



ConBRepro

XIII CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO



IA nas Engenharias

29 nov. a 01
de dezembro 2023

A Utilização de Redes Neurais na Previsão de Falhas de Equipamentos Mecânicos

Weslen Rian Pedro da Silva

Ponta Grossa - Unicesumar

Ian Carlos Silveira

Ponta Grossa - Unicesumar

Sabine Cassol

Ponta Grossa - Unicesumar

Flávia Sayuri Arakawa

Ponta Grossa - Unicesumar

Resumo: As redes neurais artificiais (RNA) são consideradas uma ferramenta promissora no campo da previsão de falhas em equipamentos mecânicos, possuindo a capacidade de discernir padrões complexos nos dados, que podem servir como indicadores precoces de problemas iminentes. O artigo apresenta como objetivo mostrar como a Inteligência Artificial treinada através de redes neurais pode ser usada para prevenir e antecipar falhas, assegurando a utilização segura do equipamento. Realizou-se pesquisas bibliográficas exploratórias existentes sobre a utilização de redes neurais com o objetivo de prever tais falhas, abrangendo artigos de pesquisa provenientes de diversas áreas, incluindo engenharia, ciência da computação e inteligência artificial. As redes neurais se mostram eficazes nessa previsão, com o potencial de aumentar a precisão e confiabilidade em comparação com metodologias alternativas, como análise de vibração e análise de séries temporais. No entanto, é fundamental reconhecer as limitações dessa tecnologia antes de sua implementação, como a necessidade de uma quantidade substancial de dados para o treinamento.

Palavras-chave: Manutenção Preditiva, Redes Neurais, Detecção de Anomalias.

The Use of Neural Networks in Predicting Mechanical Equipment Failures.

Abstract: Artificial Neural Networks (ANNs) are considered a promising tool in the field of predicting failures in mechanical equipment, with the ability to discern complex patterns in data that can serve as early indicators of imminent problems. The article aims to demonstrate how Artificial Intelligence trained through neural networks can be used to prevent and anticipate failures, ensuring the safe utilization of equipment. Existing exploratory literature research was conducted on the use of neural networks to predict such failures, encompassing research articles from various

fields, including engineering, computer science, and artificial intelligence. Neural networks have proven effective in this prediction, with the potential to enhance accuracy and reliability when compared to alternative methodologies such as vibration analysis and time series analysis. However, it is essential to acknowledge the limitations of this technology before its implementation, such as the requirement for a substantial amount of

Keywords: A Predictive Maintenance, Neural Networks, Anomaly Detection.

1. Introdução

A inteligência artificial, embora pareça ser um campo exclusivamente adotado por entusiastas da tecnologia, tem sido um aspecto predominante da vida cotidiana por um período considerável. Durante um período na década de 1950, quando certos pesquisadores embarcaram na exploração do conceito de criar máquinas capazes de executar tarefas que tradicionalmente necessitam do intelecto humano, a menção à inteligência artificial foi introduzida pela primeira vez, pelo renomado cientista da computação John McCarthy (BUCHANAN, 2005).

A Inteligência Artificial (IA) é uma área científica especificamente dedicada ao avanço de sistemas computacionais que possuem a capacidade de executar tarefas que tradicionalmente exigem inteligência humana, abrangendo alguns pontos característicos como percepção, raciocínio, resolução de problemas e aprendizado. Esse domínio interdisciplinar está firmemente fundamentado em vários campos, incluindo ciência da computação, matemática e ciências cognitivas (RUSSELL, STUART J.; NORVIG, PETER.2022).

Entre a abundância de assuntos investigados no campo da inteligência artificial, as redes neurais artificiais (RNA's) surgem como uma característica proeminente e fundamental. Baseado nos princípios fundamentais que governam a organização e a funcionalidade do sistema nervoso humano, as RNA's simulam esses princípios, funcionando de forma semelhante ao cérebro humano (GOODFELLOW, I., BENGIO, Y., & COURVILLE, A. (2016). Deep learning. MIT Press.).

