

## ANÁLISE BIBLIOMÉTRICA E SISTÊMICA SOBRE APLICAÇÃO DE MACHINE LEARNING PARA DIAGNÓSTICO DE FALHAS DE MÁQUINAS EM TEMPO REAL

Joelton Deonei Gotz ([gotz@alunos.utfpr.edu.br](mailto:gotz@alunos.utfpr.edu.br)) – Universidade Tecnológica Federal do Paraná (PPGEM-CT).

João Felipe Raffe Espolador ([joaofe@alunos.utfpr.edu.br](mailto:joaofe@alunos.utfpr.edu.br)) – Universidade Tecnológica Federal do Paraná (PPGEM-CT).

Samuel Henrique Werlich ([samuelw@alunos.utfpr.edu.br](mailto:samuelw@alunos.utfpr.edu.br)) – Universidade Tecnológica Federal do Paraná (PPGEM-CT).

Lucas Iuri dos Santos ([lucassantos.1994@alunos.utfpr.edu.br](mailto:lucassantos.1994@alunos.utfpr.edu.br)) – Universidade Tecnológica Federal do Paraná (PPGEM-CT).

Milton Borsato ([borsato@utfpr.edu.br](mailto:borsato@utfpr.edu.br)) – Universidade Tecnológica Federal do Paraná (PPGEM-CT).

### RESUMO

No processo de transformação digital, as fábricas do futuro buscam excelência com foco em qualidade de produto e eficiência de produção. Na busca de um processo controlado, objetiva-se reduzir ao máximo problemas e paradas em equipamentos, através da identificação de falhas de forma online, precoce e antecipada para realizar a tomada de decisão em tempo real. Nesse contexto, técnicas de *Machine Learning* (ML) são frequentemente utilizadas para diagnosticar falhas em equipamentos em tempo real. Portanto, esse trabalho busca recuperar as principais publicações vinculadas ao tema de diagnóstico de falhas em tempo real a partir da aplicação de técnicas de ML e realizar uma análise bibliométrica e sistêmica. Esse objetivo foi alcançado através da utilização do método de *Knowledge Development Process-Constructivist* (Proknow-C) para selecionar e classificar os artigos mais relevantes ao tema. A aplicação do Proknow-C resultou no resgate de 38 artigos que compõem o portfólio final. Em seguida realizou-se uma análise bibliométrica que indicou a relevância dos artigos, as palavras-chaves mais encontradas e a tendência de publicações nessa área. Por fim, uma análise sistêmica foi efetuada, onde foram explorados os principais problemas observados, as tendências dos métodos mais utilizados e as oportunidades de pesquisa indicadas pelos autores.

Palavras chave: *machine learning*; diagnóstico de falhas; *real time*; *deep learning*

## 1. INTRODUÇÃO

O advento da quarta revolução industrial está aliado à adoção da tecnologia da informação e a comunicação nos processos industriais. Com o objetivo de realizar o monitoramento e controle da qualidade dos produtos e da eficiência nos processos. Esse cenário origina o conceito "fábricas do futuro" ou ainda "fábricas inteligentes", as quais são caracterizadas por buscarem excelência em seus processos produtivos, além de se tornarem mais digitais, automatizadas e inteligentes (XU *et al.*, 2019).

Na etapa intermediária do desenvolvimento de produto, encontra-se o *Middle Of Life* (MOL), que compreende a etapa mais longa da vida de um produto (JUN; KIRITSIS, 2012). Justamente na busca do prolongamento dessa etapa que está o segredo das fábricas do futuro: na qual buscam a adoção de sistemas de diagnóstico de falhas com abordagem preditiva. Nesse contexto, as falhas podem ser monitoradas nas fases iniciais, reduzindo-se gastos com manutenção corretiva e preventiva (WEN *et al.*, 2018; XIA *et al.*, 2020).

Atualmente são encontrados 3 modelos de aplicação de diagnóstico de falhas na indústria, dos quais o modelo baseado em *Data-Driven* é considerado muito promissor. Esse modelo trabalha com dados históricos que podem ser gerados a partir da digitalização das fábricas do futuro e realizar o reconhecimento de falhas a partir da análise do padrão de sinais (WEN *et al.*, 2018).

Técnicas de ML são consideradas para aplicação de diagnóstico de falhas a partir de *data-driven*. Porém, os modelos estatísticos possuem dificuldade em extrair *features* de forma automática e de diferentes níveis de abstração. Além disso, precisam de grande conhecimento do processo para elaborar o modelo (HOANG; KANG, 2019). Para resolver esse problema, técnicas de ML baseadas em redes neurais podem ser utilizadas, principalmente pela sua capacidade de extrair *features* mais complexas automaticamente (EREN; INCE; KIRANYAZ, 2019).

Por isso, esse trabalho realizou uma revisão bibliográfica acerca do envolvimento de algoritmos de ML para diagnosticar falhas em equipamentos em tempo real através do Proknow-C. Esse processo auxilia o pesquisador a encontrar direções e trabalhos na área de pesquisa, com objetivo de verificar na academia as soluções publicadas recentemente, as dificuldades e as oportunidades de pesquisa encontradas nessa área (ENSSLIN *et al.*, 2010).

O método Proknow-C é composto das etapas de levantamento de artigos, análise bibliométrica e análise sistêmica, na qual é possível obter uma determinada quantidade de artigos que mostrarão as oportunidades de pesquisa na área visada (ENSSLIN et al., 2010). Por isso, esse artigo é composto por 5 seções: introdução, levantamento do portfólio bibliográfico, análise bibliométrica, análise sistêmica e a conclusão.

## 2. LEVANTAMENTO DO PORTFÓLIO BIBLIOGRÁFICO

A primeira etapa do método Proknow-C diz respeito ao levantamento do portfólio bibliográfico, que consiste na busca de artigos vinculados ao tema abordado. Para isso, criou-se a sintaxe de pesquisa baseada no seguinte objetivo de trabalho: desenvolver um algoritmo de *Machine Learning* para diagnosticar falhas em tempo real em máquinas.

O objetivo foi dividido em três eixos, compostos das seguintes palavras-chaves: “Machine Learning”, “diagnosticar” e “tempo real”. No entanto, para elaborar a sintaxe, palavras similares foram levantadas a ponto de construir uma sintaxe de busca otimizada, como visto no Quadro 1.

Machine Learning	diagnosticar	real time
"artificial intelligence"	phm	"time series analy*"
"deep learning"	"prognostic and health management"	"data-driven"
"neural network*"	"failure analys*"	"online"
"Long short-term memory"	"fault detection"	real-time data
"Kalman Filter*"	"Fault diagnos*"	iot
"random forest*"	"condition monitoring"	"edge computing"
"feature learning"	"Predictive maintenance"	time-scale
"genetic algorithm"	"predictive analys*"	temporal data
"Bayesian Network"	"anomaly detection"	big data
CNN or "convolutional neural network"	"sensor fault"	"signal processing"
"extreme learning"	"fault identification"	time series
Recurrent neural network		data stream

QUADRO 1 – Palavras-chaves escolhidas para a montagem da sintaxe. Fonte: Os autores.

