

**UNIVERSIDADE DO VALE DO RIO DOS SINOS - UNISINOS
UNIDADE ACADÊMICA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO
APLICADA NÍVEL MESTRADO**

MIROMAR JOSÉ DE LIMA

**HEALTHMON: UM NOVO SISTEMA PARA PROVER MANUTENÇÃO
PREVENTIVA DE MÁQUINAS ATRAVÉS DA IDENTIFICAÇÃO DE
EVOLUÇÕES DE FALHAS EM CONJUNTO DE SÉRIES TEMPORAIS**



São
Leopoldo
2020

Miromar José de Lima

HEALTHMON: UM NOVO SISTEMA PARA PROVER MANUTENÇÃO
PREVENTIVA DE MÁQUINAS ATRAVÉS DA IDENTIFICAÇÃO DE EVOLUÇÕES
DE FALHAS EM CONJUNTO DE SÉRIES TEMPORAIS

Dissertação apresentada como requisito parcial para a obtenção do título de Mestre pelo Programa de Pós-Graduação em Computação Aplicada da Universidade do Vale do Rio dos Sinos - UNISINOS

Orientador:

Prof. Dr. Rodrigo da Rosa Righi

Coorientador:

Prof. Dr. Cesar David Paredes Crovato

São
Leopoldo
2020

L732h

Lima, Miromar José de.

Healthmon: um novo sistema para prover manutenção preventiva de máquinas através da identificação de evoluções de falhas em conjunto de séries temporais / Miromar José de Lima. – 2020.

133 f. : il. ; 30 cm.

Dissertação (mestrado) – Universidade do Vale do Rio dos Sinos, Programa de Pós-Graduação em Computação Aplicada, 2020.

“Orientador: Prof. Dr. Rodrigo da Rosa Righi

Coorientador: Prof. Dr. Cesar David Paredes Crovato.”

1. Manutenção preventiva. 2. Monitoramento. 3. Conjunto de séries temporais. 4. Aprendizado de máquina. 5. Indústria 4.0.

CDU 004.732

Dados Internacionais de Catalogação na Publicação (CIP)
(Bibliotecária: Amanda Schuster – CRB 10/2517)

AGRADECIMENTOS

Primeiramente, agradeço à Deus pela impagável oportunidade em permitir que eu realize este grande sonho. Agradeço pela maravilhosa esposa, companheira e amiga, por estar sempre ao meu lado, apoiando e cuidando de nosso pequeno anjo, nos momentos em que preciso me ausentar em função dos trabalhos e estudos.

Ao meu anjinho Ágatha, minha doce e querida filhinha, fonte de minha inspiração.

Agradeço em especial a todos os Professores, com "P" maiúsculo, pois é assim que eu os considero, sintam-se todos prestigiados. Pessoas incríveis e profissionais fantásticos que não medem esforços para nos ajudar nesta caminhada.

Em especial, ao meu orientador Dr. Rodrigo Righi, um grande ser humano, parceiro e amigo, sempre apoiando e orientando, com alto grau de intelecto, mas com uma simplicidade inigualável. Até mesmo nos momentos mais difíceis, apesar das grandes demandas, sempre consegue reservar tempo para seus orientandos.

Ao meu coorientador Dr. Cesar Crovato, dono de singular simpatia. Agradeço-te por compartilhar seu nobre conhecimento na implementação desta incrível solução: a HealthMon.

Ao Professor Dr. Gabriel Ramos, por dedicar seu precioso conhecimento e tempo para elevar ainda mais a qualidade de nossos trabalhos.

Ao Professor Dr. Cristiano Costa, por ser a "primeira mão" que apertei no PPGCA, docente este que me transmitiu grande sentimento de acolhimento e receptividade ao ingressar no curso, cujas aulas são ministradas com extrema maestria.

Ao Professor Dr. Ivan Mejia, um grande intelectual cheio de alegria e entusiasmo.

Aos nobres colegas de curso e de projeto que somaram muito, permitindo que fosse possível chegar nos belos resultados atingidos, especialmente ao Lincoln Vinicius Schreiber, grande parceiro. Aos colegas Rafael Viana e ao Henrique Kuhn por todo apoio e parceria.

À Universidade como um todo, ao nobre reitor Pe. Marcelo F. de Aquino, por permitir essa cultura maravilhosa e humana, ao Professor Dr. Celso Piter, coordenador do ITT Chip, que nos apoiou ativamente em todo tempo.

À empresa HT Micron por ser parceira e patrocinadora do presente projeto.

Enfim, sou muito grato a todos. Quero que saibam que todos ficarão eternizados em minha memória e coração. Agradeço por tudo que fizeram e ainda estão fazendo. Saibam que através desta oportunidade ímpar, está sendo possível elevar minha vida para outro patamar.

RESUMO

No contexto da Indústria 4.0, monitorar a degradação de máquinas para antecipar possíveis falhas representa um desafio significativo. Essa tarefa é especialmente importante quando os custos impostos pela manutenção e pela parada nos processos produtivos são altos. Atualmente, muitas técnicas de manutenção preventiva empregam algoritmos de aprendizado de máquina supervisionados ou não supervisionados. No entanto, a definição de quais variáveis devem ser processadas por esses algoritmos não é uma tarefa simples, sendo crucial para o sucesso da técnica proposta. Dada essa perspectiva, consideramos se algoritmos não supervisionados combinados com a decomposição de séries temporais podem contribuir para melhorar a saúde das máquinas de monitoramento. Neste trabalho, propomos o HealthMon, que se trata de uma nova abordagem, cuja função é calcular um índice de integridade de máquinas com base em medições de sensores. O HealthMon extrai séries temporais desses sensores, que são decompostos de uma maneira nova e sem supervisão, além de serem usados a fim de calcular o índice de integridade dessa máquina. Esse índice de integridade está relacionado à degradação da máquina considerada, sendo útil, portanto, para otimizar o cronograma de manutenção da máquina. O presente trabalho avança o estado da arte nos seguintes quesitos: (i) propõe um índice global de saúde, que oferece uma visão mais direta e intuitiva da degradação da máquina; (ii) elabora uma abordagem capaz de estimar o índice de integridade de uma máquina, enquanto apenas o conhecimento básico sobre o funcionamento (interno) da máquina é necessário; (iii) oferece uma extensa gama de aplicabilidade, já que é escalável a ponto de poder ser utilizado em qualquer tipo de máquina vibratória ou rotativa. O nosso método foi avaliado mediante extensas simulações em um motor de indução. Os resultados mostraram que a degradação pode ser efetivamente detectada sob várias cargas de trabalho de entrada. Ademais, cabe salientar que o HealthMon foi avaliado por meio do uso de dados reais. Nesse caso, é interessante frisar que, em ambas as avaliações, verificamos que os resultados obtidos foram promissores de modo a confirmar nossa hipótese.

Palavras-chave: Manutenção preventiva. Monitoramento. Conjunto de séries temporais. Aprendizado de máquina. Indústria 4.0.

ABSTRACT

In the context of Industry 4.0, monitoring machine degradation to anticipate possible failures represents a significant challenge. That task is especially important when the costs imposed by maintenance and stopping production processes are high. Nowadays, many preventive maintenance techniques employ supervised or unsupervised machine learning algorithms. However, the definition of which variables should be processed by those algorithms is not a simple task, being crucial for the success of the proposed technique. Given this perspective, we consider whether unsupervised algorithms combined with the decomposition of time series can contribute to improve the health of monitoring machines. In this research, we propose HealthMon, which is a new approach, whose function is to calculate a machine integrity index based on sensor measurements. HealthMon extracts time series from those sensors, which are decomposed in a new and unsupervised way, in addition to being used to calculate the integrity index of that machine. That integrity index is related to the degradation of the machine considered, being useful, therefore, to optimize the maintenance schedule of the machine. This research advances the state of art in the following points: (i) proposes a global index of health, which offers a more direct and intuitive view of machine degradation; (ii) elaborates an approach capable of estimating the integrity index of a machine, while only basic knowledge about the (internal) operation of the machine is necessary; (iii) offers an extensive range of applicability, since it is scalable so that it can be used in any type of vibrating or rotating machine. Our method was evaluated through extensive simulations on an induction motor. The results have shown that the degradation can be effectively detected under various input workloads. Besides, it is worth noting that HealthMon was evaluated through the usage of real data. In this regard, it's interesting to highlight that, in both evaluations, we found that the results obtained were promising with regard to our hypothesis.

Keywords: Preventive maintenance. Monitoring. Set of time series. Machine learning. Industry 4.0.

LISTA DE FIGURAS

Figura 1 – Pipeline de atividades do HealthMon, a partir da entrada do usuário até a geração de Índice Global de Saúde (IGS).....	22
Figura 2 – Fluxograma das etapas de desenvolvimento da pesquisa.....	25
Figura 3 – Revolução Industrial	28
Figura 4 – Análise comparativa entre a Indústria nos dias atuais e a Indústria 4.0.....	29
Figura 5 – Curva da Banheira.....	31
Figura 6 – Processo de Quebra de Máquina/Equipamento.....	32
Figura 7 – Linha do Tempo da Manutenção Industrial.....	35
Figura 8 – Taxonomia Da Manutenção.....	36
Figura 9 – Manutenção Centrada na Confiabilidade (MCC).....	37
Figura 10 – Distribuição do consumo de energia elétrica por uso final na indústria.....	38
Figura 11 – Distribuição do consumo de energia elétrica na força motriz na indústria.....	39
Figura 12 – Pesquisa de Implantação do Paradigma da Indústria 4.0.....	41
Figura 13 – Mapeamento de <i>Machine Learning</i>	46
Figura 14 – Classificação de <i>Machine Learning</i>	47
Figura 15 – Exemplo de Aplicação do Algoritmo K-means.....	50
Figura 16 – Exemplo Algoritmo Genético Clássico.....	52
Figura 17 – Aplicações de IoT.....	54
Figura 18 – <i>String</i> de Busca	60
Figura 19 – Bases de Busca resultantes da <i>String</i> de Busca.....	61
Figura 20 – Trabalhos resultantes da <i>String</i> de Busca, classificados por tipo.....	62
Figura 21 – Processo de seleção dos artigos.....	63
Figura 22 – Artigos selecionados.....	63
Figura 23 – Fluxograma do Funcionamento do HealthMon.....	81
Figura 24 – HealthMon Arquitetura de Alto Nível.....	82
Figura 25 – Módulo de Processamento de Sinais (SPM). Processamento que envolve rastreamento espectral e criação de tendências.....	83
Figura 26 – Matriz A resultante do SPM - Dados Sintéticos e Reais.....	86
Figura 27 – Processo para criação da Matriz A', que é resultante do processamento da Matriz A (Fase 2 na Figura 3).....	87

Figura 28 – Resultados obtidos para o cenário de teste com dados reais – CST.....	91
Figura 29 – Matriz A resultante do SPM em testes - Dados Sintéticos.....	97
Figura 30 – Ensaio Realizados.....	102
Figura 31 – Equipamento usado para experimento com dados reais.....	103
Figura 32 – Fluxograma para avaliação do HealthMon com dados reais.....	104
Figura 33 – Bancada de simulações de falhar com motor elétrico (MFS).....	105
Figura 34 – Resultados obtidos em cenário de teste com dados sintéticos.....	108
Figura 35 – Comparação envolvendo os algoritmos CST, GA e ILS, avaliando métricas de monotonicidade e tempos de execução.....	108
Figura 36 – Resultados obtidos para o cenário de teste com dados reais – Sinais.....	110
Figura 37 – Resultados obtidos para o cenário de teste com dados reais – CST.....	110
Figura 38 – Resultados obtidos para o cenário de teste com dados reais – GA.....	111
Figura 39 – Comparação de desempenho de algoritmos com dados reais.....	113
Figura 40 – Comparação de monotonicidade obtida a partir dos algoritmos com dados reais.....	114

LISTA DE TABELAS

Tabela 1 – Análise Comparativa entre Aprendizado Supervisionado vs. Não Supervisionado	48
Tabela 2 – Análise Comparativa entre trabalhos relacionados revisão sistemática.....	71
Tabela 3 – Análise Comparativa Algorítmica - Monotonicidade e Desempenho.....	109
Tabela 4 – Análise Comparativa Desempenho de Tempo em minutos.....	112
Tabela 5 – Análise Comparativa de Índice de Monotonicidade	113

LISTA DE SIGLAS

API	Application Programming Interface
CBM	Manutenção baseada em condições
CPS	Sistemas Ciber-Físicos
IM	Induction Motor/Motor "Elétrico"por Indução
IoT	Internet of Things
MFS	Machinery Fault Simulator
MPS	Módulo de Processamento de Sinais
MPT	Manutenção Produtiva Total
MCC	Manutenção Centrada na Confiabilidade
MO	Módulo de Otimização
OM	Otimization Module
PID	Proportional Integral Derivative
TPM	Total Productive Maintenance
RCM	Reliability-Centred Maintenance
RFID	Radio Frequency Identification/Radiofrequência
SPM	Signals Processing Module
TI	Tecnologia da Informação

SUMÁRIO:

1 INTRODUÇÃO	14
1.1 Motivação	16
1.2 Questão de Pesquisa	19
1.3 Objetivos	20
Etapas de Desenvolvimento da Pesquisa	22
1.5 Organização do Texto	23
2 FUNDAMENTAÇÃO TEÓRICA	26
2.1 Indústria 4.0	26
2.2 Falhas em Máquinas Industriais e seus Impactos	30
2.3 Manutenção em Máquinas Industriais	33
2.3.1 Abordagem para a Manutenção	35
2.3.2 Oportunidades com a Indústria 4.0	40
2.3.3 Recurso, Técnicas e Estratégias para Manutenção na Indústria 4.0	41
2.4 Inteligência Artificial, Técnicas de Machine Learning e Tecnologias Relacionadas	43
2.4.1 Machine Learning	44
2.4.3 Big Data no contexto da Indústria 4.0	54
2.4.4 Séries Temporais	55
2.5 Considerações parciais	57
3 TRABALHOS RELACIONADOS	58
3.1 Metodologia de Pesquisa para Seleção dos Trabalhos	58
3.2 Estado da Arte	63
3.2.1 Trabalhos Relacionados Obtidos em uma Revisão Sistemática	64
3.3 Análise e Oportunidades dos Trabalhos	74
3.4 Considerações Parciais	75
4 O HEALTHMON	76
4.1 Arquitetura HealthMon	77
4.1.1 Fase 1: Preparação e parametrização do ambiente	78
4.1.2 Fase 2: Trenderização - Processo de decomposição de sinal e identificação de tendências	81
4.1.3 Fase 3: Redução de dimensionalidade - Reduzindo de um espaço multidimensional para um espaço bidimensional.	86
4.1.4 Fase 4: Agrupamento dos Sinais em Tendências	87
4.1.5 Fase 5: Gerar IGS - Índice Global de Saúde de Máquina	88
4.1.6 Fase 6: Identificando o Conjunto de Tendências Relevantes	90
4.2 Considerações parciais	93
5 METODOLOGIA DE AVALIAÇÃO	94
5.1 Modelo de falha do motor de indução - Dados Sintético	94
5.1.1 Mecanismo SPM - Dados Sintéticos e Reais	95
5.1.2 Mecanismo de Otimização - Dados Sintéticos e Reais	96

5.1.3 Modelagem de testes - Dados Sintéticos	96
5.2 Protótipo - Dados Sintéticos	98
5.2.1 Avaliação com Protótipo - Dados Sintéticos	98
5.2.2 Cenários de avaliação - Dados Sintéticos	98
5.2.3 Parâmetros dos Algoritmos de Otimização - Dados Sintéticos	99
5.3 Testes e Avaliação - Dados Reais	100
5.3.1 Cenários de Avaliação - Dados Reais	101
5.3.2 Modelagem de testes - Dados Reais	102
5.4 Considerações parciais	104
6 RESULTADOS	106
6.1 Avaliação com Dados Sintéticos	106
6.2 Avaliação com Dados Reais	109
6.3 Considerações Parciais	115
7 CONCLUSÃO	116
7.1 Contribuições	116
7.2 Limitações e Trabalhos Futuros	117
REFERÊNCIAS	118

1 INTRODUÇÃO

Estudos com base na literatura de Engenharia Elétrica revelam que, em plantas industriais, cerca de 85 % do consumo de energia provém de motores de indução (IM) (RANGEL-MAGDALENO et al., 2009; CHOUDHARY; DUBEY, 2019). Nesse caso, é interessante informar que esse fato coloca os IMs entre os elementos mais críticos nas operações de uma fábrica (RANGEL-MAGDALENO et al., 2009). Dentre as várias vantagens verificadas em IMs, uma merece destaque que é a de ser uma máquina robusta, funcional e bem conhecida na indústria, a qual mesmo apresentando muitos tipos de falhas, ainda assim é capaz de se manter em funcionamento (EL; BENBOUZID; MEMBER, 2000; GUPTA; RAO, 2019). Graças a essas características, tornou-se um elemento crucial e indispensável para compor a planta industrial, o que permite presumir que a maioria das máquinas conta com esse recurso.