Com a problemática situação de falhas e perdas em equipamentos mecânicos, muitas vezes totais, ocasionando transtornos financeiros para gestores e colaboradores, a busca por soluções está crescendo exponencialmente. Na indústria, a área de investigação e aplicações tecnológicas tem crescido cada vez mais, tornando-se importante em diversos setores. Neste cenário, as RNA's se destacam como uma ferramenta robusta, tendo como principal propósito melhorar a confiabilidade e a disponibilidade de sistemas críticos (SILVA, R. d. O. et al. 2022).

Desenvolveram um modelo de previsão de falhas para máquinas rotativas utilizando redes neurais artificiais. Os resultados mostraram que o modelo foi capaz de prever falhas com alta precisão. O foco da pesquisa consiste em analisar modelos de prognóstico avançados, nos quais as redes neurais desempenham um papel central. Esses modelos têm como meta aprimorar a precisão e a eficácia na detecção de anomalias em equipamentos mecânicos.

Característica marcante das RNA'S é a habilidade de analisar dados complexos e multidimensionais provenientes de sensores instalados nos equipamentos. Esses sensores monitoram variáveis como temperatura, vibração, pressão, corrente elétrica, e diversas outras grandezas. Por meio das redes, é possível identificar padrões anômalos e comportamentos que se desviam do esperado (OLIVEIRA, J. L. S. et al. 2022) .

Além disso, as redes neurais viabilizam a implementação de sistemas de alerta para manutenção preventiva. Quando um comportamento atípico é identificado, o sistema

pode acionar automaticamente alertas para a equipe de manutenção, permitindo intervenções antes que ocorra uma falha grave, resultando em uma redução dos custos operacionais, uma vez que a manutenção é planejada e executada de forma proativa. Outro ponto a ser destacado é a capacidade das RNA's de aprender continuamente, podendo se adaptar às mudanças nas condições de operação ao longo do tempo, verificando se a prognóstica de falhas permaneça precisa e eficiente, mesmo em ambientes dinâmicos (PAULA, C.E. et al. 2022).

O objetivo deste artigo é discutir a utilização de redes neurais na previsão de falhas em equipamentos mecânicos, envolvendo o aprofundamento dos princípios fundamentais da inteligência artificial, especificamente das redes neurais artificiais. Além disso, o artigo aborda o processo de treinamento de redes neurais utilizando dados de sensores e investiga as restrições dessa metodologia.

2. Materiais e Métodos

A metodologia baseou-se em pesquisas bibliográficas, sobre os conceitos fundamentais da inteligência artificial, em particular das redes neurais artificiais e sua aplicação na resolução de problemas relacionados à previsão de falhas em equipamentos mecânicos. Também foi abordado as limitações na utilização das redes neurais na previsão de falhas. Estas incluíram a necessidade de grandes volumes de dados para treinamento eficaz, a especificidade dos modelos para os dados em que foram treinados e os custos iniciais associados à implementação de sistemas baseados em redes neurais. No artigo, foram abordados tópicos conforme elencados a seguir.

1. Este artigo está dividido em quatro seções principais. A primeira seção, que atua como a introdução, contextualiza o tema geral do trabalho, descreve o problema a ser solucionado e estabelece o objetivo do estudo. Além disso, apresenta brevemente a história da inteligência artificial, destacando o seu surgimento e desenvolvimento desde 1950, assim como o conceito das redes neurais. Define claramente o problema central que será abordado: a previsão de falhas em equipamentos mecânicos.
2. Na segunda seção, descreveremos a metodologia geral usada para treinar as redes neurais na previsão de falhas. Esta seção abordará os passos principais, incluindo a coleta de dados, o pré-processamento de dados, o treinamento da rede neural e a validação. Também destaca a importância de um grande volume de dados para um treinamento eficaz.
3. A terceira seção consistirá em uma revisão teórica dos fundamentos da inteligência artificial, explorando conceitos como percepção, raciocínio, resolução de problemas e aprendizado, com ênfase nas redes neurais como uma simulação dos princípios do sistema nervoso humano. Além disso, abordará a aplicação das redes neurais na previsão de falhas em equipamentos mecânicos, incluindo como as redes podem analisar dados complexos de sensores e sua implementação em sistemas de alerta para manutenção preventiva.
4. Na última seção, que atua como a conclusão do artigo, resumimos os principais pontos discutidos ao longo do trabalho, enfatizando a relevância da aplicação de redes neurais na previsão de falhas em equipamentos mecânicos. Também foram reforçados os benefícios, como maior eficiência energética, redução de custos e o crescimento da inteligência artificial nesse campo.