Após a montagem da sintaxe de pesquisa, foi realizado a busca nas quatro principais bases de artigos para engenharia: Compendex, Scopus, Web of Science e IEEE Xplorer. Para isso, a pesquisa foi direcionada a artigos periódicos e a publicações dos últimos cinco anos, restritos à língua inglesa. Também houve filtros de artigos vinculados com as áreas de Engenharia, Ciência da Computação e Energia.

Com os filtros realizados e a sintaxe adequada para cada base de artigos, a pesquisa realizada entre os dias 02 e 27 de abril de 2021 retornou 2711 artigos como observado na Figura 1.

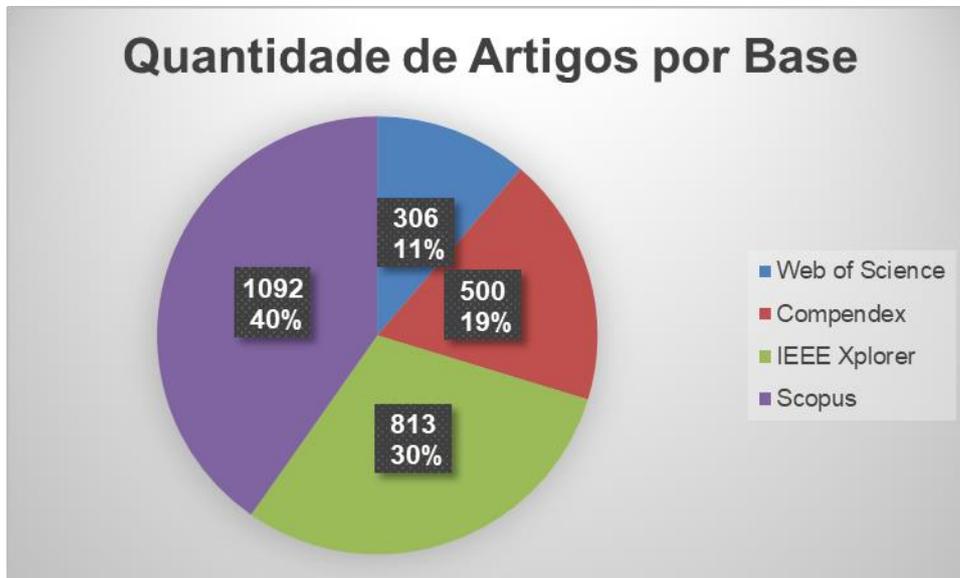


FIGURA 1 – Publicações por base de artigos. Fonte: Os autores.

A eliminação de artigos foi realizada através de um Script em linguagem Python. Ao final obteve-se 1947 artigos não repetidos em um único arquivo Excel. Essa etapa reduziu a quantidade de 2711 para 1947 artigos.

Em seguida foi realizada a leitura dos títulos dos artigos, que resultou em 1138 artigos relacionados ao tema. Após, foi aplicada a regra de Pareto para selecionar os 20% dos artigos que contém 80% do número total de citações, resultando em 265 artigos. Na etapa de repescagem dos 80% de artigos não escolhidos foram selecionados os artigos publicados nos dois últimos anos e os artigos escritos pelos autores mais relevantes, resultando em 711 artigos.

A seguir, foi realizada a leitura dos resumos dos 976 trabalhos, adotando o critério de seleção contido no Quadro 2. Após essa etapa, apenas 165 artigos alinhados com o tema e com um número relevante de citações foram mantidos.

Critério	Número de Artigos
Alinhados com o tema e relevante número de citações	165
Desalinhados com o tema	433
Alinhados com o tema, porém não descrevem detecção em tempo real	14
Parcialmente alinhados com o tema, mas possui baixo número de citações	364

QUADRO 2 – Critérios de classificação na etapa de leitura dos resumos. Fonte: Os autores.

Como o método Proknow-C recomenda que a leitura na íntegra dos artigos não seja realizada em número superior a 50 artigos, foi aplicado novamente o método de Pareto para selecionar 30% dos artigos com 70% das citações. Foram então obtidos 50 artigos que foram lidos na íntegra, sendo que 38 artigos foram considerados aptos ao tema proposto e estão apresentados no Quadro 3.