Assim como em todas as máquinas, faz-se necessário realizar a manutenção preventiva em IMs a fim de evitar falhas incipientes ou condições de degradação que podem aumentar rapidamente ao longo do tempo, gerando conseqüentemente falhas consumadas que podem resultar em custos ainda mais altos do que na manutenção preventiva (RAN et al., 2019). Assim, para realizar a manutenção preventiva em IMs, a medição da corrente do estator seria suficiente para determinar a saúde do motor. No entanto, frisamos que a medição da corrente do estator de um IM, embora conceitualmente simples, pode ser complicada na prática (LORENZ et al., 1994). Por exemplo, sabe-se que os cabos de alimentação dessas máquinas são protegidas por tubos, os quais não podem ser facilmente acessados ou abertos por razões de segurança de maneira a tornar difícil a medição da corrente de fase individual em tais dispositivos. Além disso, destacamos que a caixa de ligação costuma ser tipicamente apertada, seu manuseio, delicado e a instalação de dispositivos de medição de corrente em painéis elétricos, um processo demorado que exige planejamento do espaço, autorização, incluindo alguns trâmites legais, para obedecer as normas e os requisitos de segurança industrial (ZHANG et al., 2011).

Apesar desses problemas, as falhas nos MIs tendem a ser recorrentemente modeladas computacionalmente (SINGH et al., 2016), o que os torna candidatos para a avaliação de sistemas de detecção de falhas em evolução. Atualmente, é possível encontrar diversas teorias e modelos de falha que aconselham quando realizar a manutenção preventiva de uma máquina de IM (TERRA et al., 2005; MEHALA; DAHIYA, 2007). Ademais, salientamos que há uma outra possibilidade de se medir a vibração de IM em vários pontos de modo a

viabilizar a geração do indicador de saúde do IM (AZEEM et al., 2019). Todavia, percebemos que não existem abordagens completas e universalmente válidas com base nos modos de vibração em IM. Nesse sentido, é essencial lembrar que *hardwares* complexos como Simuladores de Falha em Máquinas (MFS), em combinação com *softwares* e técnicas de *Machine Learning* (ML), por meio de abordagens de aprendizagem de máquina supervisionada, também estão sendo utilizados para determinar a degradação de IM (AZEEM et al., 2019; KANKAR; SHARMA; HARSHA, 2011). Contudo, é válido enfatizar que o uso de uma abordagem supervisionada, nesse tipo de contexto, pode vir a ser questionável quando o sistema físico usado para recolher as assinaturas de falhas é diferente do sistema físico, no qual o algoritmo irá ser utilizado (o lugar e a máquina de destino em si). Mesmo que ambos os sistemas sejam os mesmos no início, qualquer mudança no ambiente ou no próprio IM, após a manutenção preventiva, pode causar desvios nos modelos no decorrer da coleta de dados para a formação dos dados com a aplicação de técnicas de algoritmos supervisionados (ROH; HEO; WHANG, 2018). Por conta disso, eles podem gerar algoritmos supervisionados menos preferíveis, principalmente em sistemas cujos modelos são dependentes de parâmetros com alta sensibilidade a alterações (AMINIKHANGHAHI; COOK, 2017).

Abordagens supervisionadas são prejudicadas quando não há dados previamente rotulados disponíveis, ou seja, no momento em que dificultam a aplicação ou inviabilizam esse tipo de abordagem. Por outro lado, abordagens de aprendizagem de máquina baseados em dados podem ser aplicados na tentativa de extrair informações de um conjunto de séries temporais (AMINIKHANGHAHI; COOK, 2017). No entanto, citamos que para isso, é necessário definir quais séries temporais são relevantes para analisar e contar com o apoio da Inteligência Artificial (IA). A esse respeito, verificamos que muitos trabalhos costumam buscar soluções por intermédio das técnicas de IA, porém envolvendo abordagens supervisionadas (evidenciando as lacunas já apresentadas) ou abordagens híbridas. Nesse caso, é fundamental dizer que não identificamos, por meio das pesquisas, a adoção de uma abordagem que fosse puramente não supervisionada. Em vista disso, o presente trabalho buscou propor o HealthMon, cuja principal funcionalidade é a geração de um índice global de saúde da máquina (IGS/GHI). Para que isso seja viável, a abordagem aplica a decomposição dos sinais obtidos dos sensores da máquina, obtendo em várias tendências que resultará no índice de integridade global para a máquina monitorada. A justificativa para essa proposição tem como base o fato de os MIs, em particular, permanecerem robustos e funcionais, mesmo na presença de diferentes falhas (EL; BENBOUZID; MEMBER, 2000).

O HealthMon não exige que o operador seja um especialista em conhecimento de sinais, mas que tenha domínio minimamente dos sinais que devam ser analisados em conjunto. Na verdade, isso requer que, em um primeiro momento, um conjunto de sinais tantos quanto possíveis, melhor dizendo, com alguma relevância intuitiva. O usuário deve, por conseguinte, identificar, pelo menos, uma variável que tenha sensibilidade em relação à evolução da degradação. Por exemplo, temperatura, corrente, vibração são exemplos de variáveis que costumam ser a detecção de falha da máquina. Entretanto, existem outros como pressão atmosférica ou a umidade que poderiam estar relacionados com uma degradação em particular, a qual dependerá da máquina em questão. Aliás, é interessante ressaltar que, se o usuário instalar um sensor que não esteja relacionado à manifestação de falha, o HealthMon não poderá apresentar o resultado esperado. Um exemplo disso seria o caso de o usuário instalar um sensor de umidade para monitorar a saúde da máquina, que é de natureza elétrica. Em tal conjuntura, observamos que a umidade é uma variável do ambiente, a qual não possui relação direta com a máquina.

Conforme visto anteriormente, a principal vantagem desse tipo de abordagem é que a aprendizagem ocorre em tempo real, sem a necessidade de grandes períodos para treinamentos de modo a outorgar que, sistemas dessa natureza, sejam colocados em funcionamento imediatamente após sua validação. Nas próximas seções serão apresentadas o HealthMon, assim como outros assuntos pertinentes a esse trabalho.

1.1 Motivação

A fim de que as indústrias possam se manter competitivas, a tendência é de que adotem o paradigma da Indústria 4.0. Dessa forma, para se tornem mais competitivos, os fabricantes precisam adotar tecnologias emergentes como análises avançadas e abordagens baseadas em sistemas Ciberfísicos para melhorar sua eficiência e produtividade (LEE et al., 2013). Com as crescentes demandas esperadas e projetadas para a manufatura, muitos setores da economia, que trabalham para prover soluções e fomentar a indústria, tendem a se beneficiar ao atender tais demandas. A esse respeito, averiguamos, na literatura, a adoção de estratégias colaborativas entre empresa e meio acadêmico que culminam em benefícios para ambos. A razão para isso reside em duas questões. Primeira, as instituições acadêmicas, por estarem diretamente envolvidas com pesquisa, obtêm evidências que podem impactar diretamente nas operações das companhias dentro do contexto da Indústria 4.0 (KHAN; TUROWSKI, 2016). Segundo, as indústrias, as quais podem dar suporte às pesquisas acadêmicas, acabam

por se favorecer dessa parceria por meio do uso da tecnologia de ponta oferecida em termos de *hardware* e *software* (KHAN; TUROWSKI, 2016).

No entanto, é crucial evidenciar que, estudos e pesquisas realizadas, revelam a existência de uma lacuna na literatura no que tange à falta de propostas totalmente não supervisionadas para gerar um índice global para monitorar a saúde de máquinas. Ao realizar tais buscas, também foi possível notar que, na literatura, não há estudos que relacionem uma máquina ou equipamento com seu estado de saúde por meio de um índice geral. Com isso, verificamos a necessidade de suprir essa lacuna por intermédio do desenvolvimento de uma abordagem, que possa fornecer um índice global de saúde da máquina/equipamento. De forma que essa informação gerada possa servir para apoiar o processo de tomada de decisão quanto à realização de manutenção preventiva. O intuito é, então, ensejar uma melhor organização na realização do calendário de manutenção, cuja finalidade é diminuir o risco de paradas não planejadas. Consequentemente, isso acarretará em melhores resultados em termos de eficiência no que concerne à realização de manutenção.

Muitos estudos mostram que há uma maior aplicação de abordagens supervisionadas (AMIHAI et al., 2018; AREMU et al., 2019; ZSCHECH et al., 2019; SANTOS; MAUDES; BUSTILLO, 2018; VISHNU et al., 2018; Arias Chao, Manuel; Kulkarni, Chetan; Goebel, Kai; Fink, 2019) em comparação com abordagens não supervisionadas. Constatamos ainda que grande parte dos trabalhos se concentram em máquinas ou peças específicas (LI et al., 2020a; CAMPOS et al., 2019; MA et al., 2019; WANG et al., 2020). Além disso, a aplicação de apenas dados sintéticos para avaliação da abordagem também pode ser vista como uma lacuna (LI et al., 2020a; AL-DULAIMI et al., 2020).

As vantagens competitivas de uma indústria têm forte relação com os procedimentos de manutenção, pois a manutenção de máquinas e equipamentos é fundamental. Sendo que afeta o tempo de operação e a eficiência do equipamento; por essa razão, falhas em máquinas ou no equipamentos demandam ser identificadas e solucionadas, evitando paradas nos processos de produção (CARVALHO et al., 2019). A realização da manutenção preventiva é uma atividade que merece atenção por parte das companhias, visto que as máquinas estão entre os principais meios para a produção. Dentre os diferentes tipos de manutenção, citamos a manutenção baseada em condições (CBM), a qual se refere a uma estratégia de manutenção que usa as informações obtidas durante o monitoramento da condição de um ativo físico para recomendar ações de manutenção (WAKIRU et al., 2019), que é o foco deste trabalho.

Este trabalho propõe, uma abordagem inovadora que visa a beneficiar, a realização da

manutenção preventiva. Para isso, consideramos o envolvimento da computação e da engenharia para atingir seus objetivos e prover subsídios para a realização da manutenção preventiva em equipamentos com base na condição de maneira a proporcionar contribuições para ambas as áreas. Conforme Derigent et al. (DERIGENT; CARDIN; TRENTESAUX, 2020), há uma variedade de tecnologias que podem e devem ser usadas como parte de um programa abrangente de manutenção preventiva e preditiva. Contudo, é interessante ressaltarmos que essa combinação propicia as condições apropriadas à proposta apresentada, já que o tema está alinhado às oportunidades, viabilizando todas as fases, desde a sua implementação até a realização de testes e validações em cenários reais. O desenvolvimento do HealthMon só foi possível em função da aplicação do conhecimento de pesquisadores pertencentes às áreas da Engenharia Eletrônica e Computação.

O HealthMon visa a contribuir para a redução de custos e otimizar o processo produtivo. De maneira mais específica, ele busca gerar informações com relação à saúde das máquinas, permitindo um melhor desempenho e eficiência, além de aprimorar o planejamento da manutenção preventiva, o que aumenta o tempo de vida útil dos maquinários. Vale lembrar ainda que essa proposta possibilita o planejamento ações de acordo com paradas planejadas sem comprometer o processo produtivo. Essa solução, por conseguinte, minimizar riscos de paradas inesperadas da produção industrial. O HealthMon, então, propõe-se a contribuir significativamente tanto para a comunidade acadêmica, por meio de suas contribuições científicas, quanto para a indústria, no que diz respeito a resultados monetários.

Isso posto, as principais contribuições deste trabalho são as seguintes:

1. Indicador global de saúde: levando em consideração vários conjuntos de séries temporais de variáveis relacionadas à degradação, a solução proposta deverá gerar um índice global de saúde (IGS) para a máquina.
2. Baixa complexidade para colocar a solução em funcionamento: o HealthMon requer um entendimento básico de como a máquina funciona internamente no sentido de conhecer minimamente como sucede um fenômeno físico da manifestação de degradação, ou seja, quais são as variáveis alteradas pela degradação da máquina.
3. Ampla gama de aplicabilidade: o HealthMon é uma solução escalável, uma vez que

não se restringe a um tipo específico de máquina e busca atender aos requisitos da chamada indústria 4.0 em termos de ser aplicável a uma ampla variedade de setores industriais, envolvendo desde pequenas a grandes empresas.

Em linhas gerais, é plausível dizermos que o HealthMon refere-se a uma abordagem que pertence ao contexto da Indústria 4.0. Sua finalidade é agregar valor em termos de estratégias industriais no que tange à manutenção, focando na gestão de saúde de máquinas (KHAN et al., 2020; MERKT, 2019; CARVALHO et al., 2019). Ademais, cabe salientar que a sua eficiência se dá em virtude do prolongamento do tempo de vida útil das máquinas e por permitir que as máquinas operem em melhores condições de funcionamento, resultando, assim, em consumo de energia mais proveitoso (TESCH DA SILVA et al., 2020).

1.2 Questão de Pesquisa

A questão de pesquisa que a abordagem proposta busca responder é a seguinte:

- Como o monitoramento de máquinas, por intermédio de sensores, pode contribuir à criação de um índice global de saúde da máquina direcionado à realização da manutenção preventiva no contexto da indústria 4.0?

A hipótese inicial era a de que uma abordagem desenvolvida com a finalidade de monitorar a saúde de máquinas, no contexto da Indústria 4.0, poderia possibilitar a verificação de desgaste e falha por meio da utilização de um índice global que indicasse a saúde atual da máquina. Para isso, implementar-se-ia a análise de uma ou mais das suas características (como, por exemplo, energia, de vibração ou de som) que recebem como entradas séries temporais. A fim de alcançar isso, a abordagem deveria executar a decomposição de sinais organizados em tendências de séries temporais para, posteriormente, realizar buscas otimizadas dentro dessas séries com o intuito de verificar a evolução da degradação da máquina. A ideia seria gerar informações que auxiliem os gestores acerca do melhor momento para aplicar a manutenção preventiva em máquinas na planta industrial.

1.3 Objetivos

Com o objetivo de extrair dados de um conjunto de séries temporais, pretendemos realizar o processamento de otimização em várias séries temporais decompostas de modo que sejam analisados e combinados e que gerem um único índice de tendência de todo o conjunto. Para alcançar esse fim, faz-se necessário diminuir a não linearidade das dependências inter-série, aplicando a aprendizagem de máquina não supervisionada para transformar um espaço de alta dimensionalidade em um espaço de baixa dimensão. Nesse contexto, denominamos um novo processo descrito como “trenderização” (converter em tendências). Por conseguinte, o que pretendemos é gerar um índice geral de saúde de máquinas por meio da utilização do sistema denominado HealthMon e da aplicação de técnicas de *Machine Learning* como o algoritmo genético e o algoritmo CST, que é uma técnica personalizada de força bruta. Em um primeiro momento, tencionamos trabalhar com sinais de corrente e vibração IM como estudo de caso, porém a solução final foi dispor de extensão para outros tipos de máquinas, principalmente, de máquinas vibrantes via aplicação de dados reais para fins de testes e avaliação.