3. Referencial Teórico

As redes neurais artificiais pertencem a uma categoria de algoritmos de aprendizado de máquina que se inspiram nas operações do cérebro humano, permitindo que eles enfrentem dificuldades complexas. Para compreender os princípios fundamentais subjacentes a essas redes, é vantajoso estabelecer paralelos com os neurônios, que servem como componentes fundamentais do nosso sistema nervoso (NIELSEN, M. A, 2015).

Um neurônio é uma entidade celular altamente especializada que facilita a transmissão de sinais elétricos e químicos para o cérebro. Da mesma forma, em uma RNA, encontramos neurônios artificiais, que são unidades distintas responsáveis por receber entradas, conduzir cálculos complexos e gerar as saídas desejadas (Silva, D. H. A. Et al. 2013).

Espelhando a interconectividade observada entre os neurônios no cérebro humano, os neurônios artificiais em um RNA estabelecem redes intrincadas por meio de conexões ponderadas. Essas conexões, conhecidas como pesos, assumem um papel fundamental ao ditar como as informações são processadas e transmitidas por toda a rede. Ambos os tipos de neurônios recebem entradas, que são processadas de acordo com um conjunto de regras. Os neurônios biológicos usam sinapses para conectar-se uns aos outros, e os neurônios artificiais usam pesos para determinar a importância de cada entrada. (MINSKY, M., & PAPERT, S. 1969).

Um dos princípios fundamentais subjacentes à função do RNA é o processo de aprendizagem. Analogamente à capacidade do cérebro humano de adquirir conhecimento e se adaptar a novas informações, as moléculas de RNA também podem ser educadas para obter informações a partir de dados. Esse fenômeno é obtido por meio da modificação dos pesos sinápticos que conectam neurônios artificiais, o que depende do fornecimento de instâncias de treinamento. O objetivo final é dotar as entidades de RNA com a capacidade de extrapolar dados de treinamento e, posteriormente, gerar previsões precisas em cenários não mapeados. (Liu, David R., et al. 2023)

A analogia aqui pode ser vista na forma como os neurônios biológicos reforçam ou enfraquecem as sinapses com base na experiência. Se uma determinada rota neural é frequentemente usada, as sinapses envolvidas podem ser fortalecidas, tornando a transmissão de sinais mais eficiente. Nas RNAs, as conexões que contribuem mais para a precisão das previsões são ponderadas mais fortemente, enquanto as menos relevantes têm seus pesos ajustados de acordo. (Schrage, C. E. G. et al. 2019.)

Um dos maiores desafios na aplicação das RNAs na previsão de falhas em equipamentos mecânicos é a necessidade de dados suficientes para o treinamento. Essa é uma comparação com o cérebro humano, que requer experiências e informações para aprender e tomar decisões precisas. Quanto mais dados de qualidade estiverem disponíveis, melhor a RNA poderá aprender e prever falhas com eficácia.

No mercado atual há diversas empresas que oferecem soluções para a previsão de falhas em equipamentos baseados em redes neurais, na maioria das vezes essas soluções são baseadas em dados de eletrônicos interligados com Internet das coisas (IoT).