Índice	Título	Ano	Citações	Autores
883	A New Convolutional Neural Network-Based Data-Driven Fault Diagnosis Metho	2018	516	Long Wen , Xinyu Li , Liang Gao , Yu
1521	Multisensor Feature Fusion for Bearing Fault Diagnosis Using Sparse Autoencod	2017	304	Zhuyun Chen, Weihua Li
1291	Machine health monitoring using local feature-based gated recurrent unit netwo	2017	255	Rui Zhao , Dongzhe Wang, Ruqiang
702	Multiscale Convolutional Neural Networks for Fault Diagnosis of Wind Turbine C	2019	181	Guoqian Jiang, Haibo He, Jun Yan, P
1035	A convolutional neural network for fault classification and diagnosis in semicon	2017	168	Ki Bum Lee, Sejune Cheon, Chang O
899	Deep Residual Networks with Dynamically Weighted Wavelet Coefficients for F	2018	131	Minghang Zhao, Myeongsu Kang, B
757	Rolling element bearing fault diagnosis using convolutional neural network and	2019	123	Duy-Tang Hoang, Hee-Jun Kang
1066	Transfer Learning with Neural Networks for Bearing Fault Diagnosis in Changing	2017	122	RAN ZHANG, HONGYANG TAO, LIFE
912	A Data-Driven Design for Fault Detection of Wind Turbines Using Random Fores	2018	119	DAHAI ZHANG, LIYANG QIAN, BAIJIN
1286	A robust intelligent fault diagnosis method for rolling element bearings based o	2018	110	Xiang Li, Wei Zhang, Qian Ding
706	Fault diagnosis of wind turbine based on Long Short-term memory networks	2019	107	Jinhao Lei, Chao Liu, Dongxiang Jiar
914	Convolutional neural network-based hidden Markov models for rolling element b	2018	105	Shuhui Wang, Jiawei Xiang, Yongter
738	A Generic Intelligent Bearing Fault Diagnosis System Using Compact Adaptive I	2019	97	Levent Eren, Turker Ince, Serkan Kir
635	Fault diagnosis of gearbox based on RBF-PF and particle swarm optimization wa	2019	87	Liu Yang, Hanxin Chen
758	A novel deeper one-dimensional CNN with residual learning for fault diagnosis d	2019	73	DANDAN PENG, ZHILIANG LIU, HUA
1079	Bearing fault detection by one-dimensional convolutional neural networks	2017	66	Levent Eren
872	Adaptive deep feature learning network with Nesterov momentum and its applic	2018	46	Shenghao Tanga, Changqing Shena,
1253	Performance analysis of IoT-based sensor ; big data processing ; and machine le	2018	62	Muhammad Syafrudin, Ganjar Alfian
755	A Digital-Twin-Assisted Fault Diagnosis Using Deep Transfer Learning	2019	46	YAN XU, YANMING SUN, XIAOLONG
703	Automated bearing fault diagnosis scheme using 2D representation of wavelet	2019	42	M.M. Manjurul Islam, Jong-Myon Ki
884	Lired: A light-weight real-time fault detection system for edge computing using	2018	42	Donghyun Park, Seulgi Kim, Yelin An
885	Bayesian inference for mining semiconductor manufacturing big data for yield e	2018	40	Marzieh Khakifirooz, Chen Fu Chien,
578	Data-Driven Safety Envelope of Lithium-Ion Batteries for Electric Vehicles	2019	35	Wei Li, Juner Zhu, Yong Xia, Maysam
814	A Neural-Network-Based Method for RUL Prediction and SOH Monitoring of Lith	2019	26	JIANAO QU, FENG LIU, YUXIANG M
607	Online Fault Diagnosis for Industrial Processes with Bayesian Network-Based Pr	2019	19	Wanke Yu, Chunhui Zhao
388	Bayesian approach and time series dimensionality reduction to LSTM-based mo	2020	18	Diego Cabrera, Adriana Guamán, Sh
320	Transformer fault diagnosis method using IoT based monitoring system and ens	2020	18	Chaolong Zhang, Yigang He, Bolun I
816	An integrated imputation-prediction scheme for prognostics of battery data with	2019	15	Roobeh Razavi-Far, Shiladitya Chak
613	Remaining Useful Life Prediction of Lithium-Ion Batteries Using Support Vector	2019	11	Yingzhou Wang, Yulong Ni, Shuai Lu
1496	Single- and Multi-Fault Diagnosis Using Machine Learning for Variable Frequenc	2020	8	Mohammad Zawad Ali, Md Nasmus
97	Real-time robust forecasting-aided state estimation of power system based on	2021	6	Xingquan Ji, Ziyang Yin, Yumin Zhan
1422	Remaining Useful Life Prognosis Based on Ensemble Long Short-Term Memory N	2021	4	Yiwei Cheng, Jun Wu, Haiping Zhu, S
1380	Data-driven prognosis method using hybrid deep recurrent neural network	2020	4	Min Xia, Xi Zheng, Muhammad Imra
285	A coupling diagnosis method of sensors faults in gas turbine control system	2020	2	Rongzhuo Sun, Licheng Shi, Xilian Ye
347	A tool wear monitoring and prediction system based on multiscale deep learning	2020	1	Huihui Qiao, Taiyong Wang, Peng W
86	Advanced fault diagnosis method for nuclear power plant based on convolution	2021	1	Hang Wang, Min-jun Peng, Abiodun
35	A Neural Network Based Method for Thermal Fault Detection in Lithium-Ion Batt	2021	1	Olaoluwa Ojo, Haoxiang Lang, Youn
1181	SVM-BiLSTM: A Fault Detection Method for the Gas Station IoT System Based on	2020	0	YAO JIAHAO, XIAONING JIANG, SHO

QUADRO 3 – Portfólio final. Fonte: Os autores.

### 3. ANÁLISE BIBLIOMÉTRICA

Após a formação do repositório final de artigos, foi realizada uma análise bibliométrica para exibir a relevância da base de artigos finais em função de uma ordem quantitativa (ENSSLIN et al., 2010).

Dentre as análises realizadas, a Figura 2 mostra a quantidade de artigos publicadas por ano. Nela, é possível observar o ano de 2019 como destaque. Muito disso, se deve ao fato de que o tema está ganhando cada vez mais espaço, e os artigos de 2020 e 2021, por serem recentes, ainda estão com pouca relevância de citações.

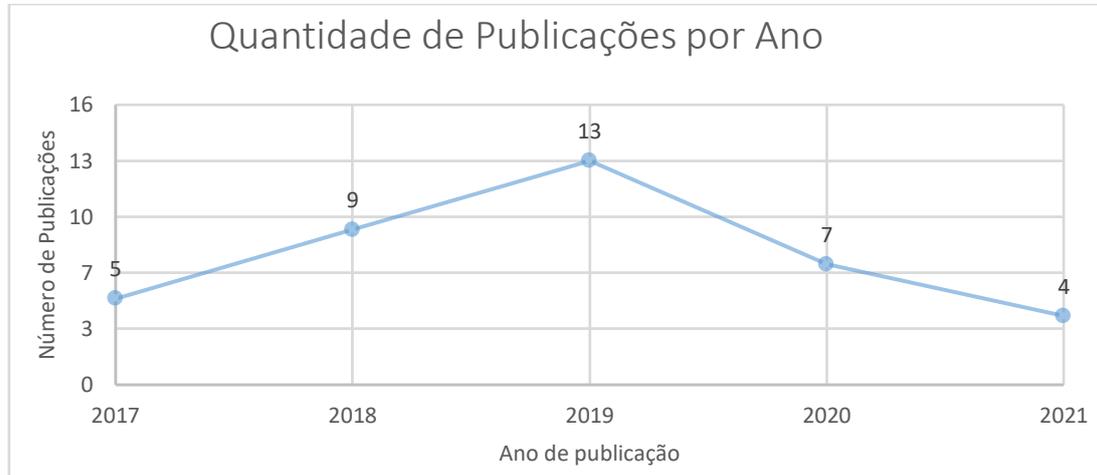


FIGURA 2 – Número de publicações por ano. Fonte: Os autores.

A Figura 3 mostra a relevância quanto ao número de citações, na qual pode-se destacar o artigo (WEN et al., 2018) com 516 citações e (CHEN; LI, 2017) com 304 citações.

