino
e teste)
Alto Viés




Generalização, *Overfitting* e *Underfitting*

3 BIAS/VARIANCE TRADEOFF

É o equilíbrio entre o viés (erro por suposições erradas / modelo simples demais) e a variância (erro por sensibilidade excessiva a pequenas variações nos dados / modelo complexo demais).

(GÉRON, 2019)



Existe um **ponto ótimo** onde o erro total é mínimo: equilíbrio entre viés e variância



EM RESUMO



Generalizar para dados novos



Equilíbrio entre viés e variância



Modelo simples demais = alto viés (underfitting)



Modelo complexo demais = alta variância (overfitting)



Melhor desempenho em dados não vistos

O sucesso do ML está em construir modelos que aprendem padrões reais, mas não o ruído.



Funções de Perda e Hiperparâmetros

1 FUNÇÃO DE PERDA (LOSS FUNCTION)


A função de perda mede o quão ruim é a previsão do modelo em relação ao valor real. O objetivo do treinamento do modelo é minimizar essa perda.

(MURPHY, 2022; DAUMÉ III, 2017)

$$\begin{array}{ccc} \text{Valor Real (y)} & & \text{Previsão do Modelo (\hat{y})} \\ \text{10} & - & 7 \\ \text{(Exemplo)} & & \text{(Exemplo)} \end{array} = \begin{array}{c} \text{Erro (Perda)} \\ 3 \\ \text{(Diferença)} \end{array}$$

Função de Perda (Exemplos)

- Erro Quadrático Médio (MSE) (quanto menor, melhor)
- Entropia Cruzada (para classificação) (quanto menor, melhor)



O objetivo é chegar ao mínimo!

2 HIPERPARÂMETROS

São parâmetros definidos ANTES do treinamento e que permanecem constantes durante o processo. Eles controlam o comportamento do algoritmo, como "botões de ajuste" do modelo.

(GÉRON, 2019; RASCHKA, 2015; SANTOS et al., 2025)

Exemplos de Hiperparâmetros



Botões de Ajuste do Modelo




Como funciona o treinamento



Ecosystem Python



Aprendizado de Máquina no Mundo Real



De Falha e Prejuízo à Inteligência e Prevenção

Transformando dados em decisões que evitam paradas e geram vantagem competitiva.

Você foi contratado como Engenheiro de IA por uma grande planta siderúrgica que opera 24 horas por dia. O principal ativo da fábrica é uma estação de usinagem CNC de alto desempenho. Recentemente, a quebra inesperada do cabeçote de corte dessa máquina causou uma parada na linha de produção que durou 36 horas, gerando um prejuízo estimado em R\$ 150.000,00 entre peças de reposição urgentes, ociosidade da equipe e multas por atraso na entrega dos produtos aos clientes.

A gerência de manutenção possui sensores que medem variáveis físicas da máquina a cada segundo, mas atualmente esses dados são apenas visualizados em telas isoladas e descartados. O seu desafio no semestre é interligar essa telemetria e criar um sistema inteligente capaz de prever uma falha mecânica com antecedência, permitindo que a equipe agende o reparo durante uma pausa planejada de produção.

O PROBLEMA



Parada: 36 horas



Prejuízo: R\$ 150.000,00



Custo da falha inesperada

ESTAÇÃO CNC – ATIVO CRÍTICO



SENSORES (1 leitura a cada segundo)



Temperatura




Vibração



Rotação



TELEMETRIA EM TEMPO REAL



ATUALMENTE

- Dados visualizados em telas isoladas
- Dados descartados



Aprendizado de Máquina no Mundo Real

1 Entendimento do Negócio e dos Dados (CRISP-DM)

- **Entendimento do negócio:** evitar paradas de 36 horas e os custos associados.
- **Entendimento dos dados:** telemetria rica (a cada segundo), atualmente descartada.
- **Integração:** criação do registro histórico para treinamento dos modelos.



(LET'S DATA, 2021; POD ACADEMY, 2023;
ENCOPEL ROLAMENTOS, 2020; BOUSDEKIS et al., 2019)

2 Atributos (Features) e Processamento

Transformamos as leituras brutas em atributos úteis.

- **Exemplos:** média da temperatura na última hora, pico de frequência de vibração, desvio padrão da vibração, etc.
- **Normalização:** garante que variáveis em escalas diferentes tenham o mesmo peso no modelo.


DADOS BRUTOS

Temp (°C)	Vibração (g)	Rotação (RPM)
37,2	0,82	1800
37,5	1,05	1820
37,1	0,77	1780
...	...	...