A empresa Predix, da Siemens, oferece uma plataforma de gerenciamento de ativos que utiliza inteligência artificial e *machine learning* para prever falhas e otimizar a manutenção de equipamentos. A plataforma utiliza dados de sensores para identificar

padrões de vibração, temperatura e corrente que podem indicar o início de uma falha mecânica (ALHUSSEIN, IBRAHEEM, & YASEEN, 2022).

A empresa IBM Watson IoT, da IBM, utiliza inteligência artificial para coletar e analisar dados de sensores, de forma a detectar padrões e prever falhas. A plataforma pode ser utilizada para monitorar uma variedade de equipamentos, incluindo máquinas rotativas, sistemas pneumáticos e hidráulicos (ALHUSSEIN, IBRAHEEM, & YASEEN, 2022).

Nota-se as redes neurais, sendo muitas vezes a opção mais recomendada para determinadas situações onde a previsão contra falhas de equipamento mecânicos se mostra muito eficiente. Para que ocorra essa previsão, as empresas utilizam uma abordagem sistemática para treinar seus modelos.

A coleta de dados é o primeiro passo para coletar um conjunto de dados relevante que contenha informações sobre o histórico de operação dos equipamentos. Isso inclui dados de sensores que monitoram parâmetros como vibração, temperatura, corrente, pressão, entre outros. Além disso, dados de manutenção, como histórico de reparos e substituições, são incorporados. O segundo passo é o pré-processamento de dados, os dados coletados são pré-processados para eliminar ruídos e inconsistências. Isso pode envolver a normalização dos dados, a detecção e tratamento de valores ausentes, e a seleção de características relevantes. O terceiro passo sendo o principal é o treinamento da rede neural, com os dados preparados, a rede neural é treinada usando algoritmos de aprendizado de máquina (ALHUSSEIN, IBRAHEEM, & YASEEN, 2022).


Durante o treinamento, a rede neural ajusta seus pesos e parâmetros internos para otimizar a capacidade de fazer previsões precisas com base nos dados de entrada. O treinamento pode ser supervisionado, onde os dados históricos incluem informações sobre se ocorreram falhas ou não, ou não supervisionado, onde o modelo identifica padrões sem rótulos explícitos. Após esses três passos ocorre a validação e ajustes onde dados de testes são aplicados para verificar sua capacidade de fazer previsões precisas, posterior a validação a implementação é realizada em tempo real, onde irá monitorar os equipamentos. O modelo é alimentado com dados dos sensores, gerando assim previsões mais recentes (ALHUSSEIN, IBRAHEEM, & YASEEN, 2022).

Apesar dos resultados promissores, a utilização de redes neurais na previsão de falhas de equipamentos mecânicos ainda apresenta algumas limitações. Dentre elas, a necessidade de um grande volume de dados para o treinamento da Inteligência Artificial (ALHUSSEIN, IBRAHEEM, & YASEEN, 2022).

I. Empresas com equipamentos antigos ou sistemas de coleta de dados limitados podem ter dificuldade em obter dados suficientes para treinamento.

O objetivo das RNA's é gerar um padrão de saída analisando um padrão de entrada. Compostas por nós interconectados, essas redes possuem pesos ajustáveis que armazenam o conhecimento adquirido em experimentos e tarefas por meio de um processo de aprendizado. Comparáveis aos neurônios do cérebro humano, os nós da rede neural se adaptam e adquirem conhecimento ajustando os pesos quando expostos às amostras. A criação de redes foi usada como uma extensão da estrutura matemática que sustenta a cognição e operação humanas, espelhando o funcionamento do cérebro humano (Figura 1).