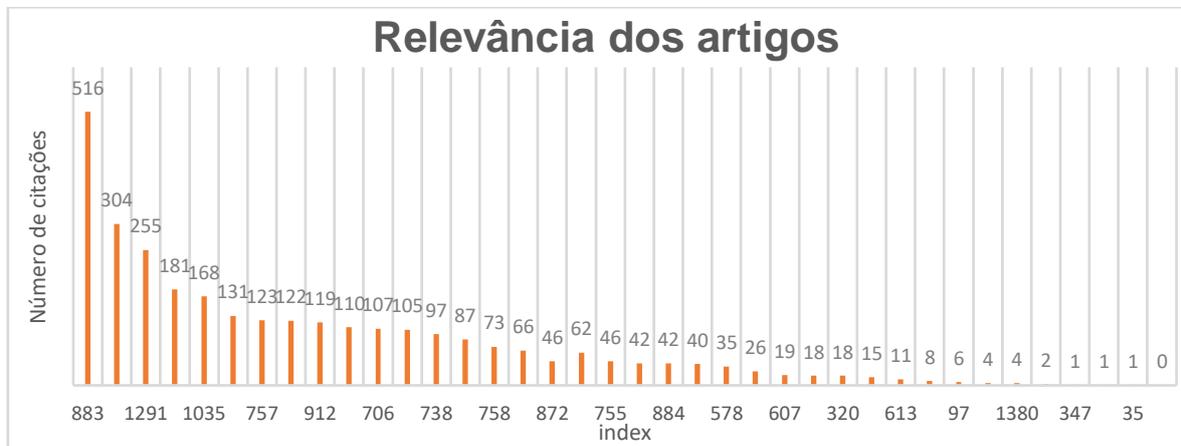


FIGURA 3 – Número de citações por artigos. Fonte: Os autores.

As palavras-chaves mais encontradas podem ser visualizadas na Figura 4. Destaque para “*fault diagnosis*”, “*convolution*” e “*deep learning*” com 18, 11 e 10 publicações, respectivamente.

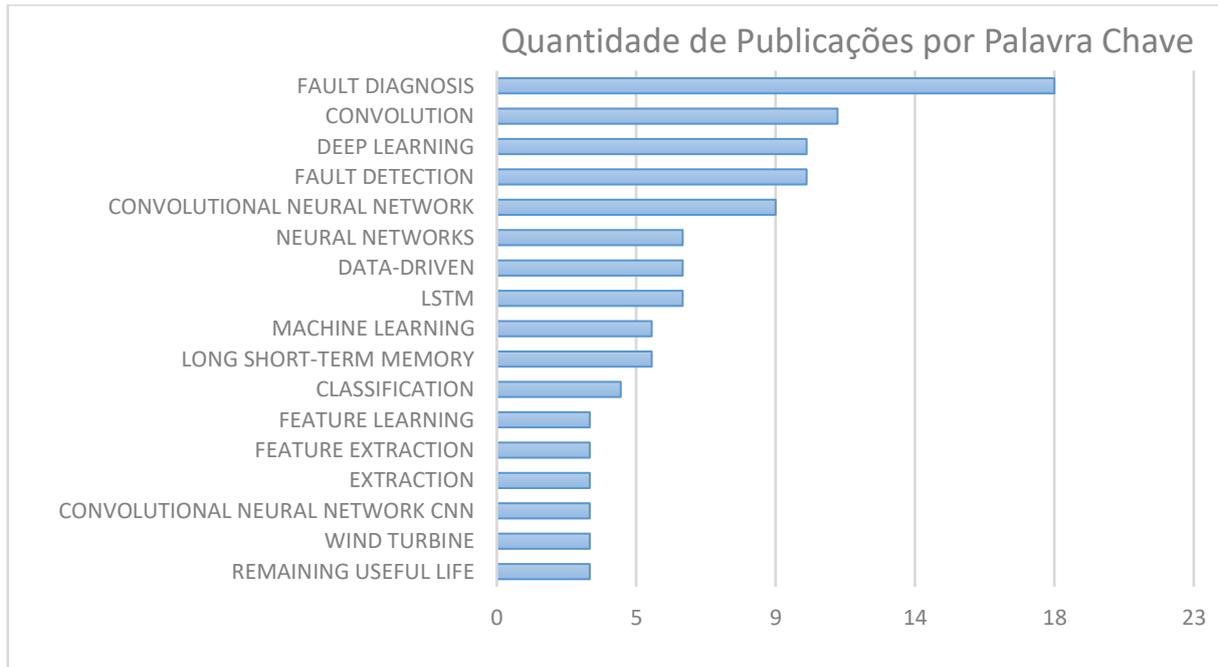


FIGURA 4 – Número de publicações por palavra-chave. Fonte: Os autores.

## 4. ANÁLISE SISTÊMICA

A partir da leitura dos 38 artigos que compõem o repositório final, foi realizada a análise sistemática. Para isso, foram extraídas as seguintes métricas dos artigos finais: problemas, soluções e oportunidades, as quais serão descritas a seguir.

### 4.1 Análise do Problema

Foram identificados cinco grupos de problemas, que serão mencionados a seguir:

**4.1.1 Processo de digitalização:** o advento da quarta revolução industrial trouxe à tona o conceito de fábricas inteligentes, as quais buscam excelência de controle de qualidade dos produtos e eficiência de processos que podem ser alcançados devido ao emprego de automação (XU *et al.*, 2019; YU; ZHAO, 2019). Park *et al.* (2018) indicam que o segredo das fábricas do futuro está relacionado com o diagnóstico precoce de falhas através do monitoramento da vida útil de equipamento. Isso leva, segundo Xia *et al.* (2020), à redução de paradas de produção baseadas nas manutenções preventivas e na diminuição de custos com substituições de elementos devido a manutenções corretivas.

**4.1.2 Dificuldade de extração de *features*:** um dos problemas encontrados nos trabalhos pesquisados está na extração de *features*, demonstrado no Quadro 4. Wen *et al.* (2018) indicam que nunca foi visto tanta disponibilidade de dados como nos dias de hoje, porém modelos de

ML que trabalham de forma estatística se tornaram ineficientes com o crescimento da geração de dados e o incremento de complexidade dos equipamentos industriais (HOANG; KANG, 2019).

Trabalhos	Descrição da abordagem
(CHEN; LI, 2017)	Apontam o processo árduo e exaustivo de extração manual de features, a qual também é totalmente dependente de conhecimentos prévios de operadores para realizar o processamento dos dados.
(ZHANG <i>et al.</i> , 2017) e (XU <i>et al.</i> , 2019)	Relatam a dificuldade desses modelos atuarem em condições de operações de máquinas, nas quais não foram treinados, ou na classificação de falhas não vistas no treinamento.
(LI; ZHANG; DING, 2018)	Acrescentam que as máquinas estão em plena mudança dos parâmetros de operação, logo o treinamento que é realizado para certas distribuições de dados não atende uma máquina por muito tempo
(ZHAO <i>et al.</i> , 2018)	Citam que as técnicas de ML estatística tem dificuldade de trabalhar com dados em tempo real por não apresentarem habilidade para extrair features em dados de alta frequência, normalmente encontrados em sinais de vibração e corrente.

QUADRO 4 – Trabalhos que demonstram a dificuldade de extrair *features*. Fonte: Os autores.

Yu e Zhao (2019) apontam para a realidade de existirem múltiplas falhas na indústria. Consequentemente, Ali *et al.* (2020) relatam a dificuldade de encontrar algoritmos que realizam diagnóstico de múltiplas falhas. Cheng *et al.* (2021) indicam que utilizar um único algoritmo para detectar falhas reduz a eficiência do diagnóstico, pois nem todas as falhas podem ser facilmente identificadas.