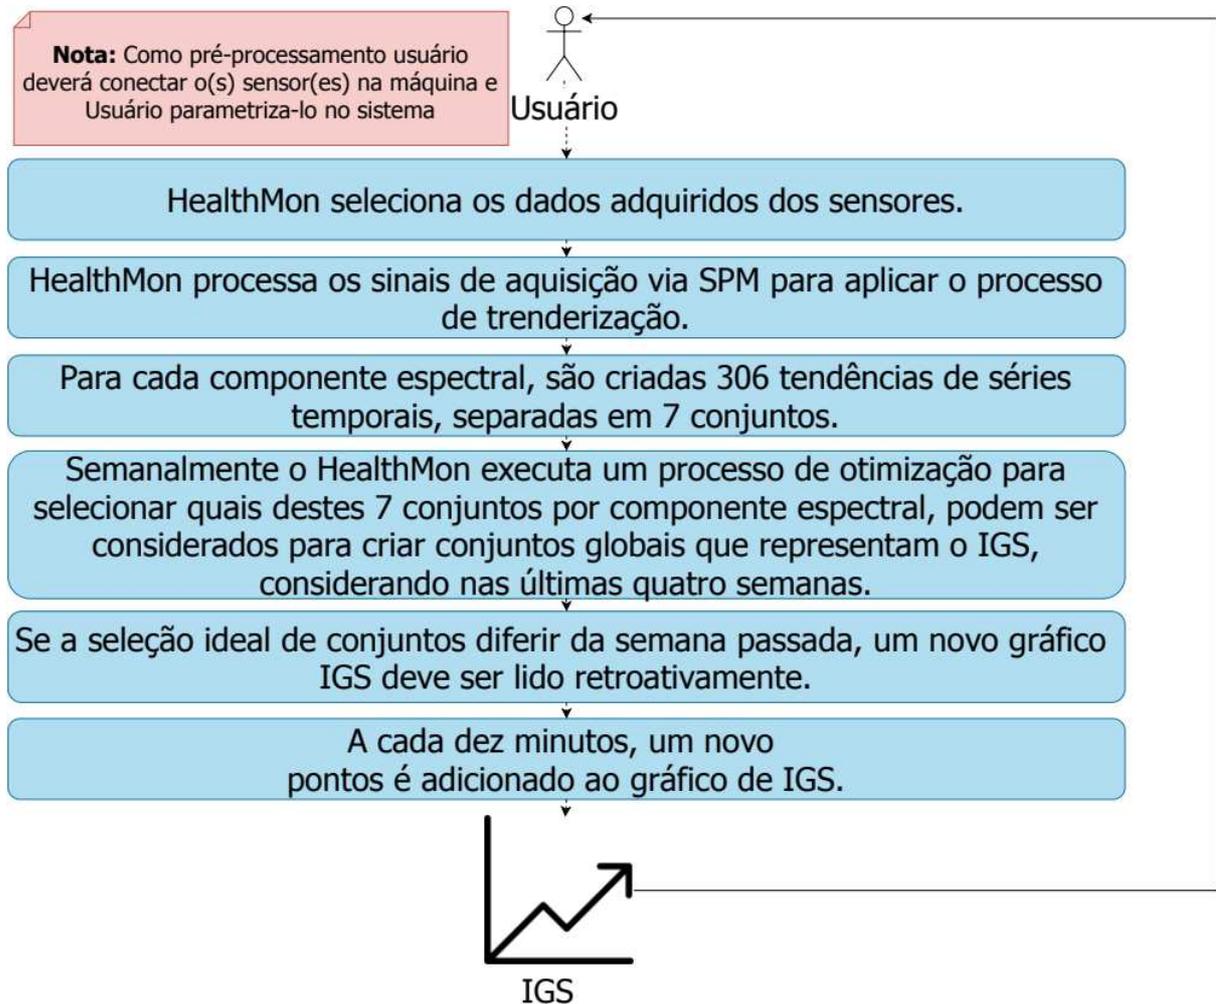
Nesse sentido, o objetivo geral deste trabalho é desenvolver uma abordagem automatizada para o apoio a manutenção preventiva, de forma transparente ao usuário, que possa ser aplicada às máquinas vibrantes e baseada no método de trenderização de sinais (converter em tendências), considerando dados obtidos de sensores e pré-processados e indicando a evolução de falhas durante determinado período de análise. Além disso, essa abordagem visa à redução de custos industriais com o mínimo de parada de máquinas, consequentemente da fábrica a ponto de permitir aos gestores a realização de manutenção preventiva por meio de bases históricas e a promoção de melhorias no desempenho das máquinas e otimização dos processos produtivos como um todo. Assim, para atingir o objetivo geral, serão definidos os seguintes objetivos específicos, como apresenta a Figura 1:

- Desenvolver interface com o usuário, conforme explicado na Figura 1. Desse modo, será necessário a intervenção do usuário em apenas três momentos:
 - para conectar sensor(es) na máquina alvo;
 - para cadastrar e vincular o sensor na máquina a ser monitorada por intermédio de uma interface de alto nível;
 - para a verificação da saída do sistema, que é o próprio Índice Global de

Saúde (IGS), para informar o estado de saúde da máquina.

- Desenvolver uma abordagem seja compatível com diferentes tipos de sensores. No entanto, é fundamental frisar que, para atingir os resultados esperados, as variáveis medidas deverão ter relação física com a falha da máquina monitorada, tais como: vibração, temperatura, elétrico, sensor de corrente, sensor de pressão, ou sensor de som, entre outros.
- Aplicar algoritmos de aprendizagem de máquina não-supervisionado, técnicas para obter um conjunto reduzido e viável de tendências após o processamento de sinal digital. Isso deve ser usado para indicar a evolução de falha no alvo da máquina.
- Gerar um índice de saúde global como resultado do monitoramento para, em seguida, apresentá-lo em *dashboard*.
- Verificar os sinais processados que não demonstram impacto sobre a evolução de falha para, dessa forma, descartá-los a fim de propiciar a otimização do funcionamento do sistema.

Figura 1 – Pipeline de atividades do HealthMon, a partir da entrada do usuário até a geração de Índice Global de Saúde (IGS).



Fonte: Elaborado pelo autor

- Monitorar qualquer tipo de máquina baseada em vibração ou rotativa na planta industrial.

Em suma, os objetivos específicos consistem em: a) prover interação entre usuário e a máquina; b) apresentar compatibilidade com diferentes sensores; c) empregar a aprendizagem de máquina não supervisionada; d) gerar Índice Global de Saúde (IGS) de máquina; e) aplicar processo de otimização para identificar evolução de degradação; f) ser aplicável para diferentes máquinas industriais, conforme apresentado na Figura 2.

1.4 Etapas de Desenvolvimento da Pesquisa

O desenvolvimento da pesquisa deverá ocorrer de acordo com o fluxograma exibido na Figura 2. Nesse fluxograma, são apresentadas as 7 etapas, sendo elas: (1) Introdução, (2) Fundamentação teórica; (3) Trabalhos relacionados; (4) A Abordagem HealthMon; (5) Metodologia de Avaliação; (6) Resultados e (7) Conclusões. Inicialmente, entramos no mérito da nossa proposta para, posteriormente, realizarmos o estudo das teorias envolvidas no tema de pesquisa para formar o referencial teórico. Em seguida, partimos para a etapa de levantamento dos trabalhos relacionados ao tema de pesquisa. Essa etapa visa buscar trabalhos com objetivos semelhantes aos desta pesquisa a fim de identificar possíveis lacunas. A quarta etapa consiste em apresentar a abordagem através de suas respectivas fases. A quinta etapa descreve o desenvolvimento de um modelo que preenche as lacunas encontradas nos trabalhos relacionados e que tenciona a responder a questão de pesquisa, bem como atender os objetivos do trabalho, implementar o modelo proposto e testar a implementação. A sétima etapa se concentra em analisar os resultados obtidos. Por fim, a sétima etapa apresenta as contribuições, limitações e sugestões de trabalhos futuros.

1.5 Organização do Texto

Esta dissertação encontra-se organizada em sete capítulos, conforme evidencia o fluxograma da Figura 2.

No capítulo 1, temos a Introdução, seguido do capítulo 2, cuja meta é discorrer sobre os conceitos fundamentais à compreensão do trabalho como aqueles referentes à Indústria 4.0; falhas em máquinas industriais e seus impactos; manutenção de máquinas; manutenção em máquinas industriais; Inteligência artificial; técnicas de *Machine Learning* (ML) e tecnologias relacionadas.

O capítulo 3, por sua vez, mostra uma relação de trabalhos relacionados ao tópico deste estudo, assim como revela o desenvolvimento do processo de revisão da literatura utilizado, incluindo um breve resumo dos trabalhos escolhidos e suas principais características, uma análise comparativa entre essas pesquisas com a finalidade de mostrar pontos relevantes sobre cada uma das abordagens e a identificação dos principais trabalhos relativos à manutenção preditiva de máquinas industriais.

Já o capítulo 4, trata da abordagem HealthMon desdobrado em fases, além da arquitetura necessária para o sistema. Nesse capítulo, abordamos ainda a apresentação da construção de protótipo para otimização da busca de conjuntos de sinais que evidenciam

evolução de falha, a validação do sistema através do protótipo, a estruturação e modelagem do sistema e o desenvolvimento do sistema.

No capítulo 5, descrevemos os procedimentos metodológicos do HealthMon, a realização de testes e a validação do sistema, incluindo a metodologia de avaliação da abordagem, a definição dos ensaios de testes esperados, juntamente com os parâmetros, a infraestrutura e dados que serão utilizados nos testes, envolvendo as métricas que serão utilizadas para análise do sistema proposto.

O capítulo 6, por seu turno, aborda os resultados obtidos através dos testes envolvendo dados sintéticos e dados reais.

Por fim, no Capítulo 7, temos a conclusão desse trabalho, na qual serão elencados as contribuições científicas, as limitações da abordagem HealthMon e os possíveis trabalhos futuros de modo a prever a melhoria ou complementação do sistema proposto.

PROBLEMA DE PESQUISA: Como o monitoramento de máquinas através de sensores, pode contribuir para a criação de um índice global de saúde da máquina, orientando para a realização de manutenção preventiva, no contexto da indústria 4.0?

OBJETIVO GERAL: Desenvolver um sistema de apoio a manutenção preventiva automático e transparente em máquinas vibrantes, baseado no método de trenderização de sinais, considerando dados obtidos de sensores e pré-processados, indicando evolução de falhas durante determinado período de análise, visando reduzir os custos industriais com o mínimo de parada de máquinas, consequentemente da fábrica. Permitindo aos gestores a realização de manutenção preventiva por meio de bases históricas resultando em melhorias no desempenho das máquinas e otimização dos processos produtivo como um todo.

Capítulo 1

OBJETIVOS ESPECÍFICOS

Prover interação entre usuário e a máquina

Apresentar compatibilidade com diferentes sensores

Aplicar aprendizagem de máquina não supervisionado

Gerar Índice Global de Saúde (IGS) de máquina

Aplicar processo de otimização para identificar evolução de degradação

Deve ser aplicável para diferentes máquinas industriais

REVISÃO BIBLIOGRÁFICA

Capítulo 2

Indústria 4.0, focando na manutenção de máquinas

Falhas em máquinas industriais e seus impactos

Manutenção em máquinas industriais

Inteligência artificial e técnicas de Machine Learning

TRABALHOS RELACIONADOS

Capítulo 3

Processo de revisão da literatura

Identificação dos principais trabalhos no estado da arte

Resumos dos trabalhos escolhidos

Análise comparativa

A ABORDAGEM HEALTHIMON (ARQUITETURA)

Capítulo 4

Fase 1

Fase 2

Fase 3

Fase 4

Fase 5

Fase 6

METODOLOGIA DE AVALIAÇÃO

Capítulo 5

Construção de protótipo

Validação do sistema através do protótipo

Estruturação e modelagem do sistema

Desenvolvimento do sistema

Planejar e Desenvolver ensaios de testes

Testar e avaliar sistema em ensaios com dados reais

RESULTADOS

Capítulo 6

Coleta de dados, compilação e análise dos resultados

Relatório dos resultados

CONCLUSÕES

Capítulo 7

Contribuições

Limitações

Trabalhos Futuros

Fonte: Elaborado pelo autor.

2 FUNDAMENTAÇÃO TEÓRICA

Nesta seção, serão abordados alguns conceitos básicos para o entendimento da proposta da presente dissertação. Essa parte encontra-se dividida em: seção 2.1, na qual contextualizamos a Indústria 4.0 com os novos desafios para área de manutenção de máquinas; seção 2.2, na qual são apresentados conceitos de falhas em máquinas industriais; seção 2.3, na qual discorreremos sobre as definições de manutenção em máquina; e seção 2.4, na qual abordamos os conceitos de Inteligência Artificial e tecnologias relacionadas.

2.1 Indústria 4.0

O termo indústria pode ser definido como algo que faz parte de uma economia que produz bens materiais altamente mecanizados e automatizados (LASI et al., 2014). De acordo com (STEARNS, 2018), a revolução industrial foi o desenvolvimento individual mais importante na história da humanidade nos últimos três séculos. Desde o seu surgimento, a indústria sempre desempenhou um papel muito importante na sociedade em função de estar fortemente associada ao progresso e ao desenvolvimento econômico, por contribuir para a melhoria do padrão de vida das pessoas e por estabelecer vínculos por meio da ciência e da tecnologia (BRESSER-PEREIRA, 2014). Dada a sua importância ao desenvolvimento da economia, o governo da Alemanha, em 2011, teve a iniciativa de apoiar o desenvolvimento econômico do país a ponto de cunhar, pela primeira vez, o termo Indústria 4.0. A razão disso foi por estar intimamente ligado à tecnologia, fazendo, portanto, referência ao versionamento de software, sendo também um termo que remete as chamadas revoluções industriais que a sucederam anteriormente (LASI et al., 2014), conforme será descrito a seguir:

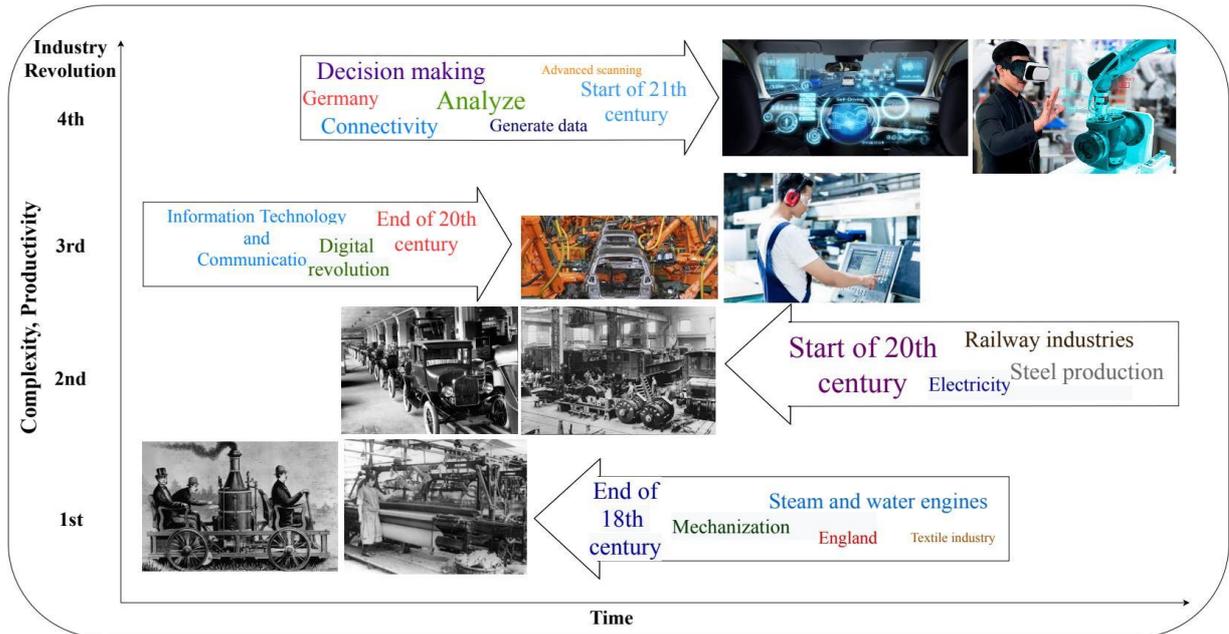
- **Primeira Revolução Industrial:** na Grã-Bretanha, do século 18 (1760-1840), deu-se início à introdução de máquinas de produção. Com relação ao processo de produção manual, começou-se a fazer uso de motores a vapor e água como fonte de energia. Uma das indústrias que mais se beneficiou dessas mudanças foi a indústria têxtil, a qual é considerada a pioneira na implantação desse paradigma.

- **Segunda Revolução Industrial:** o período entre 1870 e 1940 foi marcado pelo uso intensivo de energia elétrica que permitiu a introdução de sistemas, como telégrafos e ferrovias nas indústrias, fator este que culminou no crescimento da produção de aço nessa época.

- **Terceira Revolução Industrial:** o período compreendido entre 1950 e 1970 propiciou o surgimento de tecnologias digitais em linhas de produção. Esse período é comumente referido como Revolução Digital ou Era da Informação devido a viabilizar mudanças de sistemas analógicos e mecânicos para sistemas digitais, época está marcada, principalmente, pelo desenvolvimento de computadores e tecnologia da informação e comunicação.

- **Quarta Revolução Industrial:** surgiu a partir da digitalização avançada dentro das fábricas e da combinação de tecnologias da Internet e tecnologias orientadas para o futuro no campo de objetos inteligentes. Isso resultou em uma nova mudança de paradigma na produção industrial, levando a automação dos processos de fabricação a um novo nível a ponto de introduzir tecnologias de produção em massa personalizadas e flexíveis; possibilitando, assim, que as máquinas pudessem operar independentemente ou cooperativamente com os seres humanos. Além, é claro, de permitir que as máquinas se tornassem entidades independentes, ou seja, com a capacidade de gerar dados, viabilizando maiores capacidade de análises, e, conseqüentemente, apoiando o processo de tomada de decisão por parte dos gestores.