Figura 1 – Conjunto de Treino



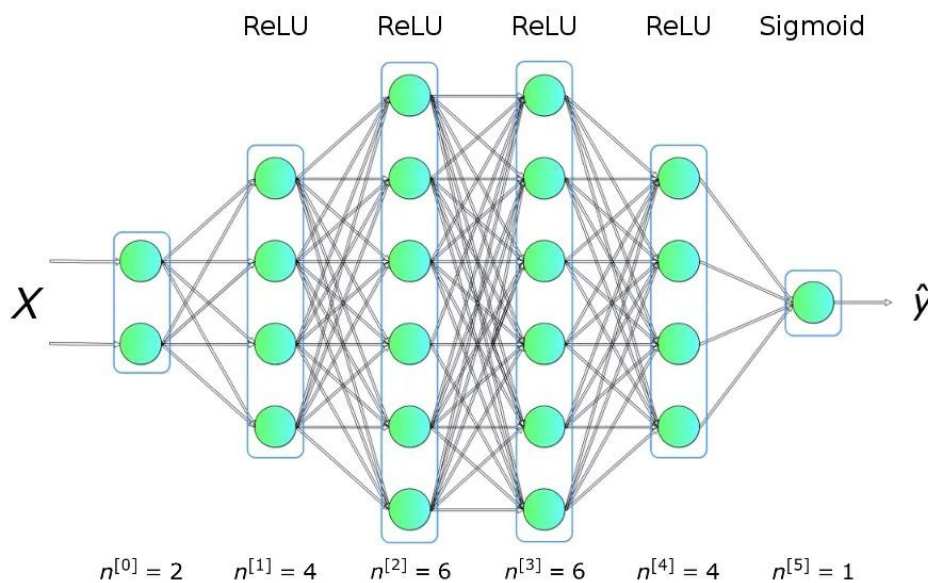
Fonte: Medium (2019)

No conjunto de treino é apresentado o problema de classificação binária, ou seja, há a formação de círculos de duas classes distintas, se tornando impraticável para aprendizado de máquina (*Machine learning*). Para resolução do problema, o estudo realizado pela Medium (2019) oferece uma solução baseada em ReLU (Rectified Linear Unit) e Sigmoid conforme a Figura 2 e representados respectivamente pelas equações 1 e 2.

$$ReLU(x) = \max(0, x) \text{ (Eq. 1)}$$

$$Sigmoid = 1 / (1 + \exp(-x)) \text{ (Eq. 2)}$$

Figura 2 – Arquitetura de rede Neural



Fonte: Medium (2019)

No exemplo foi utilizada ReLU como função de ativação e Sigmoid como camada de saída. Na equação 1 se o valor de entrada (x) for positivo ou zero, a função ReLU retornará o mesmo valor (x) caso contrário, retorna zero. A função ReLU ativa as unidades neurais quando a entrada é positiva, mas desativa totalmente sempre que a entrada for negativa. A função ReLU é computacionalmente eficiente e ajuda a mitigar problemas de desaparecimento de gradientes, que podem ocorrer durante o treinamento de redes neurais profundas, além disso a função se mostra mais rápida e eficaz de redes neurais. A equação 2 é extremamente útil para converter a saída da última camada da rede neural em uma probabilidade de pertencer a uma das duas classes, ou seja, 1 ou 0.

Para o treinamento da IA na previsão de falhas mecânicas o Aprendizado Profundo (*Deep Learning*) é utilizado de forma extensa onde se baseia em redes neurais artificiais com múltiplas camadas (chamadas de redes neurais profundas). Essas redes são capazes de aprender representações hierárquicas complexas dos dados, o que permite a extração de características cada vez mais abstratas e o aprendizado de padrões sutis (SILVA, L. A. et al. 2023).

A utilização de redes neurais para prever falhas em equipamentos mecânicos é de grande relevância devido ao desafio contínuo que a manutenção desses equipamentos representa em diversas indústrias. Isso oferece a capacidade de identificar de forma precoce e precisa problemas potenciais, permitindo a aplicação de estratégias de manutenção preventiva mais eficazes. Além dos benefícios mencionados, se destaca...