**4.1.3 Problemas nos sinais:** Ojo *et al.* (2021) citam que falhas em sensores geram problemas críticos para modelos de ML, pois podem causar previsões equivocadas. Segundo Sun *et al.* (2020), o crescimento da complexidade de sistemas de controle na indústria resulta no aumento do número de sensores, que reflete no incremento de falhas. Por isso, antes mesmo de realizar o diagnóstico de falhas, é necessário detectar falhas em sensores. Alguns trabalhos que demonstraram a preocupação com os ruídos podem ser vistos no Quadro 5.

Trabalhos	Descrição da abordagem
(SYAFRUDIN <i>et al.</i> , 2018)	Indicam que a presença de ruídos e outliers nos dados, prejudica a acurácia dos modelos de classificação
(HOANG; KANG, 2019)	Mencionam que sinais provenientes de máquinas possuem ruídos, por isso é necessário métodos para a limpeza dos dados
(PENG <i>et al.</i> , 2019)	Abordam a existência de ruídos em sinais de vibração de rolamentos de rodas de trem, principalmente ruídos de baixa frequência
(LI; ZHANG; DING, 2018)	Relatam a presença de ruídos em dados de rolamentos.

QUADRO 5 – Trabalhos que demonstram a presença de ruídos nos dados. Fonte: Os autores.

**4.1.4 Arquitetura em nuvem:** Park *et al.* (2018) indicam o crescente uso de sistemas em nuvem para acelerar a aplicação de soluções de diagnóstico de falhas, principalmente na análise de extensas quantidades de dados. Porém, Qiao, Wang e Wang (2020) apontam a presença de

latência na entrega de pacotes para diagnósticos em tempo real. Além disso, o custo de soluções em nuvem está diretamente atrelado ao armazenamento e processamento de dados.

**4.1.5 Motivações extras:** Esse trabalho levantou processos considerados críticos devido a sua complexidade, que necessitam de sistemas de diagnóstico de falhas e serão apresentados no Quadro 6.

Casos de uso	Descrição do trabalho
Monitoramento de baterias de íons-lítios	Qu <i>et al.</i> (2019) indica o crescente uso de baterias de íons-lítio em várias aplicações, principalmente em mobilidade. Porém Wang <i>et al.</i> (2019) acena para a presença de sérios riscos relacionados a sua aplicabilidade, principalmente pela presença de elementos químicos e físicos que possuem comportamentos atípicos em altos níveis de degradação.
Transformadores	Elementos sensíveis a falhas, principalmente pela exposição ao ambiente, como sol e chuva (ZHANG <i>et al.</i> , 2020).
Turbinas eólicas	Jiang <i>et al.</i> (2019) aponta para ocorrência de falhas de turbinas devido à exposição ao ambiente. Zhang <i>et al.</i> (2018) complementa que um dos motivos desses sistemas de geração de energia eólica ainda são considerados caros, pois estão sujeitos a frequente ocorrência de falhas, principalmente nas caixas redutoras e rolamentos.
Usinas Nucleares	Wang <i>et al.</i> (2021) descreve o a necessidade de um sistema de diagnóstico de falhas em usinas nucleares devido ao risco de vazamento de elementos radioativos
Motores Elétricos	Eren (2017) comenta sobre a importância de motores elétricos nas indústrias. Ali <i>et al.</i> (2020) complementa, que o correto funcionamento e o prolongamento da vida útil dependem exclusivamente de um bom sistema de diagnóstico de falhas que possa identificar de forma inicial o surgimento de eventos que que levam a possíveis falhas e inclusive danificação completa o dispositivo.
Rolamentos	Rolamentos são citados em vários trabalhos, principalmente pela alta criticidade em máquinas rotativas, pois são os elementos que mais geram falhas (HOANG; KANG, EREN; INCE; KIRANYAZ, 2019)

QUADRO 6 – Aplicação de diagnóstico de falhas em casos de uso. Fonte: Os autores.

## 4.2 Análise das Soluções

As análises de tendências de soluções para o diagnóstico de falhas em tempo real foram agrupadas em 4 grupos:

**4.2.1 Extração automática de *features*:** devido às dificuldades encontradas pelos modelos de estatísticos de ML em detectar falhas, foi visto, nessa pesquisa, uma tendência para o uso de técnicas de DL (QIAO; WANG; WANG, 2020). Zhang *et al.* (2017) indicam que DL tem a característica de automatizar a extração de *features*. Wen *et al.* (2018) complementam que modelos de DL têm a capacidade de extrair *features* abstratas de dados brutos de forma automática. E, por fim, Chen e Li (2017), Syafrudin *et al.* (2018) e Xia *et al.* (2020) indicam ótima performance de DL para atuar na fusão de dados a partir de múltiplos sensores. Essa medida se torna importante pois a acurácia do diagnóstico de falhas pode ser incrementada com os dados se complementando.

**4.2.2 Tendência de modelos:** os modelos mais vistos para diagnóstico de falhas foram o *Convolution Neural Network* (CNN) e o *Long Short-Term Memory* (LSTM). CNN é uma rede

neural que pode trabalhar no domínio do tempo em uma dimensão (1D) ou na conversão em imagens no domínio da frequência em duas dimensões (2D). Segundo Wen *et al.* (2018), esse modelo tem como característica fundamental a redução da dimensionalidade das *features* extraídas. Eren (2017) e Eren, Ince e Kiranyaz (2019) mencionam que, a partir do emprego do modelo 1D-CNN, é possível realizar a atuação em *time-series* sem a necessidade de pré-processamento dos dados. Já Jiang *et al.* (2019) indicam que o modelo 2D-CNN trabalha com a transformação dos dados para o domínio da frequência, convertendo os sinais em imagens, a partir das quais as *features* podem ser extraídas. Variações do modelo original são vistas no Quadro 7.

Autor	Derivação	Objetivo
(PENG <i>et al.</i> , 2019)	1D-CNN com <i>residual learning</i> e <i>convolutional kernel</i>	Detectar falhas em ambientes ruidosos
(ZHAO <i>et al.</i> , 2018) & (ISLAM; KIM, 2019)	<i>Wavelet</i>	Transformar dados para domínio da frequência
(WANG <i>et al.</i> , 2018)	Modelo de Markov com 2D-CNN	Predição de probabilidades de estados futuros nas funções de transição.

QUADRO 7 – Derivações de CNN. Fonte: Os autores.

Já redes LSTM têm a habilidade de indicar predições em tempo real, pois podem trabalhar com dados passados para refletir nas predições do futuro (CHENG *et al.*, 2021). Ojo *et al.* (2021) complementam que o modelo realiza predições de curto prazo com memórias de longo prazo. Algumas abordagens relacionadas com LSTM estão no Quadro 8.