ATRIBUTOS (FEATURES)

Média Temp	Pico Vib.	Std Vib.	Rotação (Norm.)
36,9	1,35	0,23	0,72
37,2	1,60	0,30	0,76
36,8	1,10	0,21	0,70
...	...	...	...

NORMALIZAÇÃO




(GÉRON, 2019; RASCHKA, 2015; SANTOS et al., 2025)

3 Tipos de Aprendizado e Modelagem

Regressão (Supervisionado)

Prever RUL (Vida Útil Restante)
Exemplo: prever que falha ocorrerá em 48 horas.



Classificação (Supervisionado)

Estado da Máquina
Normal ou Em Risco




Normal



Em Risco

Deteção de Anomalias (Não Supervisionado)


Detecta desvios sem falhas conhecidas
Alerta preventivo



(BOUSDEKIS et al., 2019; GÉRON, 2019; MURPHY, 2022)

4 Generalização, Overfitting e Underfitting

- **Generalização:** o modelo deve funcionar em dados novos.
- **Overfitting:** modelo muito complexo que "decora" o ruído.
- **Underfitting:** modelo muito simples que não captura padrões.
- **Solução:** divisão dos dados em treino, validação e teste.



(GÉRON, 2019; RASCHKA, 2015; DAUMÉ III, 2017; MURPHY, 2022)

Aprendizado de Máquina no Mundo Real

5 Métricas de Avaliação

O custo da falha (Falso Negativo) é altíssimo.



Recall (Sensibilidade)

Detectar todas as falhas possíveis é essencial.

$$\text{Recall} = \frac{TP}{TP + FN}$$



Precisão

Evitar alarmes falsos para manter a confiança da equipe.

$$\text{Precisão} = \frac{TP}{TP + FP}$$

TP: Verdadeiro Positivo FP: Falso Positivo FN: Falso Negativo TN: Verdadeiro Negativo
(GÉRON, 2019; SANTOS et al., 2025; ENCOPEL ROLAMENTOS, 2020; BOUSDEKIS et al., 2019)

6

Direcionamento: Da Predição à Prescrição

Do alerta à ação inteligente, gerando recomendações.

Predição



"Cabeçote falhará em 10 horas"



Prescrição

"Reduza a velocidade de corte em 20% para estender a vida útil até a próxima pausa planejada"

Benefícios



- ✓ Menos paradas
- ✓ Menos custos
- ✓ Mais segurança
- ✓ Mais produtividade

(ENCOPEL ROLAMENTOS, 2020; BOUSDEKIS et al., 2019)

O CICLO INTELIGENTE EM AÇÃO



Dados
(Sensores)



Coleta e
Transmissão
(MQTT)



Armazenamento
(SQLite)



Modelos de ML
(Predição, Classificação,
Anomalias)



Decisões e
Ações



Menos Paradas
Mais Eficiência



O RESULTADO: Manutenção Preditiva Inteligente



Paradas Evitadas



Custos Reduzidos



Produção Contínua




Decisões Baseadas em Dados



Competitividade

Resumindo



Referências

- AHELEROFF, S. et al. A Digital Twin-Driven Predictive Maintenance Architecture for IoT-Enabled Manufacturing. **Advanced Engineering Informatics**, v. 45, p. 101102, 2020. (Aheleroff et al., 2020).
- ARENA, F. et al. An IoT-Based Predictive Maintenance Architecture for Industrial Equipment. **Sensors**, v. 22, n. 2, p. 485, 2022. (Arena et al., 2022).
- BOUSDEKIS, Alexandros; APOSTOLOU, Dimitris; MENTZAS, Gregoris. **Predictive maintenance in the 4th industrial revolution**: benefits business opportunities and managerial implications. [S. l.]: [s. n.], 2019.
- CHEN, B. et al. Edge Computing-Based Predictive Maintenance System for IoT Smart Factories. **IEEE Access**, v. 7, p. 29321-29334, 2019. (Chen et al., 2019).
- CHRISTIAN, Brian. **The alignment problem**: machine learning and human values. 1. ed. [S. l.]: W. W. Norton & Company, 2020.
- DALZOCHIO, J. et al. Predictive Maintenance in the Fourth Industrial Revolution: A Literature Review. **Computers & Industrial Engineering**, v. 142, p. 106486, 2020. (Dalzochio et al., 2020).
- ENCOPEL ROLAMENTOS. **Webinar**: manutenção preditiva na indústria 4.0. [S. l.]: Youtube, 2020. Disponível em: <https://www.youtube.com/watch?v=A8f9D590p8c>. Acesso em: 8 jul. 2026.
- ERHAN, L. et al. Anomaly Detection in Industrial Telemetry Data Using Unsupervised Machine Learning. **Journal of Ambient Intelligence and Humanized Computing**, v. 12, p. 3152-3164, 2021. (Erhan et al., 2021).
- GARCIA, G.; ALBALADEJO, C.; MOLINA, J. M. Low-Cost IoT Sensor Node for Predictive Maintenance in Industrial Environments. **Electronics**, v. 10, n. 11, p. 1289, 2021. (Garcia; Albaladejo; Molina, 2021).