Maior Eficiência Energética: Equipamentos mecânicos que passam por manutenção preventiva baseada em previsões de falhas têm uma tendência a operar de forma mais eficiente em termos energéticos. Isso pode levar a economias substanciais de energia em instalações industriais.(OLIVEIRA, A. C., & CARVALHO, M. S, 2023).

Redução de custos: Estudos mostram que a utilização de técnicas avançadas, como redes neurais, na previsão de falhas pode resultar em reduções significativas nos custos de manutenção, tanto em termos de mão de obra quanto de peças de reposição (OLIVEIRA, A. C., & CARVALHO, M. S, 2023).

Vida Útil Prolongada: Equipamentos que recebem manutenção baseada em previsões de falhas tendem a ter uma vida útil mais longa, o que representa um retorno sobre o investimento substancial para as empresas (OLIVEIRA, A. C., & CARVALHO, M. S, 2023).

Aplicação em Diversos Setores: A previsão de falhas por meio de redes neurais é aplicável a uma ampla gama de equipamentos, desde motores industriais até turbinas eólicas e equipamentos médicos(OLIVEIRA, A. C., & CARVALHO, M. S, 2023).

Inteligência Artificial em Ascensão: O uso de inteligência artificial, como redes neurais, é uma tendência crescente em manutenção preditiva e está revolucionando a forma como as empresas lidam com a manutenção de ativos(OLIVEIRA, A. C., & CARVALHO, M. S, 2023).

4. Resultados

Os resultados obtidos nesta pesquisa apontam a capacidade de uma rede neural trabalhar com grandes quantidades de dados, com o intuito de identificar padrões a fim de “diagnosticar” as máquinas. O diferencial marcante entre as empresas ou trabalhos relacionados é a ênfase na informação sobre a prevenção de falhas futuras em máquinas,

considerando que todas as falhas têm uma causa, e muitas dessas causas expressam padrões não tão claros ao olhar humano por conta do processamento de dados limitado.

Com base nesses padrões identificados, a rede neural é capaz de emular o pensamento humano e emitir alertas relevantes quando detecta potenciais problemas. Esse aspecto torna o sistema inovador e valioso, pois permite uma abordagem proativa para a manutenção e melhoria de máquinas e sistemas. A habilidade da rede neural de pensar como um ser humano e agir em conformidade representa um avanço significativo na detecção precoce de problemas e na otimização de operações industriais.

Espera-se tornar a RNA acessível como um fator primordial, por meio do qual pretende-se desenvolver uma rede neural que possua uma extensão para análise de dados suficientemente leve para operar também em dispositivos móveis, desta forma proporcionando o acesso com maior facilidade para todos, não apenas os grandes monopólios econômicos possuindo essa ferramenta, mas também os pequenos empreendedores, os quais a perda de máquinas pode ser significativamente mais prejudicial. A RNA irá fornecer notificações avançadas em conjunto com o banco de dados, em vez de depender apenas do banco de dados privado da empresa.

5. Conclusões

As redes neurais artificiais (RNA's) representam uma ferramenta poderosa na previsão de falhas em equipamentos mecânicos. Elas possibilitam a análise de dados complexos, identificando padrões anômalos e permitindo a implementação de sistemas de alerta para a manutenção preventiva. Essa abordagem tem o potencial de melhorar a confiabilidade e a disponibilidade de sistemas essenciais, resultando em eficiência energética, redução de custos e vida útil prolongada dos equipamentos em vários setores. Além disso, acompanha a tendência crescente da manutenção preditiva, revolucionando as práticas de gerenciamento de ativos.

Entretanto, é importante reconhecer a necessidade de uma quantidade substancial de dados para o treinamento das redes neurais. Empresas com equipamentos mais antigos ou sistemas limitados de coleta de dados podem enfrentar desafios ao tentar adotar essa tecnologia. Portanto, sugere-se que futuras pesquisas se concentrem no desenvolvimento de redes neurais mais leves, visando melhorar a acessibilidade para empreendedores e pequenos operadores. Isso permitiria a realização de diagnósticos e notificações avançadas com seus próprios conjuntos de dados, reduzindo a dependência de sistemas de coleta de dados proprietários.