Autor	Objetivo
(XIA <i>et al.</i> , 2020)	LSTM para realizar a predição de <i>Remaining Useful life</i> de forma online e em tempo para tomada de decisão.
(CABRERA <i>et al.</i> , 2020)	LSTM com otimizador dos parâmetros realizado pelo modelo <i>Bayesian Optimization</i> para trabalhar no diagnóstico de falhas em tempo real de compressores
(LEI; LIU; JIANG, 2019)	LSTM para diagnosticar falhas de múltiplos sensores com a fusão de dados

QUADRO 8 – Abordagens complementares de LSTM. Fonte: Os autores.

Como relatado por Cheng *et al.* (2021), o uso de um único classificador para processos complexos pode se tornar limitante. Por isso, entra em contexto o *Ensemble Learning* (EL), o qual utiliza vários classificadores para serem treinados e diagnosticar falhas, construindo, dessa maneira, uma variedade de hipóteses que podem ser observadas para resolver um determinado problema (YU; ZHAO, 2019). Alguns trabalhos sobre esse tema estão no Quadro 9.

Trabalhos	Descrição da abordagem
(SYAFRUDIN <i>et al.</i> , 2018)	Fusão de 4 algoritmos em um processo no setor automotivo
(ZHANG <i>et al.</i> , 2020)	Construção de um modelo de EL baseado em DBN e <i>auto-encoder</i> para eliminação de ruídos e classificadores individuais para identificar falhas e suas localizações em uma rede elétrica
(ZHANG <i>et al.</i> , 2018)	Uma combinação de <i>Random Forest</i> e <i>Extreme Gradient Boosting</i> na detecção de falhas de turbinas eólicas
(JIAHAO <i>et al.</i> , 2020)	Fusão de SVM com BiLSTM para diagnosticar falhas com alta acurácia em dados provenientes de dispositivos IOT

QUADRO 9 – Descrição do uso de EL em trabalhos contidos no repositório Final. Fonte: Os autores.

Outra tendência observada na pesquisa está relacionada com a transferência de aprendizagem. Zhang *et al.* (2017) indicam que os problemas de diferença entre dados de treinamento e de teste podem ser resolvidos com algoritmos chamados de *Transfer Learning* (TF). O objetivo dessa técnica é realizar o treinamento sobre dados que possuem uma determinada característica e transferir o modelo para realizar a inferência em dados similares, porém com outras características. Uma das aplicações desse modelo foi vista no desenvolvimento de um *Digital Twin*. Esse modelo virtual é capaz de simular dados de operações da máquina sob diferentes condições de trabalhos, além de simular falhas que podem ser utilizadas para treinar o modelo (XU *et al.*, 2019). Outras técnicas vistas na revisão estão presentes no Quadro 10.

Técnicas	Descrição
<i>Digital Twin</i> , <i>Convolution Gated Recurrent unit</i> e <i>Particle Swarm Optimization</i>	Wang <i>et al.</i> (2021) desenvolveu um <i>Digital Twin</i> para simular dados de processo. Em seguida, aliou esses dados do modelo virtual com as técnicas de <i>Convolution Gated Recurrent Unit (CGRU)</i> com otimização dos hiperparâmetros e um método de inchamento de partículas para diagnosticar falhas em equipamentos de usinas nucleares
Particle Swarm Optimization, attention mechanism e LSTM	Qu <i>et al.</i> (2019) utilizou o inchamento de partículas para otimizar os hiperparâmetros e aliou a um método chamado <i>attention mechanism</i> para calcular os pesos das features, e complementou com LSTM para estimar <i>State of Health (SOH)</i> e realizar previsões de <i>Remaining Useful Life (RUL)</i> de baterias
Decomposition Wavelet Transformation (DWT), Decision Tree Learning, <i>Support Vector Machine</i> e <i>K-Nearest Neighbor</i>	Ali <i>et al.</i> (2020) utilizou o DWT para transformar os dados no domínio da frequência, em várias faixas diferentes que permitem analisar os sinais de com multi resoluções. Após a extração das features, foram utilizados alguns classificadores como <i>Decision Tree Learning</i> , SVM e KNN e classificadores ensemble que uni vários algoritmos para classificar as falhas
Detecção de Anomalias e <i>density-based spational clustering</i>	Syafrudin <i>et al.</i> (2018) aplicou técnicas de detecção de outliers nos dados, entre elas está a <i>density-based spational clustering</i> para trabalhar com dados que contém alto nível de ruídos
<i>Wavelet</i> e <i>Support Vector Machine (SVR)</i>	Sun <i>et al.</i> (2020) criou um modelo para diagnosticar falhas em sensores baseado em <i>Wavelet</i> que pode ser dividido em extração de features em sinais e classificação de features, onde o <i>Wavelet</i> pode extrair features dos sinais e um classificador SVR é utilizado para diagnosticar e classificar as falhas nos sensores. Foram utilizada as 5 principais falhas de sinais de sensores.

QUADRO 10 – Descrição de técnicas complementares observadas na pesquisa. Fonte: Os autores.

**4.2.3 Computação em borda x nuvem:** Outra abordagem vista nas pesquisas está no local de armazenamento e processamento dos dados. Park *et al.* (2018) indicaram que o uso de nuvem permitiu o armazenamento e análise de dados em grande escala, sem a dependência de

estruturas físicas locais que demandam enorme investimento de recursos e manutenção. Por outro lado, o autor menciona o uso da tecnologia de computação de borda para eliminar o problema de latência de transmissão. Computação de borda, também conhecida como *Edge Computing* é existência da aplicação de um processo de computação que se localiza entre a fonte de geração de dados e o armazenamento em nuvem (SHI *et al.*, 2016). Para complementar, Qiao, Wang e Wang (2020) relatam para o uso de uma combinação entre computação em nuvem e em borda para reduzir os altos custos de estrutura em nuvem.

**4.2.4 Prognostic and health management (PHM):** outro assunto abordado na pesquisa foi o emprego de PHM. Park *et al.* (2018) mencionaram a importância do PHM na indústria para realizar prognósticos de falhas e previsões do fim de vida útil de equipamento. Segundo os autores, a aplicação de PHM se torna mais eficiente com o uso do *Data-Driven*, que permite a coleta e armazenamento de uma grande quantidade de dados, o que é útil para a análise de padrão de dados. Xia *et al.* (2020) relatam ainda que o PHM ganha cada vez mais espaço no prognóstico de condições de operação dos equipamentos e no auxílio na gestão de manutenção.

### 4.3 Análise das Oportunidades

Abaixo serão listados três grupos com indicações de oportunidades.

**4.3.1 Melhorias no método atual:** a maioria dos trabalhos sugeriu melhorias que serão realizadas nos próprios modelos, como visto no Quadro 11.