Referências

GÉRON, Aurélien. **Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow**: concepts, tools, and techniques to build intelligent systems. 2. ed. [S. l.]: O'Reilly Media, 2019.

INDUSTRIA 4.0. **Manutenção Preditiva On-Line - Industria 4.0**. [S. l.]: Youtube, 2020. Disponível em: <https://www.youtube.com/watch?v=Fst5jZ8v7I8>. Acesso em: 8 jul. 2026.

KUMAR, A.; SINGH, S. Predictive Maintenance Using AI4I 2020 Dataset: A Comparative Study of Machine Learning Classifiers. **Procedia Computer Science**, v. 218, p. 211-220, 2023. (Kumar; Singh, 2023).

LET'S DATA. **CRISP-DM**: a melhor metodologia para projetos de Data Science. [S. l.]: Youtube, 2021. Disponível em: <https://www.youtube.com/watch?v=fV7i6U-0Q7M>. Acesso em: 8 jul. 2026.

MCCULLOCH, Warren S.; PITTS, Walter. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, [S. l.], v. 5, p. 115-133, 1943.

MURPHY, Kevin P. **Machine learning**: a probabilistic perspective. [S. l.]: MIT Press, 2012.

MURPHY, Kevin P. **Probabilistic machine learning**: an introduction. [S. l.]: MIT Press, 2022.

PANORAMA da Indústria 4.0 no Brasil e os impactos no mercado de trabalho | Transição. [S. l.]: Youtube, 2022. Disponível em: https://www.youtube.com/watch?v=q6O2O9eZ1_I. Acesso em: 8 jul. 2026.

POD ACADEMY | DATA & ANALYTICS. **Aprenda a metodologia CRISP-DM para tomada de decisão data-driven [Webinar PoD Academy]**. [S. l.]: Youtube, 2023. Disponível em: <https://www.youtube.com/watch?v=C7QYm0fL2vA>. Acesso em: 8 jul. 2026.

Referências

PREDICTIVE maintenance in the 4th industrial revolution: benefits business opportunities and managerial implications. [S. l.]: [s. n.], 2019.

RASCHKA, Sebastian. **Python machine learning**. Birmingham: Packt Publishing, 2015.

ROSENBLATT, Frank. The Perceptron: a probabilistic model for information storage and organization in the brain. **Psychological Review**, [S. l.], v. 65, n. 6, p. 386-408, 1958.

RUMELHART, David E.; HINTON, Geoffrey E.; WILLIAMS, Ronald J. Learning internal representations by error propagation. **Nature**, [S. l.], v. 323, p. 533-536, 1986.

RUSSELL, Stuart. **Human compatible:** artificial intelligence and the problem of control. [S. l.]: Viking, 2019.

SANTOS, Bruno J. et al. Electroencephalogram Signal Acquisition System with Machine Learning for Robotic Prosthesis Control: In Vivo Dataset. **Artificial Intelligence and Applications**, [S. l.], v. 00, n. 00, p. 1-22, 2025. DOI: 10.47852/bonviewAIA52024252.

SANTOS, R. et al. Imbalanced Data Treatment in Predictive Maintenance Machine Learning Models. **Applied Sciences**, v. 11, n. 18, p. 8542, 2021. (Santos et al., 2021).

SCHMIDT, M. et al. Interactive Dashboards for Predictive Maintenance: User-Centered Design in Industry 4.0. **International Journal of Industrial Ergonomics**, v. 89, p. 103310, 2022. (Schmidt et al., 2022).

ZONTA, T. et al. Machine Learning for Predictive Maintenance in Industry 4.0: A Review. **International Journal of Production Research**, v. 58, n. 18, p. 5766-5784, 2020. (Zonta et al., 2020).

Referências

Este material foi produzido com auxílio de ferramentas de Inteligência Artificial:



Inteligência Artificial

INTA

Profº José W. R. Pereira

jose.pereira@ifsp.edu.br

josewrpereira.github.io/docs