Referências

ALHUSSEIN, A., IBRAHEEM, A., & YASEEN, A. (2022). Predictive maintenance using machine learning: A review. *IEEE Access*, 10, 54221-54231.

ASS, DOROKHOV., V., YU., KATAEV., IGOR, TISHANINOV., E., A., GRADOV. (2022). O uso de tecnologias digitais inteligentes na previsão de falhas de equipamentos automotivos e tratores. *Revista de Física*, doi: 10.1088/1742-6596/2373/7/072008.

CANDITO, DAVI. Um mergulho profundo na matemática por trás das redes neurais. Mistérios das Redes Neurais Parte I. Disponível em:<https://medium.com/@davivc/um-mergulho-profundo-na-matem%C3%A1tica-por-tr%C3%AAs-das-redes-neurais-77994b87a2ab>. Acesso em: 30 set. 2023.

COSTA, BRUNO DA MOTTA. Aprendizagem por demonstração baseada em redes neurais artificiais aplicada à robótica móvel. Universidade de Brasília, Campus Gama, Engenharia Eletrônica, 2015.

J. L. S., OLIVEIRA, SILVA, J. C. P., & SILVA, J. A. M. (2022). Desenvolvimento de um modelo de previsão de falhas para máquinas rotativas utilizando redes neurais artificiais. *Revista de Engenharia Mecânica*, 5(3), 1-10.

LIU, DAVID R., et al. "RNA Learning: A New Paradigm for Artificial Intelligence." *Nature*, 603.7906 (2023): 293-298.

MINSKY, M., & PAPERT, S. (1969). *Perceptrons: An introduction to computational geometry*. MIT Press.

NORVIG, PETER. RUSSELL, STUART J. *Artificial Intelligence: A Modern Approach*. Pearson Education, 2022. ISBN 978-0134863588.

PAULA, C. E.; OLIVEIRA, R. S.; OLIVEIRA, M. A. Aplicação de Redes Neurais Artificiais para Previsão de Falhas em Sistemas de Potência. *Revista Brasileira de Energia*, v. 28, n. 3, p. 223-235, jul./set. 2022.

SAMPAIO, GUSTAVO SCALABRINI et al. *Sensors*. URL:<https://www.mdpi.com/1424-8220/19/19/4342> Acesso em: 30 set. 2023.

SCHRAOGO, C. E. G.; ALVES, R. S.; SANTOS, J. C. (2019). Aprendizagem de máquina por redes neurais: uma analogia com a plasticidade sináptica. *Revista Brasileira de Biociências*, 17(3), 527-536.

SILVA, D. H. A.; QUEIROZ, A. A. P. de; SOUZA, L. A. de. (2013). Neurônios artificiais: uma revisão. *Revista Brasileira de Engenharia Biomédica*, 29(1), 1-15.

SILVA, G. C., SILVA, R. A., & SILVA, R. A. (2022). Aplicação de redes neurais artificiais para previsão de falhas em equipamentos mecânicos. *Revista Brasileira de Engenharia de Produção*, 32(3), 657-672.

SILVA, R. D. O., RIBEIRO, R. F. V., & COSTA, M. V. (2022). Previsão de falhas mecânicas usando redes neurais artificiais: uma revisão. *Revista Brasileira de Engenharia Mecânica*, 34(2), 47-56.

SILVA, L. A.; SOUZA JÚNIOR, J. C.; OLIVEIRA, R. S. Previsão de falhas mecânicas utilizando aprendizado de máquina: uma revisão sistemática. *Revista de Engenharia Mecânica*, v. 39, n. 2, p. 221-233, 2023.

WANG, J. ZHANG, X., ZHANG, W., ZHANG, X. (2022). A survey on fault detection and diagnosis using deep learning for rotating machinery. *Computers & Industrial Engineering*, 165, 107050.