Trabalhos	Descrição das oportunidades
(WEN <i>et al.</i> , 2018)	Indicam a necessidade de adaptação do atual modelo para diagnosticar falhas desconhecidas
(LEE; CHEON; KIM, 2017)	Mencionam necessidade de aprofundamento da técnica utilizada
(ZHANG <i>et al.</i> , 2018), (EREN; INCE; KIRANYAZ, 2019), (XIA <i>et al.</i> , 2020) e (LEI; LIU; JIANG, 2019)	Indicam a necessidade de mais dados e diferentes condições de trabalho para serem utilizadas e testadas
(LI; ZHANG; DING, 2018)	Apontam otimização da estrutura da rede como sugestão de melhoria.
(EREN, 2017) & (SYAFRUDIN <i>et al.</i> , 2018)	Acenam para que mais dados de falhas seja utilizados para o modelo
(ISLAM; KIM, 2019)	Sugerem a aplicação do modelo em diagnóstico de falhas reais
(PARK <i>et al.</i> , 2018)	Apontam para a necessidade de dispositivo com mais memória, além requisitar a redução do tamanho de dados para treinamento
(YU; ZHAO, 2019), (WANG <i>et al.</i> , 2021) e (ZHANG <i>et al.</i> , 2020)	A validação deve ser realizada no diagnóstico de falhas outros sistemas
(RAZAVI-FAR <i>et al.</i> , 2019)	Como sugestão, os autores indicam o uso de múltiplas saídas e técnicas de trabalho em paralelo para reduzir o custo computacional
(JI <i>et al.</i> , 2021), (JIAHAO <i>et al.</i> , 2020) e (CHENG <i>et al.</i> , 2021)	Os autores mencionam a necessidade de melhorias para diagnosticar falhas em diferentes condições de trabalho e falhas desconhecidas
(QIAO; WANG; WANG, 2020)	Os autores tem a intenção de aplicar a arquitetura de computador de borda para outras máquinas
(OJO <i>et al.</i> , 2021)	Indicam melhorias em seu método para reduzir os falsos positivos.

QUADRO 11 – Sugestão de melhorias nos modelos pesquisados. Fonte: Os autores.

**4.3.2 Expansão do atual modelo:** os trabalhos do Quadro 12 mostram a intenção dos autores em expandir seus modelos.

Trabalhos	Descrição das oportunidades
(CHEN; LI, 2017)	Indicam o uso do modelo estudo com fusão de dados
(WANG <i>et al.</i> , 2019) & (JIANG <i>et al.</i> , 2019)	Mencionam a utilização do modelo para atuar sobre dados brutos.
(WANG <i>et al.</i> , 2018)	Sugerem expandir a utilização do modelo para sistemas mais complexos.
(PENG <i>et al.</i> , 2019)	Pensam em introduzir (TF) e <i>multi-scale learning</i> no atual sistema
(EREN, 2017)	Supõe a implementação de hardware com FPGA para o modelo
(ZHANG <i>et al.</i> , 2020)	Apontam a utilização de mais funções de ativação e classificadores
(WANG <i>et al.</i> , 2019)	Introduzem a ideia de aplicar a técnica de <i>multi-kernel</i> para predição

QUADRO 12 – Sugestão de expansão dos sistemas propostos. Fonte: Os autores.

**4.3.3 Demais oportunidades:** demais oportunidades são encontradas no Quadro 13.

Trabalhos	Descrição das oportunidades
(WEN <i>et al.</i> , 2018)	Apontam para o uso de TF com intenção de reduzir o tempo de treinamento
(JIANG <i>et al.</i> , 2019)	Irão trabalhar para melhorar o modelo com o incremento de dados desbalanceados
(HOANG; KANG, 2019)	Indicam a necessidade de criar um método de seleção automática dos hiper parâmetros
(LEI; LIU; JIANG, 2019)	Menciona a oportunidade de utilizar CNN para reduzir dimensões dos dados de entrada para métodos LSTM
(PARK <i>et al.</i> , 2018)	Sugere o uso de modelos mais simples no Edge como GRU para reduzir o processamento
(QIAO; WANG; WANG, 2020)	Aponta para a necessidade de relacionar desgaste de ferramenta com perda de qualidade da peça

QUADRO 13 – Oportunidades complementares encontradas na pesquisa. Fonte: Os autores.

## 5. CONCLUSÃO

A revisão sistêmica e bibliométrica realizada nesse trabalho com o uso do método Proknow-C retornou 38 artigos alinhados com o tema de diagnóstico de falhas em equipamentos em tempo real. A análise bibliométrica resgatou as palavras-chaves mais utilizadas, com destaque para “fault diagnosis” e “deep learning”.

Já a análise sistêmica apontou para a redução de custos, a partir da detecção de falhas em equipamentos de forma precoce através de ML. Porém, técnicas estatísticas possuem dificuldades para extrair features de grandes quantidades de dados e sistemas complexos. A solução encontrada foi a aplicação de DL. Essa técnica tem a capacidade de extrair *features* de forma automática, além de possuir maior facilidade de aprender com múltiplos sensores e dados com diferentes distribuições.

CNN e LSTM foram as redes neurais mais encontradas na pesquisa. A primeira reduz a dimensão de dados, enquanto a segunda realiza previsões com dados em tempo real. Como oportunidade de pesquisa, foi sugerido o uso de TL na intenção de reduzir o tempo de treinamento dos algoritmos. Também, observou a lacuna de algoritmos mais leves para trabalharem em computação de borda e por último a busca pelo uso de EL, a qual se utiliza de diferentes métodos para realizar a classificação de múltiplas falhas de maneira mais precisa.

## 6. AGRADECIMENTOS

Esse trabalho é apoiado pela Fundação de Desenvolvimento da Pesquisa - Fundep - Rota 2030.