Figura 3 – Revolução Industrial



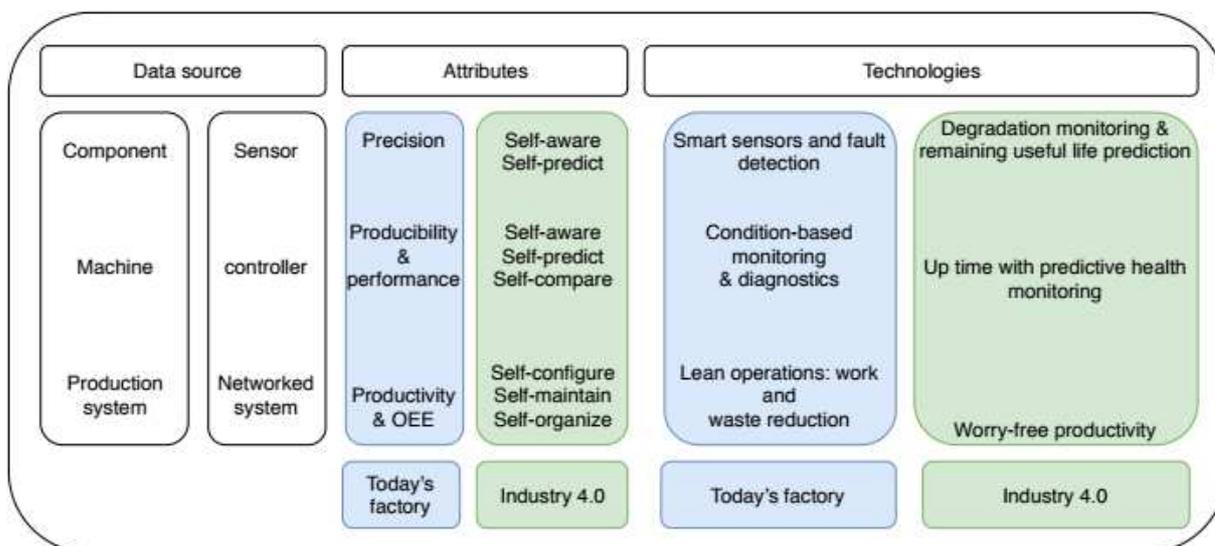
Fonte: Elaborado pelo autor

De acordo com a Figura 3, percebemos que a quarta revolução industrial promove um novo paradigma, no qual é possível notar a presença de sensores nos elementos que compõe o chão de fábrica, assim como nos produtos associados a conectividade entre equipamentos e dispositivos de forma a dar origem aos chamados sistemas ciberfísicos (CPS). É interessante destacarmos que, segundo, Lee, Bagheri e Kao (2015), estes últimos são vistos como um sistema no qual as informações de todas as perspectivas relacionadas são monitoradas de perto e sincronizadas entre o chão de fábrica físico e o espaço ciber computacional. Além disso, eles também são definidos como sendo tecnologias transformadoras que gerenciam sistemas interconectados entre seus ativos físicos e recursos computacionais, possibilitando fazer análises avançadas de informações de modo que as máquinas em rede possam executar de forma mais eficiente, colaborativa e resiliente. Aliás, cabe enfatizarmos que isso se trata de uma tendência global, que está transformando a indústria para a denominada Indústria 4.0.

Conforme Lee, Bagheri e Kao (2015), para constituir um CPS, são imprescindíveis dois componentes funcionais principais, a saber: (I) a conectividade avançada que garanta a aquisição de dados em tempo real do mundo físico e o retorno de informações do espaço cibernético; e (II) o gerenciamento inteligente de dados, capacidade analítica e computacional providos do espaço cibernético. Um CPS é, na verdade, um mecanismo por

meio do qual objetos físicos e *software* estão intimamente interligados a ponto de viabilizar que diferentes componentes interagem entre si de diversas maneiras para trocar informações (ZHONG et al., 2017). Para Lee, Bagheri e Kao (2015), a implementação do CPS, nas fábricas atuais, oferece grandes vantagens que podem ser categorizadas em três estágios. Dentre eles estão: componentes, máquinas e sistemas de produção. Na Figura 4, temos a exibição de uma análise comparativa entre a indústria dos dias atuais e a Indústria 4.0.

Figura 4 – Análise comparativa entre a Indústria nos dias atuais e a Indústria 4.0



Fonte: (LEE; BAGHERI; KAO, 2015) - Adaptado pelo auto

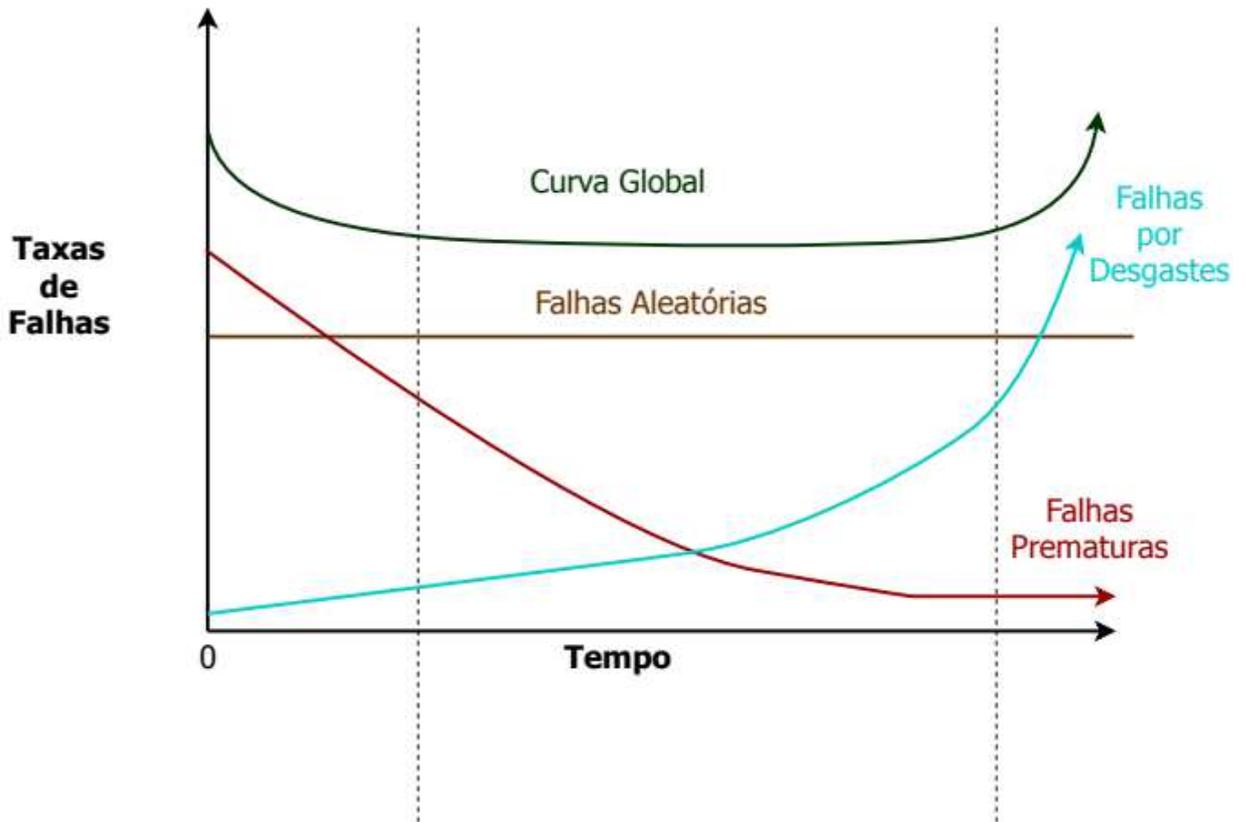
Na Figura 4, averiguamos que os atributos para a indústria 4.0 giram em torno da automaticidade com destaque particular para automaticidade para predição, visto ser este uma característica fundamental de um CPS. Outra característica relevante é a fusão do digital e físico. Segundo Lasi et al. (2014), no CPS, o nível físico e o digital se fundem a ponto de abranger tanto o nível de produção quanto o dos produtos, dando origem, assim, a um tipo de sistema, cuja representação física e digital não pode mais ser diferenciada de maneira razoável. Um exemplo pode ser observado na área de manutenção preventiva, na qual os parâmetros do processo como estresse, tempo produtivo, etc., dos componentes mecânicos subjacentes a um desgaste físico são registrados digitalmente nesse tipo de sistema. No entendimento de Lasi et al. (2014), a condição real do sistema resulta do objeto físico e de seus parâmetros de processo digital.

2.2 Falhas em Máquinas Industriais e seus Impactos

O termo falha faz parte do cotidiano das indústrias de modo que a definição de falha poderia ser considerada como algo que culminou em erro, ou seja, não saiu conforme o esperado. Para Nowlan e Heap (1978), falha é vista como uma condição insatisfatória. Em outras palavras, uma falha é qualquer desvio identificável da condição original, o qual é insatisfatório para um determinado usuário. As ocorrências de evolução de falhas são o foco deste estudo, porém cabe ressaltarmos que os benefícios das soluções propostas estão na redução dos impactos causados pelas falhas. De acordo com Nowlan e Heap (1978), as consequências das falhas podem variar, sendo desde um custo modesto, como substituir um componente com falha, a possível destruição de um equipamento até perda de vidas. Na visão desses estudiosos, todos os programas de manutenção deveriam ser norteados pelas consequências de uma falha, visto que elas determinam a prioridade das atividades de manutenção ou a melhoria do projeto necessária para impedir a sua ocorrência. A ocorrência de falha está geralmente associada ao fator tempo. Por esse motivo, estudos avançaram em verificar as probabilidades de ocorrências de falhas. Uma das técnicas desenvolvidas para esse tipo de estudo é a Curva da Banheira. Segundo Slack, Chambers e Johnston (2009), as falhas ocorrem em diferentes momentos da vida útil de algo físico, como uma máquina ou um equipamento, podendo ser classificadas em três etapas: (I) a mortalidade "infantil" ou a etapa da "vida inicial", que é quando as falhas iniciais ocorrem por causa de peças defeituosas ou uso inadequado; isso geralmente ocorre em máquinas/equipamentos recém montados ou saindo de uma manutenção; (II) a etapa da "vida normal" ocorre quando a taxa de falhas é normalmente baixa, razoavelmente constante e causada por fatores aleatórios normais; etapa (III) é aquela que evidencia falhas em função de "desgaste", isto é, quando a taxa de falha aumenta à medida que a peça aproxima do final da sua vida útil, logo, essas falhas são causadas por envelhecimento e deterioração das peças de uma máquina ou equipamento, ou seja, pela consequência de um longo tempo de uso. A Figura 5 representa a taxa de falha em função do tempo. A ilustração apresenta as três diferentes etapas com destaque para a etapa III e é referente à ocorrência de falhas por desgaste, que é o foco deste trabalho. As falhas em máquinas são detectadas, analisadas e, posteriormente, aplicadas as devidas providências pela área de manutenção das organizações. Em vista disso, essa área passa a ser um setor estratégico e fundamental para as companhias. A prática da gestão de manutenção é composta por conjuntos de procedimentos e ações, cujo intuito é manter o funcionamento de máquinas e

equipamentos regular e permanentemente a fim de que estejam disponíveis para seu propósito. Esse cuidado

Figura 5 – Curva da Banheira



Fonte: (SLACK; CHAMBERS; JOHNSTON, 2009), adaptada pelo auto

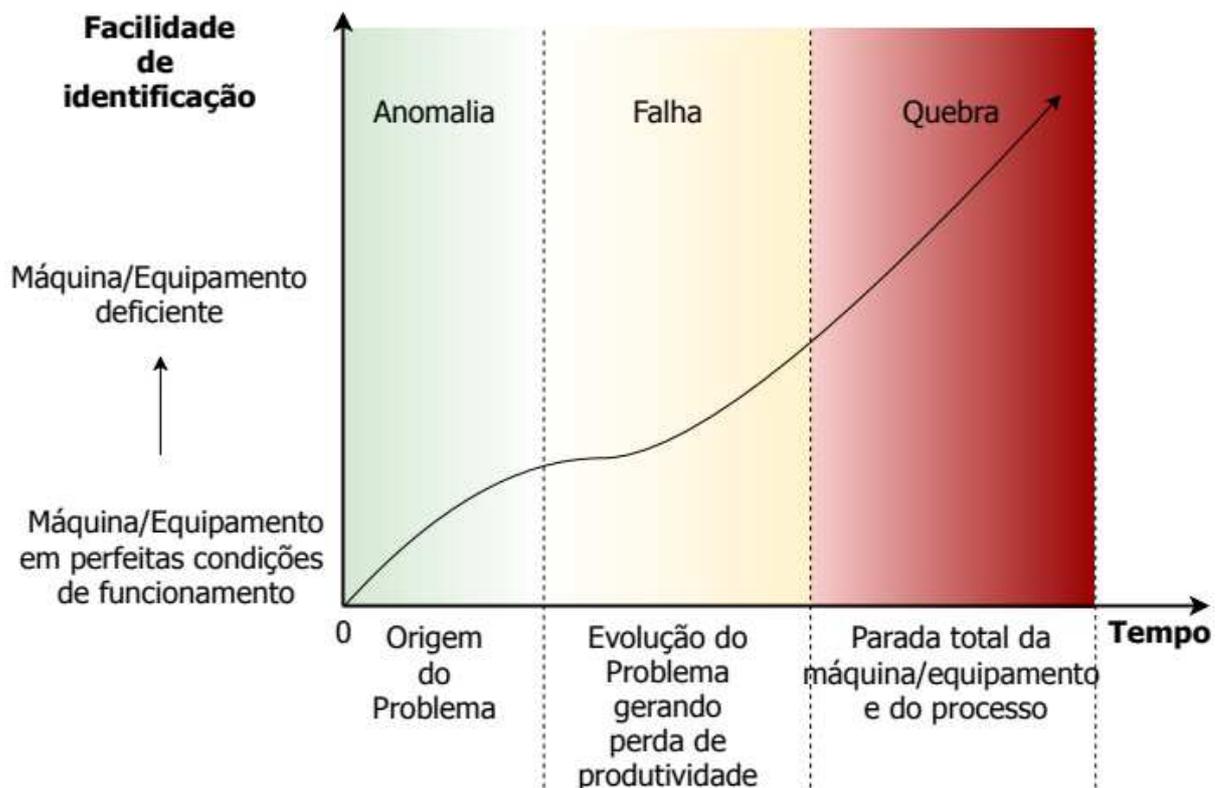
envolve adequação, conservação, a substituição, restauração, bem como a prevenção. Para Felix e Fuente (2006), um equipamento atravessa três fases distintas: anomalia, falha e quebra. A fase de anomalia compreende os primeiros sintomas, os quais já podem ser observados, como, por exemplo, o início de uma trinca no cabeçote de um motor. Em outros termos, é a origem do processo de quebra e pode ser identificada por manutenções planejadas como a preditiva e por inspeção. A fase seguinte, a de falha, resulta em uma perda de produção. Caso não haja a intervenção, isso desencadeará a quebra. Essas duas últimas fases geram uma manutenção corretiva. Nessa situação, as falhas podem ser classificadas em modo e efeito. Um modo de falha é um dos estados possíveis de um item com defeito no que se refere a uma determinada função requerida. Um efeito de falha, por sua vez, é a consequência

de um modo de falha em termos de operação, função ou *status* de um sistema. Um efeito de falha pode ser causado por um ou mais modos de falha de um ou mais itens (SÖDERHOLM, 2005). De acordo com Söderholm (2005), as falhas podem ainda gerar quatro tipos de consequências, as quais são classificadas por tipos de gravidades.

As consequências Geradas por Falhas são:

- Falhas com consequências de segurança;
- Falhas com consequências ambientais;
- Falhas com consequências operacionais;
- Falhas com consequências não operacionais, ou seja, apenas consequências econômicas.

Figura 6 – Processo de Quebra de Máquina/Equipamento.



Fonte: (FELIX; FUENTES, 2006), Adaptado pelo auto

Classificação de Gravidades das Falhas:

- Catastrófica: falhas que resultam em morte ou perda total do sistema;

- Crítico: falhas que resultam em ferimentos graves ou danos graves ao sistema;
- Marginal: Falhas que resultam em ferimentos leves ou danos menores ao sistema;
- Insignificante: falhas que resultam em defeitos leves ou danos ao sistema.

O tratamento adequado às ocorrências de falha está associado à confiabilidade, sendo este quesito almejado por muitas organizações que buscam um diferencial competitivo. Falhas em máquinas podem ter reflexo na qualidade de produtos ou serviços fornecidos pelas organizações. Isso significa que possuir produtos e serviços confiáveis é um indicativo de as companhias obterem vantagem competitiva (SLACK; CHAMBERS; JOHNSTON, 2009). Com o auxílio das tecnologias, grandes soluções podem contribuir para a prevenção de falhas, resultando em aumento da confiabilidade. Em tal conjuntura, é possível afirmar que o rápido avanço da tecnologia de detecção, a disponibilidade e acessibilidade de todos os tipos de dados de estruturas foram bastante aprimoradas. À medida que a duração dos dados registrados aumenta, os efeitos sazonais tornam-se inevitavelmente importantes, especialmente, para o monitoramento em longo prazo (SHI; WORDEN; CROSS, 2019).

2.3 Manutenção em Máquinas Industriais

Desde a primeira Revolução Industrial, prover a manutenção de máquinas e equipamentos tem sido parte dos desafios das indústrias, tendo em conta que as máquinas precisam estar em ótimo estado de funcionamento para que o produto seja produzido. Todavia, de acordo com pesquisas, é possível observar que a realização da manutenção passou a ser vista como um diferencial estratégico; considerando que diversos setores comprovam que colocar a área de manutenção como prioridade pode fazer toda a diferença no resultado final. O setor militar já deu provas disso ao dar ênfase à realização de manutenção. Com isso, esse foco ganhou mais força na área militar, principalmente, no que tange às aplicações de manutenção centradas na confiabilidade para aeronaves comerciais e militares (NOWLAN; HEAP, 1978).