## 7. REFERÊNCIAS

- ALI, M. Z. *et al.* Single- and multi-fault diagnosis using machine learning for variable frequency drive-fed induction motors. **IEEE Transactions on Industry Applications**, v. 56, n. 3, p. 2324–2337, 2020.
- CABRERA, D. *et al.* Bayesian approach and time series dimensionality reduction to LSTM-based model-building for fault diagnosis of a reciprocating compressor. **Neurocomputing**, v. 380, p. 51–66, 2020.
- CHEN, Z.; LI, W. Multisensor feature fusion for bearing fault diagnosis using sparse autoencoder and deep belief network. **IEEE Transactions on Instrumentation and Measurement**, v. 66, n. 7, p. 1693–1702, 2017.
- CHENG, Y. *et al.* Remaining useful life prognosis based on ensemble long short-term memory neural network. **IEEE Transactions on Instrumentation and Measurement**, v. 70, Oct. 2021. DOI: 10.1109/TIM.2020.3031113.
- ENSSLIN, L. *et al.* **ProKnow-C, knowledge development process – constructivist**. [S.l.:s.n.], 2010. Processo técnico com patente de registro pendente junto ao INPI.
- EREN, L. Bearing fault detection by one-dimensional convolutional neural networks. **Mathematical Problems in Engineering**, v. 2017, 2017. DOI: <https://doi.org/10.1155/2017/8617315>.
- EREN, L.; INCE, T.; KIRANYAZ, S. A Generic intelligent bearing fault diagnosis system using compact adaptive 1D CNN classifier. **Journal of Signal Processing Systems**, v. 91, n. 2, p. 179–189, 2019.
- HOANG, D. T.; KANG, H. J. Rolling element bearing fault diagnosis using convolutional neural network and vibration image. **Cognitive Systems Research**, v. 53, p. 42–50, 2019.
- ISLAM, M. M. M.; KIM, J. M. Automated bearing fault diagnosis scheme using 2D representation of wavelet packet transform and deep convolutional neural network. **Computers in Industry**, v. 106, p. 142–153, 2019.
- JI, X. *et al.* Real-time robust forecasting-aided state estimation of power system based on data-driven models. **International Journal of Electrical Power and Energy Systems**, v. 125, Aug. 2020. DOI: 10.1016/j.ijepes.2020.106412.

- JIAHAO, Y. *et al.* SVM-BILSTM: a fault detection method for the gas station IoT system based on deep learning. **IEEE Access**, v. 8, p. 203712–203723, 2020.
- JIANG, G. *et al.* Multiscale convolutional neural networks for fault diagnosis of wind turbine gearbox. **IEEE Transactions on Industrial Electronics**, v. 66, n. 4, p. 3196–3207, 2019.
- JUN, H. B.; KIRITSIS, D. Several aspects of information flows in PLM. **IFIP Advances in Information and Communication Technology**, v. 388 AICT, p. 14–24, 2012.
- LEE, K. B.; CHEON, S.; KIM, C. O. A Convolutional neural network for fault classification and diagnosis in semiconductor manufacturing processes. **IEEE Transactions on Semiconductor Manufacturing**, v. 30, n. 2, p. 135–142, 2017.
- LEI, J.; LIU, C.; JIANG, D. Fault diagnosis of wind turbine based on Long Short-term memory networks. **Renewable Energy**, v.133, p.422-432,2019. DOI: 10.1016/j.renene.2018:i:c:p:422-432.
- LI, X.; ZHANG, W.; DING, Q. A Robust intelligent fault diagnosis method for rolling element bearings based on deep distance metric learning. **Neurocomputing**, v. 310, p. 77–95, 2018.
- OJO, O. *et al.* A Neural network based method for thermal fault detection in lithium-ion batteries. **IEEE Transactions on Industrial Electronics**, v. 68, n. 5, p. 4068–4078, 2021.
- PARK, D. *et al.* Lired: a light-weight real-time fault detection system for edge computing using LSTM recurrent neural networks. **Sensors (Switzerland)**, v. 18, n. 7, 2018. DOI: <https://doi.org/10.3390/s18072110>.
- PENG, D. *et al.* A Novel deeper one-dimensional CNN with residual learning for fault diagnosis of wheelset bearings in high-speed trains. **IEEE Access**, v. 7, p. 10278–12093, 2019.
- QIAO, H.; WANG, T.; WANG, P. A Tool wear monitoring and prediction system based on multiscale deep learning models and fog computing. **International Journal of Advanced Manufacturing Technology**, v. 108, n. 7–8, p. 2367–2384, 2020.
- QU, J. *et al.* A Neural-network-based method for RUL prediction and SOH monitoring of lithium-ion battery. **IEEE Access**, v. 7, p. 87178–87191, 2019.
- RAZAVI-FAR, R. *et al.* An Integrated imputation-prediction scheme for prognostics of battery data with missing observations. **Expert Systems with Applications**, v. 115, p. 709–723, 2019.
- SHI, W. *et al.* Edge computing: vision and challenges. **IEEE Internet of Things Journal**, v. 3, n. 5, p. 637–646, 2016.
- SUN, R. *et al.* A Coupling diagnosis method of sensors faults in gas turbine control system. **Energy**, v. 205, 2020. DOI: 10.1016/j.energy.2020.117999.
- SYAFRUDIN, M. *et al.* Performance analysis of IoT-based sensor, big data processing, and machine learning model for real-time monitoring system in automotive manufacturing. **Sensors (Switzerland)**, v. 18, n. 9, 2018. DOI: <https://doi.org/10.3390/s18092946>.
- WANG, H. *et al.* Advanced fault diagnosis method for nuclear power plant based on convolutional gated recurrent network and enhanced particle swarm optimization. **Annals of Nuclear Energy**, v. 151, 2021. DOI: 10.1016/j.anucene.2020.107934.
- WANG, S. *et al.* Convolutional neural network-based hidden Markov models for rolling element bearing fault identification. **Knowledge-Based Systems**, v. 144, p. 65–76, 2018.

WANG, Y. *et al.* Remaining useful life prediction of lithium-ion batteries using support vector regression optimized by artificial bee colony. **IEEE Transactions on Vehicular Technology**, v. 68, n. 10, p. 9543–9553, 2019.

WEN, L. *et al.* A New convolutional neural network-based data-driven fault diagnosis method. **IEEE Transactions on Industrial Electronics**, v. 65, n. 7, p. 5990–5998, 2018.

XIA, M. *et al.* Data-driven prognosis method using hybrid deep recurrent neural network. **Applied Soft Computing Journal**, v. 93, 2020. DOI: <https://doi.org/10.1016/j.asoc.2020.106351>.

XU, Y. *et al.* A Digital-twin-assisted fault diagnosis using deep transfer learning. **IEEE Access**, v. 7, p. 19990–19999, 2019.

YU, W.; ZHAO, C. Online fault diagnosis for industrial processes with bayesian network-based probabilistic ensemble learning strategy. **IEEE Transactions on Automation Science and Engineering**, v. 16, n. 4, p. 1922–1932, 2019.

ZHANG, C. *et al.* Transformer fault diagnosis method using IoT based monitoring system and ensemble machine learning. **Future Generation Computer Systems**, v. 108, p. 533–545, 2020.

ZHANG, D. *et al.* A Data-driven design for fault detection of wind turbines using random forests and XGboost. **IEEE Access**, v. 6, p. 21020–21031, 2018.

ZHANG, R. *et al.* Transfer learning with neural networks for bearing fault diagnosis in changing working conditions. **IEEE Access**, v. 5, p. 14347–14357, 2017.

ZHAO, M. *et al.* Deep residual networks with dynamically weighted wavelet coefficients for fault diagnosis of planetary gearboxes. **IEEE Transactions on Industrial Electronics**, v. 65, n. 5, p. 4290–4300, 2018.