O objetivo do processo de manutenção é manter a capacidade do sistema de fornecimento de um serviço, no qual o processo de manutenção monitora a capacidade do sistema de fornecer tais serviços, registrar problemas para análise, executar ações corretivas, adaptativas e preventivas, além de confirmar a capacidade restaurada (SÖDERHOLM, 2005). Aliás, é interessante lembrarmos que as abordagens para a realização de manutenção em máquinas industriais estão em constante evolução. Segundo Lafraia (2001), a abordagem mais recente é abordagem de Manutenção Centrada na Confiabilidade. De acordo com a

Figura 7, a manutenção preventiva passou por duas formas distintas de atuação da manutenção: (I) a manutenção baseada no tempo, e (II) a manutenção baseada na condição. A realização de manutenção agrega valor à organização produtiva quando realizada de forma adequada, permitindo que seus objetivos sejam definidos em concordância com o negócio da empresa a ponto de conduzir as organizações a compreender a importância de um plano estruturado de manutenção por meio da aplicação dos conceitos de confiabilidade (FELIX; FUENTES, 2006).

Com o surgimento da Indústria 4.0, a gestão da informação passou a ser unânime para todos aqueles, que de alguma forma, fomentam a indústria. Como era de se esperar, desde o início do século XXI e com o crescente avanço da tecnologia e a atual necessidade de informação em todos os níveis do negócio, os sistemas de automação modernos passaram de simples automações de processos para automação de negócios, lidando com grandes quantidades de informações relevantes (NEVES et al., 2007).

Juntamente com técnicas de reconhecimento de padrões, está a identificação de falhas em sistema de automação que pode ser resolvido com um classificador de defeitos, possibilitando possíveis projetos para identificar as grandes falhas em sistemas. Implementar elementos que identifiquem as possíveis falhas de determinado equipamento está intimamente ligada ao bom desempenho do reconhecimento de padrões. Para Neves et al. (2007), o problema reside em estimar uma máquina “inteligente” para informar quando ocorre defeitos por meio de padrões construídos com o auxílio de especialistas. À vista disso, os autores sugerem resolver o problema das falhas de sistema de automação por intermédio da utilização de ferramentas adequadas ao reconhecimento de padrões.



Figura 7 – Linha do Tempo da Manutenção Industrial

Fonte: (LAFRAIA, 2001), adaptado pelo autor.

A automação anda junto com os paradigmas da Indústria 4.0 no sentido de automatizar os processos e as operações a fim de aumentar a demanda de manutenção em máquinas, visto que a indústria depende disso cada vez. É válido destacarmos que os mecanismos de detecção de problemas e interrupção do processamento podem ser aplicados, conforme conceitos da automação, para a eliminação das quebras de máquinas (Da SILVA; SELITTO, 2010). A Manutenção Produtiva Total - MPT (*Total Productive Maintenance - TPM*) é um dos elementos que podem auxiliar no alcance e sustentação da quebra zero, maximizando a efetividade dos equipamentos no sistema produtivo. A TPM pode ser útil em objetivos de manutenção, tais como: aumento de confiabilidade e de manutenibilidade dos equipamentos (Da SILVA; SELITTO, 2010).

2.3.1 Abordagem para a Manutenção

Na literatura, identificamos diferentes abordagens para a manutenção. É de concordância da maioria que existem três tipos básicos: (I) corretiva, que visa permitir a operação até a quebra da máquina/equipamento; (II) preventiva, que propõe eliminar ou reduzir as probabilidades de falhas em intervalos pré-planejados; (III) preditiva, por meio de monitoração contínua, permitindo a identificação de anomalias, indicando a necessidade de manutenção (SLACK; CHAMBERS; JOHNSTON, 2009).

De modo geral, a manutenção pode ser classificada em proativa e reativa: (I) proativa ou planejada pode ser denominada como preventiva, não havendo a expectativa de que o equipamento venha a falhar antes de iniciar as operações de manutenção; (II) manutenção reativa ou corretiva, ocorre após a ocorrência da evolução da falha, indo até a parada da mesma. Portanto, com parada não planejada (KOTHAMASU; HUANG; VERDUIN, 2009). Na Figura 8, apresentamos as nomenclaturas básicas que compõem a Taxonomia de Manutenção Proativa e Reativa.

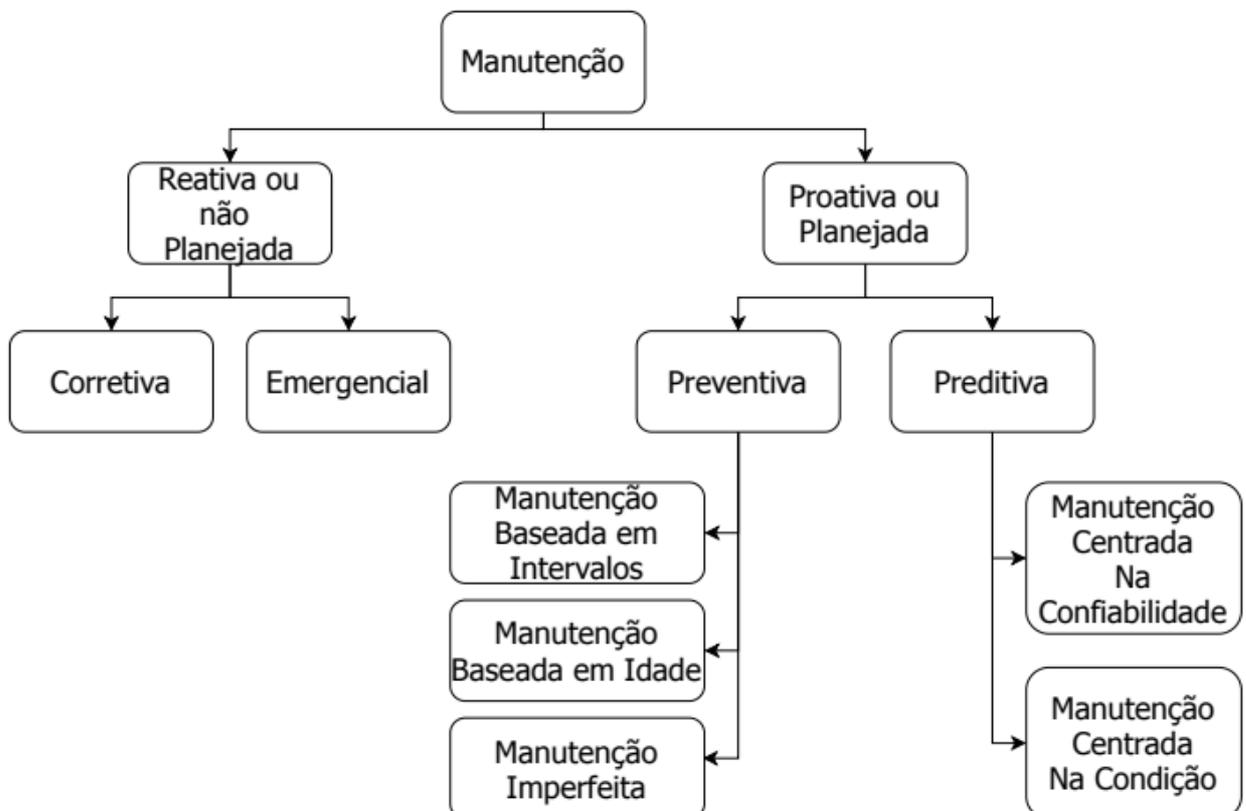
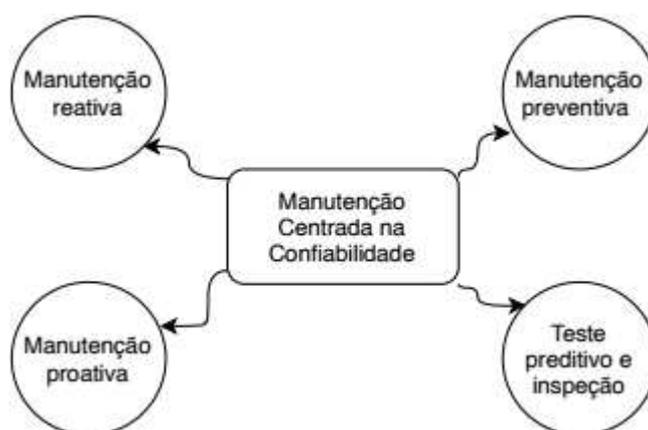


Figura 8 – Taxonomia Da Manutenção

Fonte: (KOTHAMASU; HUANG; VERDUIN, 2009), adaptado pelo autor

A taxonomia da manutenção apresentada na Figura 8 abrange as principais estratégias utilizadas na indústria (CHESWORTH; BENG, 2018). A abordagem HealthMon se concentra na estratégia Proativa, se aplicando diretamente à manutenção preventiva, porém viabilizando a parte preditiva ao observar as tendências do IGS. A manutenção preditiva se caracteriza como uma abordagem proativa, conforme apresentado na figura 8. Na literatura, averiguamos outras formas de representar essas abordagens, como, por exemplo, a proposta de Dhillon (2002), que coloca a Manutenção Centrada na Confiabilidade (MCC) ou Reliability-Centred Maintenance (RCM), a qual é composta pelo seguintes componentes: manutenção reativa, manutenção preventiva, teste e inspeção preditivos e manutenção proativa, como mostra a Figura 9.

Figura 9 – Manutenção Centrada na Confiabilidade (MCC)



Fonte: (DHILLON, 2002), adaptado pelo autor.

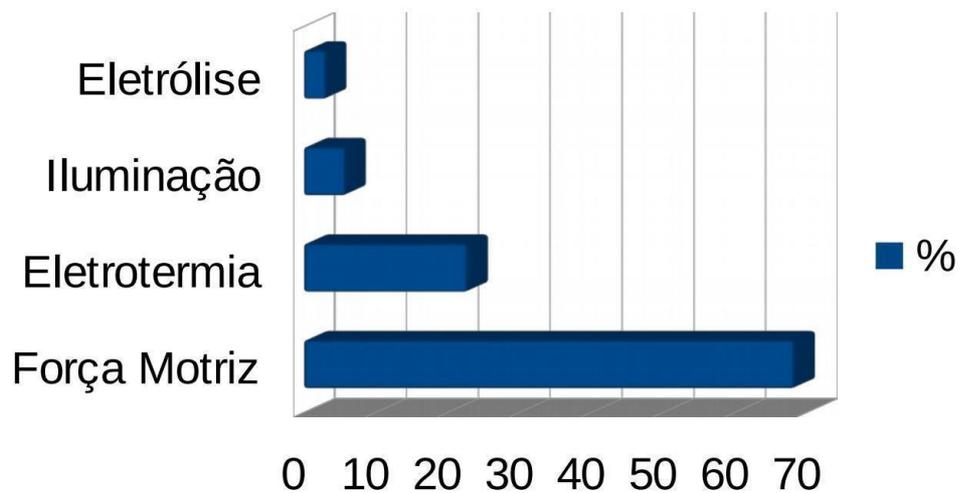
A MCC tornou-se tão relevante como abordagem para a manutenção industrial que foi considerada um dos braços da engenharia. De acordo com Dhillon (2002), a engenharia de confiabilidade, em conjunto com outras abordagens proativas de manutenção, envolve o

redesenho, modificação ou aprimoramento de itens/peças ou sua substituição por melhores itens/peças. Realizar manutenção preventiva nas máquinas tem sido uma prática comum na área industrial há muito tempo em virtude de esta prática resultar em redução de custos para as organizações. Segundo Ariza (1977), a manutenção preventiva pode reduzir pela metade os custos com manutenção corretiva. Nesse caso, o presente trabalho mantém o foco na manutenção preventiva/preditiva por ser uma abordagem que prevê o envolvimento da computação e da engenharia para atingir seus objetivos e fornecer subsídios à realização da manutenção preventiva em equipamentos com base na condição.

Na concepção de Dhillon (2002), há uma variedade de tecnologias que podem e devem ser usadas como parte de um programa abrangente de manutenção preditiva. Conforme o autor, os sistemas ou as máquinas mecânicas são responsáveis pela maioria dos equipamentos da fábrica, sendo o monitoramento de vibrações considerado o componente principal da manutenção preditiva. Para fins de implementação de testes e validação do desenvolvimento de um novo sistema, entende-se que o motor elétrico de indução trata-se de um ótimo candidato. Dentre todas as máquinas presentes na planta fabril, o motor elétrico é a máquina mais usada para transformar energia elétrica em energia mecânica, pois combina as vantagens da utilização de energia elétrica (baixo custo, facilidade de transporte, limpeza e simplicidade de comando) com sua construção simples e robusta a baixos custos com grande versatilidade de adaptação aos mais variados tipos de cargas (WEG/SEBRAE, 2016).

De acordo com pesquisas realizadas no Brasil, os motores elétricos representam a força motriz da indústria, sendo eles responsáveis por mais de 68 % do consumo de energia elétrica (ELETROBRAS; PROCEL-INFO, 2008), como revela a Figura 10.

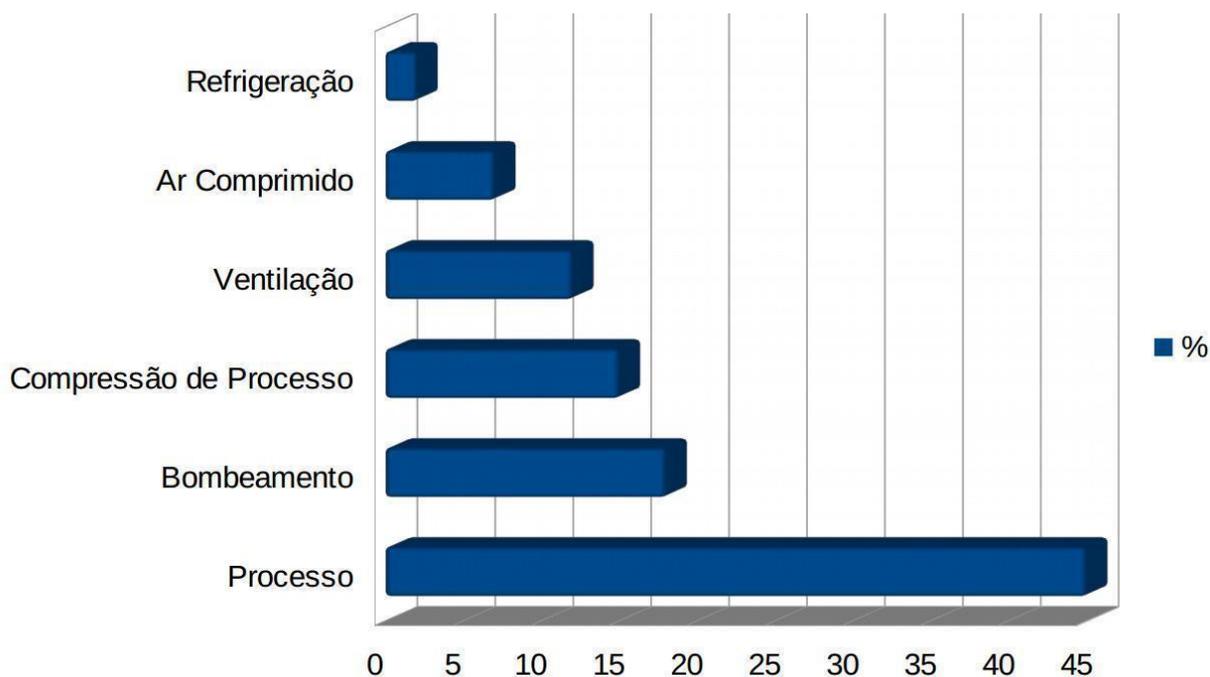
Figura 10 – Distribuição do consumo de energia elétrica por uso final na indústria



Fonte: (ELETROBRAS; PROCEL- INFO, 2008), adaptado pelo autor.

A mesma pesquisa mostra que os motores representam uma parcela significativa do consumo de energia na indústria, demonstrando, assim, a importância desse componente para o processo produtivo. A Figura 11 permite interpretar e identificar a finalidade de utilização desses motores, verificando o consumo de energia pela sua aplicação na indústria.

Figura 11 – Distribuição do consumo de energia elétrica na força motriz na indústria



Fonte: (ELETROBRAS; PROCEL- INFO, 2008), adaptado pelo autor

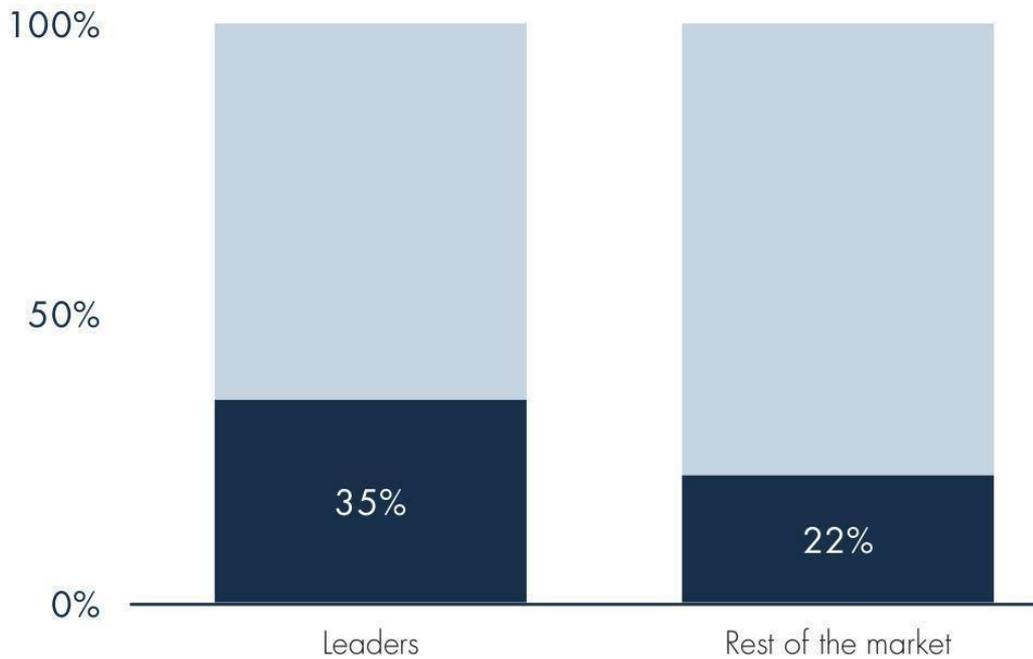
Diante de diferentes abordagens para a manutenção, torna-se de extrema importância que as organizações desenvolvam estratégias para o gerenciamento da saúde de seus ativos, mas, principalmente, máquinas e equipamentos por estarem diretamente relacionadas com a produção de produtos, bens e serviços, conseqüentemente, com a fonte de renda da companhia. De acordo com Söderholm (2005), a saúde, ou condição, de um sistema técnico muda com o tempo, uma vez que os elementos no sistema estão sujeitos à degradação, a qual mais cedo ou mais tarde levará à falha no sistema. Desse modo, o gerenciamento da saúde pode ser aplicado para melhorar a segurança e a confiabilidade de máquinas e equipamentos, possibilitando diminuir custos por paradas, conseqüentemente estendendo vida útil do ativo. É possível verificarmos na literatura que a abordagem que mais vem se destacando é Manutenção Centrada na Confiabilidade. Para Söderholm (2005), uma contribuição vital do RCM é a definição de falha potencial, que conduziu ao conceito de Manutenção Baseada em Condição (CBM), sendo aceito como uma das melhores maneiras de prevenir a falha funcional. Na visão desse autor, o foco no CBM levou a um setor completamente novo, que fornece ferramentas para o monitoramento da integridade do sistema. O diagnóstico está preocupado com a interpretação dos dados de saúde coletados e com a conclusão oriunda da saúde atual do sistema.

2.3.2 Oportunidades com a Indústria 4.0

Diante desse cenário de grandes mudanças, no qual muitas indústrias tendem à migrar para o novo paradigma da Indústria 4.0, despontam-se novos leques de oportunidades. O setor de manufatura industrial também foi amplamente afetado por essa mudança de paradigma, resultando na ampla adoção de novas tecnologias digitais em seus processos e ativos (DIEZ-OLIVAN et al., 2019). Khan e Turowski (2016) asseguram que os desenvolvimentos recentes em TI abriram caminho para a próxima revolução industrial de modo a resultar na próxima revolução industrial, a qual tenderá a mudar nosso ecossistema. Os serviços de infraestrutura para a comunicação, como *hardware* e *software*, estão entre os beneficiados dessas oportunidades. O desenvolvimento em direção a uma Indústria 4.0 oferece oportunidades para a realização de uma imensa manufatura sustentável, usando a onipresente infraestrutura de tecnologia da informação e comunicação (TIC) (STOCK, 2016).

Por meio de estratégias de colaboração entre empresa e meio acadêmico, ambos podem ser beneficiados, uma vez que os centros acadêmicos são centros de pesquisa que contribuem com a busca por resultados que podem impactar diretamente nas operações das companhias, dentro do contexto da Indústria 4.0 (KHAN; TUROWSKI, 2016). Os parceiros industriais podem ajudar os parceiros acadêmicos a obter a tecnologia de ponta proprietária em termos de licenças de *hardware* e *software* (KHAN; TUROWSKI, 2016). A relação entre companhias igualmente tendem a se beneficiar por intermédio das integrações a fim de melhorar a produtividade e a qualidade dos produtos e serviços. Oportunidades crescentes também estão sendo abertas pelas tecnologias *Internet of Things* (IoT) e Sistemas Cyberfísicos (CPS), que permitem tornar a integração mais ampla e mais abrangente, compreendendo três níveis de integração na manufatura - integração vertical, integração horizontal e integração de ponta a ponta (GERRIKAGOITIA et al., 2019). De acordo com pesquisas (OWENS, 2018) [TRENDS IN DIGITAL MANUFACTURING – Implementing Industry 4.0] and building the Digital Factory], 35% dos líderes do setor industrial indicaram que já começaram a implementar iniciativas da Indústria 4.0 em oposição a apenas 22% dos outros entrevistados, conforme a Figura 12. Tais dados indicam grandes oportunidades para suprir as lacunas desse setor.

Figura 12 – Pesquisa de Implantação do Paradigma da Indústria 4.0



Fonte: (OWENS, 2018).

2.3.3 Recurso, Técnicas e Estratégias para Manutenção na Indústria 4.0

Ao longo dos anos, os pesquisadores de sistemas e controle foram pioneiros no desenvolvimento de poderosos métodos e ferramentas de ciência e engenharia de sistemas, como métodos no domínio do tempo e da frequência, análise do espaço de estados, identificação do sistema, filtragem, previsão, otimização, controle robusto e controle estocástico (DOYLE, 2011).

Grandes progressos estão sendo possíveis graças a trabalhos conjuntos entre a área da engenharia e da computação. Como frutos desses trabalhos conjuntos, foi possível aos pesquisadores de ciência da computação obterem grandes avanços em novas linguagens de programação, técnicas de computação em tempo real, métodos de visualização, projetos de compiladores, arquiteturas de sistemas embarcados e *software* de sistemas e abordagens inovadoras para garantir a confiabilidade, a segurança cibernética e tolerância a falha baseado em sistemas computacionais (DOYLE, 2011).

A pesquisa de sistemas ciberfísicos, como parte das estratégias para manutenção na Indústria 4.0, visa integrar os princípios de conhecimento e engenharia nas disciplinas de computação e engenharia (redes, controle, software, interação humana, teoria da

aprendizagem, bem como elétrica, mecânica, química, biomédica, ciência dos materiais e outras disciplinas de engenharia) para desenvolver nova ciência CPS e tecnologia de suporte. O *design* e a implementação de sistemas de controle em rede apresentam vários desafios relacionados à computação orientada por tempo e evento, *software*, atrasos variáveis, falhas, reconfiguração, sistemas de suporte, e à decisão distribuída (DOYLE, 2011). Dentre as estratégias para a manutenção da Indústria 4.0, está o controle de processo, que é, em muitos aspectos, uma tecnologia madura que atende indústrias maduras. As indústrias de processo historicamente têm sido um grande beneficiário de soluções avançadas de controle. Auto-sintonizadores de PID, controle preditivo de modelo e otimização em tempo real tiveram um impacto substancial no custo, eficiência e segurança das operações da planta de processo. Cientistas e engenheiros de controle devem continuar a se esforçar para superar barreiras, técnicas e de outra natureza, aumentando as demandas da sociedade e da indústria por eficiência energética, emissões reduzidas de GEE, operações mais competitivas e maior automação e capacidade de resposta em circuito fechado, todos prometendo demandas crescentes, controles avançados e tecnologias relacionadas nas indústrias de processo (DOYLE, 2011).

Outro recurso presente na indústria é o Sistema Sob Controle Cognitivo, que tem como objetivo:

- exibir comportamento orientado a objetivos na detecção, raciocínio e ação;
- mudar de maneira flexível seus objetivos e comportamento, dependendo do contexto e da experiência situacionais;
- ser capaz de agir em ambientes não estruturados sem intervenção humana e responder com robustez à surpresa;

A fim de alcançar essas propriedades, um sistema sob controle cognitivo precisa entender a situação atual (incluindo a consciência de si mesmo, de seu ambiente e de outros agentes). Para esse fim, o sistema de controle cognitivo deve implementar várias funções, como detecção (ativa), extração e abstração de informações relevantes, aquisição de conhecimento semântico, comparação com experiência anterior e atualização de conhecimento. Aliás, cabe enfatizarmos que técnicas computacionais estão sendo adotadas e, conseqüentemente, gerando resultados relevantes para o chão de fábrica. Grupos de pesquisa na área de processamento digital de imagens e reconhecimento de padrões estão caminhando para a sua perfeição com uma boa qualidade. Nesse caso, recomendamos um estudo

interdisciplinar das ciências correlacionadas. Em tal situação, o processamento digital de imagens é uma ferramenta que auxilia por meio da aquisição, digitalização e quantificação de uma imagem. A pesquisa diária por métodos e algoritmos, que fazem reconhecimento de padrões, tem sido bem desempenhada, sendo este o estado da arte do momento (NEVES et al., 2007).

A necessidade de gerenciar processos, máquinas e equipamentos em tempo real contribuiu muito para atuação da área de TI na busca de processar, armazenar e disponibilizar os dados e as informações obtidas por intermédio de dados. Conforme Neves et al. (2007), o desenvolvimento da automação, ligado à evolução de tecnologias, apresenta, na comunicação industrial, uma importante ligação com o crescimento da tecnologia da informação, especialmente, na relação entre os níveis gerencial e operacional. A TI, inicialmente alterou bastante as estruturas no ambiente de escritório, porém com o advento da Indústria 4.0 passa a influenciar também o ambiente industrial, nos mais diversos níveis de processos. Para Neves et al. (2007) o aumento de informações industriais de qualidade, resultou no amadurecimento das tecnologias. Deste modo, abrindo ainda mais o caminho para outras áreas da computação, como a inteligência artificial (IA), por meio de técnicas de aprendizado de máquina.

2.4 Inteligência Artificial, Técnicas de Machine Learning e Tecnologias Relacionadas

Nos dias atuais, por intermédio dos avanços das tecnologias, a Inteligência Artificial (doravante IA) está sendo bastante aplicada nas mais diferentes áreas do conhecimento. Verificamos a sua presença nos mais diferentes segmentos, visto ser uma ciência necessária e muito útil em um mundo cada vez mais conectado, em meio a grandes volumes de dados, onde se busca autonomia e vantagens que vão para além das capacidades humanas nas concepções de novas soluções inovadoras. As demandas para aplicação de IA na Indústria 4.0 é algo latente. Em poucas palavras, a IA pode ser definida como um ramo da ciência da computação, que se ocupa da automação do comportamento inteligente (LUGER, 2013). A próxima seção abordará *AI, IoT e Big Date* no contexto da Indústria 4.0.

2.4.1 *Machine Learning*

Os fundamentos da IA passam pelo Teste de Turing, pois o mesmo reuniu os conceitos básicos para uma validação daquilo que poderia vir a ser considerado uma autêntica inteligência artificial. Alan Turing (1950) projetou o teste para fornecer uma operação satisfatória da inteligência. O pesquisador sugeriu um teste baseado na impossibilidade de um interrogador humano diferenciar se o interlocutor é um computador ou um humano (RUSSELL; NORVIG, 2004). O teste envolvia, portanto, quatro capacidades:

- Processamento de linguagem natural: para permitir a comunicação, com sucesso em linguagem natural;
- Representação do conhecimento: para armazenar o que sabe ou ouve;
- Raciocínio automatizado: para usar a informação armazenada com a finalidade de responder a perguntas e tirar novas conclusões;
- Aprendizado de máquina: para se adaptar às novas circunstâncias e para destacar e explorar padrões.

Dentre esses quatro itens, o quarto é o que apresenta maior aplicabilidade para esta pesquisa, visto que o sistema proposto aplica técnicas de aprendizado de máquina, ou *Machine Learning* (ML), para identificação de padrões como parte do módulo de otimização.

Os sistemas de aprendizado de máquina (ML) criaram enormes efeitos sociais em uma ampla variedade de utilizações, como, por exemplo, visão computacional, processamento de fala, entendimento de linguagem natural, neurociência, saúde e Internet das Coisas (DIVYA; BHARGAVI; JYOTHI, 2018). Atualmente, notamos que existem várias aplicações para ML, dentre as quais, destacamos com a mineração de dados. O aprendizado de máquina pode ser aplicado com sucesso para análises e estabelecer relacionamentos entre vários recursos, melhorando a eficiência dos sistemas e os projetos das máquinas. (KOTSIANTIS, 2007).

Os métodos de ML revelam aos usuários estrutura oculta e permitem fazer previsões a partir de extensos conjuntos de dados. Tais métodos fornecem técnicas de aprendizado proficientes, dados ricos e vastos e condições efetivas de computação (DIVYA; BHARGAVI; JYOTHI, 2018). Para que ocorra o aprendizado de máquina, é necessário a combinação de alguns elementos. Para Divya, Bhargavi e Jyothi (2018), o ML é uma combinação de Ciência da Computação, Engenharia e Estatística.

Atualmente, há um número considerável de técnicas de ML na literatura, pois existem diferentes maneiras pelas quais um algoritmo pode modelar um problema com base em seu domínio de conhecimento. A Figura 13 apresenta as principais técnicas, sendo útil no sentido de orientar o método mais apropriado com relação às saídas que se pretende obter, com base no conhecimento do problema a ser resolvido. ML é o processo de construção de um modelo indutivo que aprende com uma quantidade limitada de dados sem intervenção especializada. Esse aprendizado implica em encontrar um conjunto subjacente de estruturas (ou padrões) que são úteis para entender relacionamentos em dados, os quais podem não ser exatamente semelhantes àqueles nos quais o aprendizado ocorreu (STETCO et al., 2019).

Os métodos do *Machine Learning* podem assumir três tipos de abordagens de aprendizagem, sendo elas: supervisionada, não supervisionada e por reforço (RUSSELL; NORVIG, 2004).

- Aprendizagem supervisionada: envolve a aprendizagem de uma função a partir de exemplos de suas entradas e saídas. É necessário que um "instrutor" forneça os valores corretos para entrada e a saída por meio de treinamento;
- Aprendizagem não supervisionada: abarca a aprendizagem de padrões na entrada, quando não são fornecidos valores específicos de saída. Isso não envolve treinamentos;
- Aprendizagem por reforço: este método consiste em uma intervenção inicial de um "instrutor" para que a aprendizagem ocorra de forma automática com as saídas geradas após o processamento. Para que isso aconteça, é preciso um subproblema para que o algoritmo aprenda como o ambiente funciona.

De forma simples e resumida, exibimos, na Figura 14, as possíveis aplicações de ML, de acordo com o tipo de problema.

Figura 13 – Mapeamento de Machine Learning



Fonte: (DIVYA; BHARGAVI; JYOTHI, 2018), adaptado pelo autor.

Figura 14 – Classificação de *Machine Learning*

	Aprendizado supervisionado	Aprendizagem não supervisionada
Discreta	Classificação ou Categorização	Agrupamento ou clusterização
Contínua	Regressão	Redução de dimensionalidade

Fonte: (SONI, 2019a), adaptado pelo autor.

Levando em consideração os tipos de problemas e suas quatro classificações nos quadrantes demonstrados na Figura 14, entendemos que basta relacionar com a abordagem (supervisionada ou não supervisionada) com a natureza da variável em questão (contínua ou discreta). De modo sucinto, a Tabela 1 apresenta uma análise comparativa entre a abordagem supervisionada e abordagem não supervisionada (SONI, 2019b). Ressaltamos que a

comparação não tem o objetivo de destacar que um é melhor em detrimento do outro, mas sim, salientar as características, evidenciando que a aplicação deve levar em conta tais características. No aprendizado supervisionado, o conceito de objetivo está relacionado à filiação de classe, enquanto no aprendizado não supervisionado, o conceito de objetivo geralmente está associado às estruturas inatas dos dados (ZHAO; LIU, 2007).

Tabela 1 – Análise Comparativa entre Aprendizado Supervisionado vs. Não Supervisionado

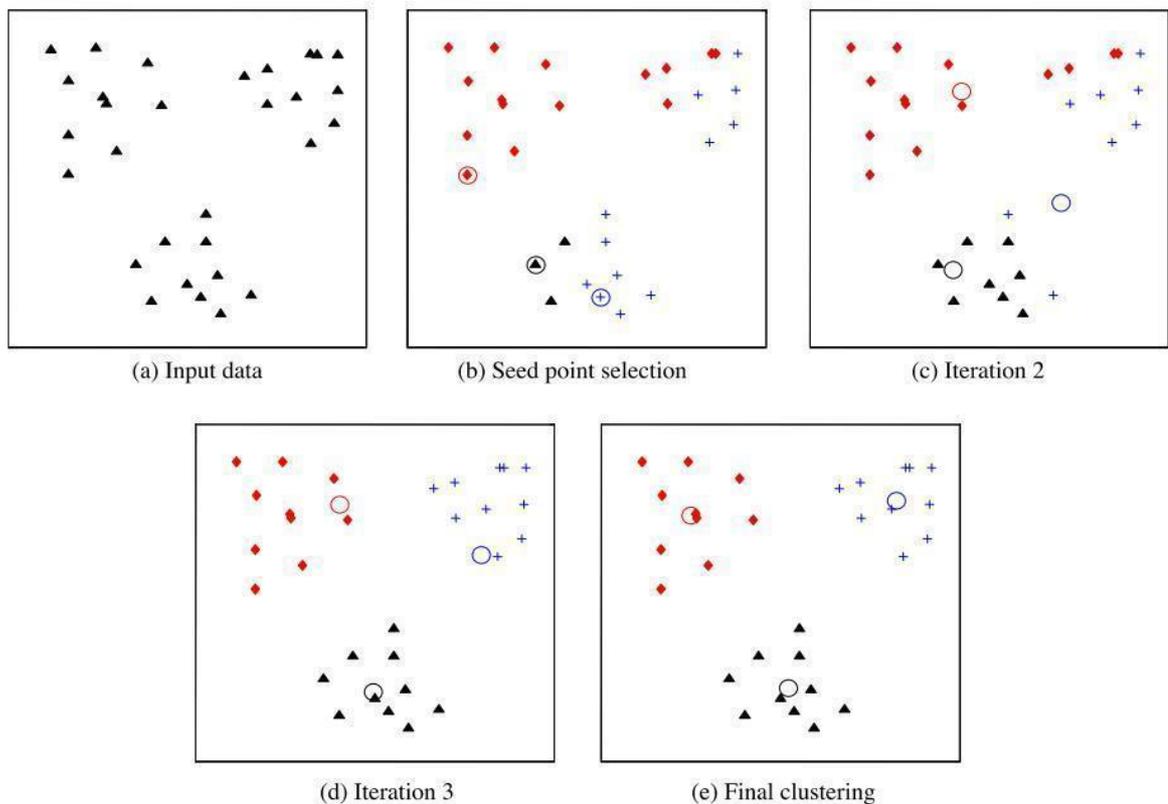
Parâmetros	Técnica de aprendizado de máquina supervisionado	Técnica de aprendizado de máquina não supervisionada
Processo	Em um modelo de aprendizado supervisionado, variáveis de entrada e saída serão fornecidas.	No modelo de aprendizado não supervisionado, apenas dados de entrada serão fornecidos
Dados de entrada	São treinados usando dados rotulados	Não são treinados. Não necessita dados já rotulados
Alguns Algoritmos usados	Máquina de vetores de suporte, rede neural, regressão linear e logística, floresta aleatória e árvores de classificação.	K-means, Hierarchical clustering, Genético
Uso de dados	Requer dados de treinamento para aprender fazendo link entre a entrada e as saídas	Não usa dados de treinamento para aprender
Aprendizagem em tempo real	O método de aprendizagem ocorre offline.	O método de aprendizagem ocorre em tempo real.
Número de Classes	O número de classes é conhecido.	O número de classes não é conhecido.

Fonte: (SONI, 2019b) - Adaptado pelo autor.

Embora abordagens supervisionadas, segundo a literatura, sejam amplamente utilizadas, presentes em muitos trabalhos que exibem resultados satisfatórios e altamente relevantes, isso não significa que abordagens não supervisionadas sejam incapazes de gerar resultados significativos. De acordo com pesquisas, as abordagens não supervisionadas parecem não serem aplicadas amplamente como os supervisionados; porém alguns estudos revelam, que ao realizar análise de desempenho entre estas duas abordagens, os não supervisionados exibem resultados promissores. Conforme Sathya e Abraham (2013), constatou-se que, mesmo que o algoritmo de aprendizado supervisionado por retroprojeção de erro seja muito eficiente para muitos problemas não lineares em tempo real, no caso da classificação de seus estudo envolvendo alunos, o modelo não supervisionado executou com maior eficiência com relação ao algoritmo de aprendizado supervisionado. Outros estudos realizados a esse respeito, envolvendo classificação de documentos, sugerem que abordagens não supervisionadas demonstram resultados promissores, comparados às abordagens não supervisionadas (OZGUR, 2015). Trabalhos desenvolvidos envolvendo processamento com palavras também se demonstraram encorajadores aplicando abordagens não supervisionadas (YAROWSKY, 1995).

Conforme visto na Figura 14, as aplicações podem ser classificadas em agrupamentos para variáveis discretas e redução de dimensionalidade para variáveis contínuas. A alta dimensionalidade dos dados apresenta desafios para as tarefas de aprendizado (ZHAO; LIU, 2007). No caso de abordagens envolvendo agrupamento e redução de dimensionalidade, o algoritmo K-means está entre os o mais citados na literatura (DING; HE, 2004). O objetivo do agrupamento de dados, também conhecido como análise de agrupamento, é descobrir o(s) agrupamento(s) natural(is) de um conjunto de padrões, pontos ou objetos. O algoritmo básico de K-means foi estendido de várias maneiras diferentes. Algumas dessas extensões lidam com heurísticas adicionais que envolvem o tamanho mínimo do cluster e clusters de mesclagem e divisão (JAIN, 2010). A heurística pode ser definida como uma estratégia de busca com informação. Ou seja, uma estratégia que utiliza um conhecimento específico do problema. Essa abordagem igualmente pode ser chamada de busca da melhor escolha (RUSSELL; NORVIG, 2004).

Figura 15 – Exemplo de Aplicação do Algoritmo K-means



Fonte: (JAIN, 2010).

Conforme apresentado na Figura 15, (a) dados de entrada bidimensionais com três *clusters*; (b) três pontos de semente selecionados como centros de cluster e atribuição inicial dos pontos de dados aos clusters; (c) e (d) iterações intermediárias que atualizam rótulos de *cluster* e seus centros; (e) agrupamento final obtido pelo algoritmo K-means na convergência. O algoritmo de agrupamento K-Means é um algoritmo de agrupamento parcial, que está sendo aplicado em vários campos como a engenharia de software, a medicina, a biologia, a segurança de dados e o *marketing* (BISHNU; BHATTACHERJEE, 2012).

Um das características do algoritmos K-means é o modo de como um centróide de *clusters* se movem ao longo do tempo, significa que o conjunto está descrevendo um movimento de tendência e selecionando tendências processadas cuja ascensão ou queda consistente de acordo com a evolução da falha da máquina. Ele pode estabelecer uma ligação entre esses movimentos do centróide e o desgaste da máquina. A redução de dimensão é fundamental não apenas para reduzir as não linearidades na pesquisa de tendências nesse espaço (MASULLI; ROVETTA, 2015), mas também para eliminar componentes irrelevantes que não colaboram para rastrear a saúde da máquina em avaliação.

Para medir o quão crescente ou decrescente estão as tendências formadas pelos centróides de *clusters*, pode ser aplicada uma equação de monotonicidade. O conceito de monotonicidade é bastante geral e rico. Por outro lado, a monotonicidade sugere um certo aspecto da simplicidade, ou seja, cada atributo tem um efeito unidirecional no valor da função. Assim, saber que um conceito é monotônico pode ser útil em várias aplicações. De fato, essa forma de simplicidade é explorada pelo algoritmo de aprendizado (GOLDREICH et al., 1998). Dessa forma, a fim de calcular a monotonicidade, é viável aplicar a seguinte equação:

$$\Gamma = \frac{1}{M} \sum_{j=1}^M \left| \sum_{k=1}^{N_j-1} \frac{\text{sgn}(x_j(k+1) - x_j(k))}{N_j - 1} \right|, \quad (2.2)$$

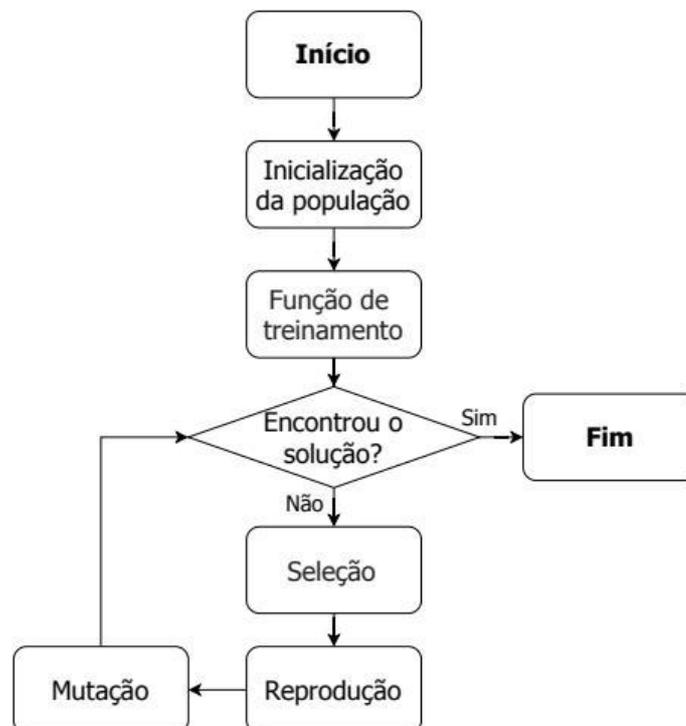
na qual x_j representa o vetor de medições de um recurso no j th sistema, M é o número de sistemas monitorados e N_j é o número de medições no sistema. O símbolo k representa o índice dentro do vetor x .

Quando se trabalha com espaços multidimensionais, conforme verificado em estudos, geralmente se aplicam técnicas de buscas. Nesse sentido, nas últimas décadas, o Algoritmo Genético (GA) recebeu muita atenção em relação ao seu potencial como técnicas de otimização global para problemas de otimização complexos (JAVADI; FARMANI; TAN, 2005). Esse algoritmo se destaca por sua empregabilidade em problemas com alta dimensionalidade (ISHIBUCHI; MURATA, 1998). Ele é baseado em uma metáfora biológica que veem o aprendizado como uma competição em uma população de soluções evolutivas para o problema (LUGER, 2013). Seu funcionamento consiste em avaliar, por meio de uma função de "aptidão", se cada solução gerada contribuirá para a próxima geração de soluções. Então, por intermédio de operações análogas à transferência de genes na reprodução sexual, o algoritmo cria uma nova geração de soluções candidatas (LUGER, 2013). As melhores soluções são selecionadas para se reproduzir e se transformar e as piores são descartadas (SHAPIRO, 2001). De acordo com Bankovic et al. (2008), os AGs oferecem certas vantagens sobre outras técnicas de aprendizado de máquina, a saber:

- os GAs são intrinsecamente paralelos, uma vez que possuem vários filhos, logo podem explorar o espaço da solução em várias direções ao mesmo tempo;

- se um caminho acaba sendo um beco sem saída, eles podem facilmente eliminá-lo e continuar trabalhando em caminhos mais promissores;
- devido ao paralelismo que lhes permite avaliar implicitamente muitos esquemas de uma só vez, os algoritmos genéticos são particularmente adequados para resolver problemas em que o espaço de todas as soluções em potencial é realmente enorme - muito vasto para pesquisar exaustivamente em qualquer quantidade de tempo razoável, são como uma rede de dados;
- trabalhar com populações de soluções candidatas, em vez de uma solução única, e empregar processos estocásticos, para orientar as definições de busca, permite que os GAs lidem bem com interações de atributos e evitem ficar presos aos máximos locais, o que, juntos, os torna muito adequados para lidar com problemas de otimização;
- um sistema baseado no GA pode ser facilmente treinado novamente, podendo ser aplicado para abordagens supervisionadas e não supervisionadas.

Figura 16 – Exemplo Algoritmo Genético Clássico



Fonte: Adaptado pelo autor, (BHASIN; BHATIA, 2011).

Conforme apresentado na Figura 16, o GA consiste em 5 etapas:

(I) População inicial: O processo começa com um conjunto de indivíduos chamado População. Cada indivíduo é uma solução para o problema a ser resolvido. Um indivíduo é caracterizado por um conjunto de parâmetros (variáveis discretas, sendo zeros e uns) conhecidos como Genes. Em um algoritmo genético, o conjunto de genes de um indivíduo é representado usando um vetor com valores binários.

(II) Função de condicionamento físico: A função de condicionamento físico determina como um indivíduo está apto, ou seja, a capacidade de um indivíduo competir com outros indivíduos.

(III) Seleção: O objetivo desta fase de seleção é selecionar os indivíduos mais aptos e permitir que eles passem seus genes para a próxima geração dois pares de indivíduos (pais) são selecionados com base em suas pontuações de condicionamento físico. Indivíduos com alta aptidão têm mais chances de serem selecionados para reprodução.

(IV) *Crossover*: O cruzamento, ou *crossover*, é a fase mais significativa de um algoritmo genético. Para cada par de pais a serem cruzados, um ponto de cruzamento é escolhido aleatoriamente dentre os genes.

(V) Mutação: Em certos novos filhos formados, alguns de seus genes podem ser submetidos a uma mutação com baixa probabilidade aleatória. Isso implica em que alguns dos *bits* da cadeia de *bits* podem ser invertidos.

Por ser o AG uma técnica de busca e otimização (AURÉLIO; PACHECO, 2020), ele tornou-se um algoritmo clássico e consagrado, presente em muitas pesquisas, que permite bom desempenho, sendo, assim, muito comum encontrá-lo em abordagens de Indústria 4.0. Tanto o K-means quanto o GA são métodos aplicados no presente trabalho, que por sinal, rendem bons resultados, conforme será visto na Seção 4.

2.4.2 *Internet of Things* no contexto da Indústria 4.0

Diante de tantas mudanças provenientes do surgimento da Indústria 4.0, novas lacunas são identificadas, dentre elas está a conectividade. Esta lacuna é perfeitamente preenchida por meio das soluções denominada de *Internet of Things*, comumente conhecida como *Internet* das Coisas, ou IoT. Soluções em IoT permitem a integração entre sensores e atuadores (SINGH; KAPOOR, 2017), sendo estes dispositivos muito úteis neste contexto da indústria 4.0. A IoT é considerada um conceito moderno de manufatura no setor 4.0 e adotou avanços recentes, como infraestrutura de TI para aquisição e compartilhamento de dados, que influenciam muito o desempenho de um sistema de manufatura (ZHONG et al., 2017).

Muitos termos relevantes como custo eficaz, rede de sensores, sistemas embarcados, segurança e privacidade, processamento de dados e sinais, computação em nuvens, interoperabilidade, tecnologia de rede, gerenciamento de rede, protocolos e padrões de comunicação, eletrônica de semicondutores, entre outros; são termos presentes na indústria, cruciais para a inserção no paradigma de Indústria 4.0 e também pertencentes ao paradigma da IoT. A Figura 17 mostra a *Smart Factory*, conhecido como *Intelligent Factory*, ou *Intelligent Manufacturing*, como sendo uma das aplicações da IoT, de modo que este tipo de aplicação constitui o contexto da Indústria 4.0.

O conceito de *Internet of Things* foi cunhado por um membro da comunidade de desenvolvimento de identificação por radiofrequência (RFID) em 1999 e recentemente se tornou mais relevante para o mundo prático em grande parte devido ao crescimento de dispositivos móveis, comunicação incorporada e onipresente, computação em nuvem e análise de dados (KEYUR K PATEL, 2016). A IoT pode ser definida como um conceito, no qual objetos e coisas físicas podem se conectarem por intermédio de uma estrutura de rede pelo uso de *hardwares* ou dispositivos embarcados; e podendo ser classificada em três categorias, como: (1) Pessoas para pessoas, (2) Pessoas para máquina/coisas, (3) Coisas/máquina para coisas/máquina, interagindo por meio da *internet*. Desse modo estabelece um paradigma que considera presença generalizada no ambiente de uma variedade de coisas/objetos que, por intermédio de conexões com e sem fio e esquemas de endereçamento exclusivos, são capazes de interagir entre si e de cooperar com outros itens/objetos para criar novos aplicativos/serviços (KEYUR K PATEL, 2016).

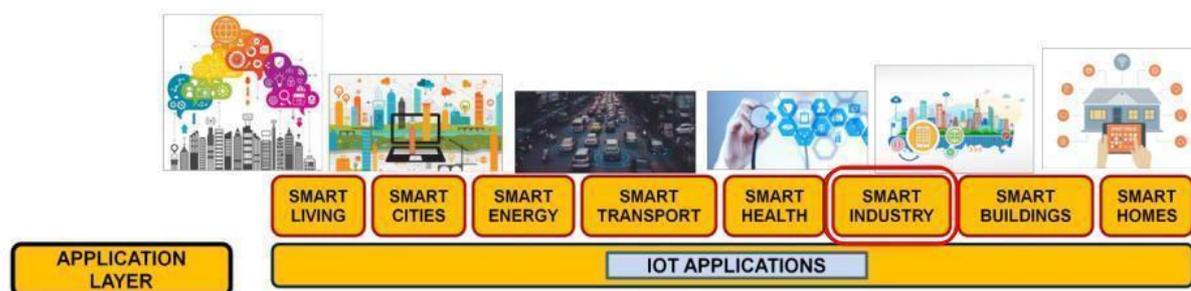


Figura 17 – Aplicações de IoT

Fonte: (KEYUR K PATEL, 2016) - Adaptado pelo autor

Do ponto de vista industrial, é válido afirmar que, conforme Chesworth e Beng (2018), a IoT fornece uma rede em tempo real, na qual os dados, de modo confiáveis, podem ser transmitidos para um *hub* principal, no qual cada sensor colocado em um ativo pode ser integrado a essa rede e fornecer acesso a dados, anteriormente impraticáveis. É possível afirmarmos que a IoT ultrapassou as barreiras acadêmicas, restringindo-se às pesquisas, para tornar-se realidade nos negócios. Contudo, de acordo com uma pesquisa realizada pela Cisco, 60% das iniciativas de IoT não vão além do estágio de Prova de conceito (PoC) (PRESENTO, 2018), ou seja, trata-se de uma área com muito potencial de expansão.

2.4.3 *Big Data* no contexto da Indústria 4.0

Com o aumento de aplicações IoT, o grande volume de dados gerados a partir destas aplicações passam a estar cada vez mais acessíveis e onipresentes em muitos setores, resultando em um enorme volume de dados em tempo real denominado *Big Data* (MANYIKA et al., 2011). Os dados classificados como *big data* podem derivar de vários canais como sensores, dispositivos, áudio e vídeo, redes, arquivos de log, aplicativos transacionais, *web* e *feeds* de mídia social (FOSSO WAMBA et al., 2015). Quando todos os dados são agregados, essa combinação é chamada de “*Big Data*” (LEE et al., 2013).

As tecnologias, combinadas com outras técnicas para análise e processamento de dados em tempo real, podem contribuir para otimizar as operações, assim como o processo de tomada de decisões em tempo real (CHAN, 2013). No contexto da Indústria 4.0, a necessidade de lidar com *Big Data* se faz presente. Portanto, para organizações e fabricantes com uma abundância de dados operacionais e de chão de fábrica, técnicas avançadas de análise são críticas para descobrir padrões ocultos, correlações desconhecidas, tendências de mercado, preferências do cliente e outras informações úteis sobre negócios (ZHONG et al., 2017).

Dedicar atenção a *Big Data*, assim como fazer os devidos investimentos podem resultar em aumento de lucratividade para as companhias. Pesquisas acadêmicas e na indústria revelam, que os varejistas podem obter um aumento entre 15% a 20% no retorno do investimento ao introduzir tecnologias BDA (ZHONG et al., 2017). A fim de que os fabricantes se tornem mais competitivos, faz-se necessário integrar sistemas avançados de

computação e Ciberfísico para se adaptar e tirar proveito do atual ambiente de *Big Data* (LEE et al., 2013).

2.4.4 Séries Temporais

Séries temporais podem ser definidas como sendo observações que são ordenadas em intervalos regulares de tempo (MORETTIN; CASTRO TOLOI, 1981). Por exemplo, mensurar o valor de uma variável a cada segundo, minuto, hora, dia, mês, etc. Pode ser descrita como $f_Y(t); t \in T_g$, onde Y é a variável de interesse e T é o conjunto de índices. Existem duas terminologias para séries temporais (EHLERS, 2007), discretas ou contínuas.

De modo geral, séries temporais tendem a ser do tipo discreta ou contínua. A primeira terminologia é a de séries temporais discretas (EHLERS, 2007; MIGON, 2005). Nestas, existem intervalos bem definidos, como, por exemplo, vendas mensais do ano de 2015 (EHLERS, 2007). Neste caso, tem-se $T = \{t_1; t_2; \dots; t_n\}$ (MIGON, 2005). A outra é a de séries temporais contínuas, na qual os intervalos são contínuos, por exemplo, a cada hora durante um espaço maior de tempo (EHLERS, 2007). Um exemplo pode ser o registro de maré de Florianópolis dos últimos 5 anos, o qual é observado a cada hora (MIGON, 2005). Tem-se então, $T = \{t : t_1 < t < t_2\}$ (MIGON, 2005). Em vista disso, pode-se fazer uma série contínua se tornar discreta, avaliando um espaço de tempo determinado. Diversas áreas aplicam séries temporais como parte de suas soluções. Dentre elas, citam-se áreas como: economia, medicina, epidemiologia, meteorologia, entre outros (EHLERS, 2007). Segundo Ehlers (2007), seria importante considerar a ordem temporal de cada variável, tendo em vista que as observações vizinhas são dependentes.

Séries temporais possuem quatro principais objetivos de estudo (EHLERS, 2007). Sendo estes:

(I) tentar descrever as características de uma série, tais como, o padrão de tendência, existência de variação sazonal, *outliers* (pontos fora do padrão) e ainda alterações estruturais, etc. (EHLERS, 2007).

(II) tentar explicar a variação de uma série aplicando outra série sobre ela.

(III) um dos mais importantes, é utilizar as séries temporais para prever futuros valores com base no histórico (EHLERS, 2007). Isso é possível por se ter os dados ordenados no tempo e cada observação sendo dependente das observações vizinhas (EHLERS, 2007). Com

isso, é viável, por exemplo, tentar prever o valor de alguma ação de acordo com o histórico dela.

(IV) é poder analisar periodicidades relevantes nos dados, podendo, dessa forma, avaliar alguma característica específica da série.

De acordo com Ehlers (2007), é permitido ser captadas diversas propriedades de uma série temporal X_t , decompondo $X_t = T_t + C_t + R_t$, onde:

- T_t é a tendência, ou seja, uma mudança no nível médio da série em longo prazo;
- C_t é o componente cíclico que captura repetições em um espaço de tempo definido;
- R_t é o componente de ruído. Espera-se que seja aleatório.

Existem diversos modelos adequados para séries temporais, cada um com suas características. Esses modelos são chamados de processos estocásticos (EHLERS, 2007). Uma importante classe de processos estocásticos são os processos estacionários, nos quais todas as características do comportamento do processo não são alteradas no tempo, de forma que escolher a origem dos tempos não é importante. O primeiro processo estocástico é o de métodos de médias (EHLERS, 2007). Esse método tem por finalidade suavizar a série temporal, removendo valores discrepantes, os chamados *outliers*. Para isso, é atribuído um peso para cada observação, de forma a dar mais ou menos importância à observação de acordo com o tempo em que a mesma foi obtida. Dependendo de como o peso é calculado, pode-se definir um método mais específico, como por exemplo, média móvel (MA) e suavização exponencial.

Séries temporais geralmente são as bases para o processamento de algoritmos de ML. Embora exista um número razoável de contribuições empregando algoritmos de aprendizado de máquina em áreas relacionadas, como previsão tradicional de séries temporais ou aprendizado de desvio de conceito, raramente são cobertos conjuntos de dados com fluxos de sensores de uma planta de produção (FAHIM, 2013). Com as técnicas adotadas por meio dessa abordagem, presumimos que o processamento sobre as séries temporais, em uma planta de produção, possibilita realizar descobertas em conjunto de dados que resultarão em grandes contribuições, tanto para a indústria quanto para a comunidade acadêmica.

Este estudo aplica o processamento em séries temporais, sendo estas, elementos cruciais e fundamentais para as técnicas subsequentes. Para isso, envolve técnicas de decomposição de sinais sobre as séries temporais, os elementos de entrada do sistema, em seguida aplica técnicas de ML, de modo a resultar na geração de um índice global de saúde da máquina, conforme será descrito na Seção 4.

2.5 Considerações parciais

Este capítulo abordou os principais conceitos envolvidos no tema do presente trabalho. Neste capítulo, visamos resgatar os fundamentos essenciais, que entendemos ser de extrema relevância para a abordagem desenvolvida. Pelo fato de este trabalho pertencer ao contexto de “Indústria 4.0”, pareceu-nos conveniente resgatar suas origens, evidenciando a evolução deste movimento até os dias atuais. Introduzida a indústria, abordamos na sequência “Falhas em Máquinas Industriais e seus Impactos”, por ser este um dos temas centrais de nosso trabalho. Como o setor de manutenção das indústrias são os principais responsáveis do tratamento de falhas, abordamos “Manutenção em Máquinas Industriais”. Dentro dessa linha de pensamento, avançamos para verificar a “Abordagem para a Manutenção”, dado a necessidade de compreensão das estratégias mais adotadas atualmente, conforme os desafios modernos exigem; desafios estes que cada vez mais crescente com o advento do movimento emergente oriundos da chamada Indústria 4.0. Para isso, ampliamos as análises para as “Oportunidades com a Indústria 4.0”. Neste ínterim, pareceu-nos oportuno abordar ainda o assunto “Recurso, Técnicas e Estratégias para Manutenção na Indústria 4.0”.

Após resgatar os fundamentos da Indústria 4.0 e conceitos relacionados envolvendo falha e manutenção, nos concentramos em abordar assuntos diretamente relacionados com as implementações, sendo estes: (i) “Inteligência Artificial, Técnicas de *Machine Learning* e Tecnologias Relacionadas”, nos quais revisamos os algoritmos e técnicas que pretendemos adotar, como K-means e o Algoritmo Genético; (ii) “Big Data no contexto da Indústria 4.0”, pelo fato da abordagem desenvolvida realizar o processamento de dados, considerando temas atuais no contexto da Indústria 4.0; (iii) destacamos “Séries Temporais”, por ser este o tipo de dados que a solução desenvolvida deverá processar. Podemos concluir que, por meio dos conceitos apresentados, percebemos total coerência entre a literatura apresentada e o que está sendo desenvolvido. Consequentemente, este capítulo visou a estabelecer conexão, com base na literatura, com os conceitos, métodos e técnicas mencionados no presente trabalho.

3 TRABALHOS RELACIONADOS

Neste capítulo, tratamos dos trabalhos relacionados na interseção de manutenção inteligente, Indústria 4.0, funcionamento da máquina e séries temporais para contribuir com recursos de monitoramento e predição para suporte manutenção industrial. A metodologia, empregada na seleção dos trabalhos, é especificada na Seção 3.1.

3.1 Metodologia de Pesquisa para Seleção dos Trabalhos

A metodologia de pesquisa consistiu em verificar, na literatura, artigos considerados similares, nos quais foram selecionados pelas peculiaridades de suas propostas. Para a execução de tal, foi necessário realizar uma revisão sistemática, a qual será apresentada na Subseção 3.2.1. Para aprofundar a análise dos trabalhos, a Tabela 2 demonstra os artigos selecionados após o processo de análise. O objetivo de desenvolver uma de revisão sistemática é a possibilidade de realizar uma análise da literatura envolvendo critérios claros por meio de uma metodologia estruturada. Portanto, que visa a reunir todas as evidências empíricas que atendam aos critérios de elegibilidade pré-especificados a fim de responder a uma pergunta de pesquisa específica. Este tipo de pesquisa aplica métodos explícitos e sistemáticos selecionados com o objetivo de minimizar o viés, fornecendo, assim, conclusões mais confiáveis (DONATO; DONATO, 2019). Nesta pesquisa, o objetivo não é aprofundar o assunto disponível na literatura, que poderia resultar em centenas, ou quem sabe milhares

de artigos; mas sim em aplicar os passos de uma revisão sistemática visando a obter os trabalhos mais recentes e relevantes dos últimos quatro anos (2017/2018/2019/2020). Consequentemente com uma quantidade não tão expressiva, porém suficiente para embasar o trabalho. Para isso, aplicamos nove passos previstos para a realização de uma revisão sistemática. Conforme Donato e Donato (2019), os passos podem ser desdobrados nas seguintes etapas:

1. Formular uma questão de investigação;
2. Produzir um protocolo de investigação e efetuar o seu registro (itens 1 e de 3 a 8 devem constar no protocolo de elaboração da revisão sistemática);
3. Definir os critérios de inclusão e de exclusão;
4. Desenvolver uma estratégia de pesquisa e pesquisar na literatura, visando a encontrar os estudos;
5. Seleção dos estudos;
6. Avaliação da qualidade dos estudos;
7. Extração dos dados;
8. Síntese dos dados e avaliação da qualidade da evidência;
9. Disseminação dos resultados

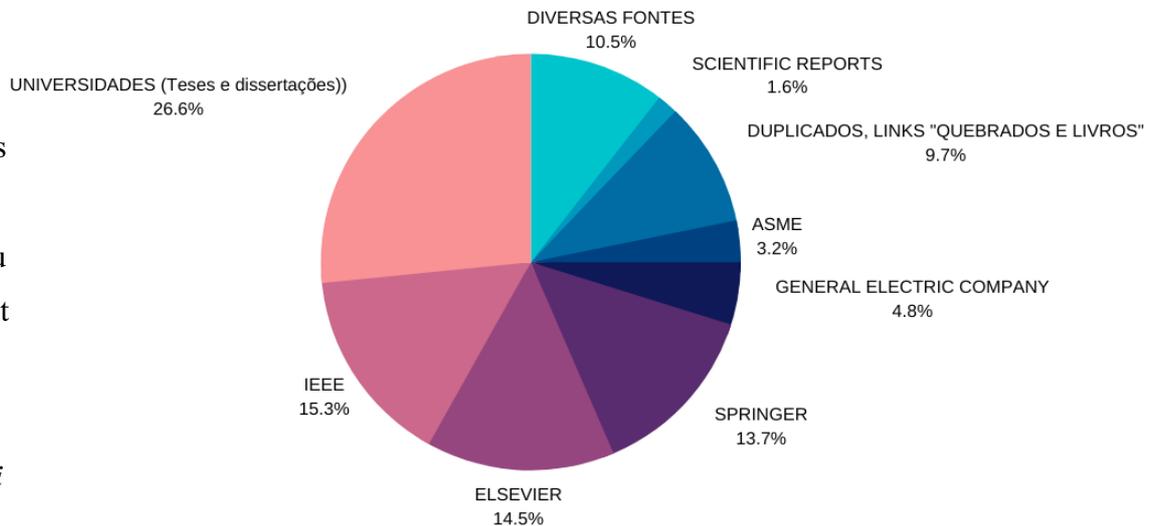
Figura 18 – *String*

de Busca

"maintenance" AND ("monitor*" OR "predict*") AND ("machine learning" OR "ML") AND "machine health"

Fonte: Elaborado pelo autor.

F
igur
a 19
—
Bas
es
de
Bus
ca
resu
ltant
es
da
String
de
Bus



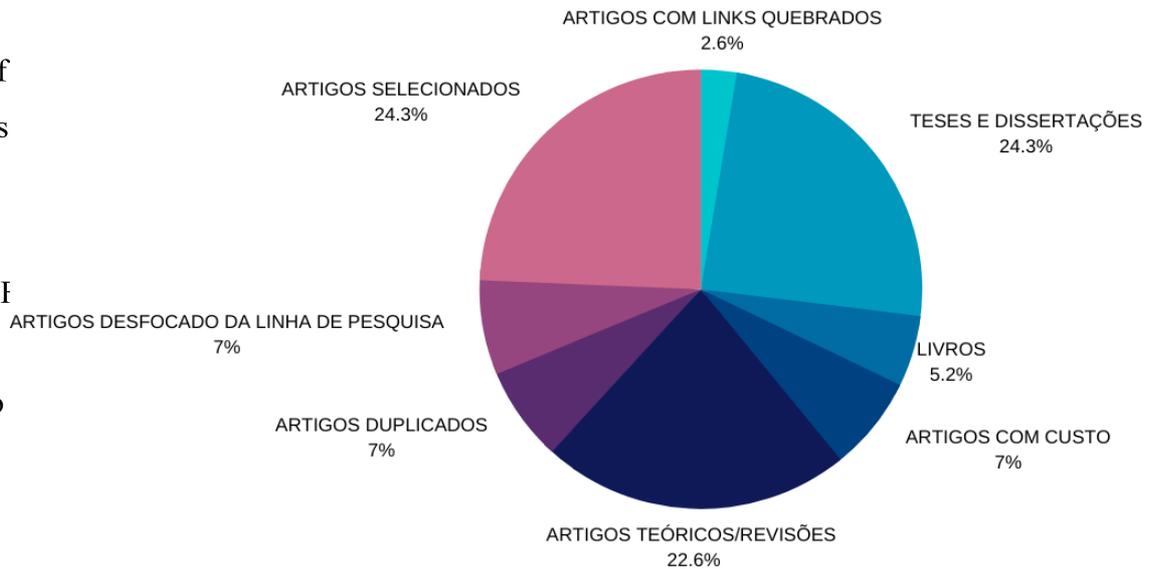
ca.

Fonte: Elaborado pelo autor.

No sentido de seguir as etapas de uma revisão sistemática, entendemos que o primeiro e o segundo passos foram satisfeitos na aplicação na chamada ‘*String* de Busca’, conforme apresentado na Figura 18, que nada mais são do que os termos que deverão estar presentes nos artigos que farão parte do volume inicial de trabalhos a serem analisados. O terceiro passo diz respeito aos critérios de inclusão e exclusão. Para tal, foi necessário ler partes dos trabalhos como título, resumo e palavras chaves de todos artigos. Note que, na Figura 18, o carácter "*" acompanha a palavra *monitor* e *predict*. Nesse contexto, esse símbolo tem a função de operador para refinar a pesquisa, indicando que toda palavra que conter os caracteres até o símbolo "*" deverão ser incluídas na busca, não importando a conjugação ou variação do termo daquele ponto em diante. Outro ponto que é importante ressaltar são os operadores booleanos "AND" e "OR" que são colocados com a finalidade estabelecer as condições para inclusão dos termos entre aspas duplas para a pesquisa.

Figura 20 – Trabalhos resultantes da String

de
Busca
,
classif
icados
por
tipo
I
onte:
Elabo
rado
pelo
autor.



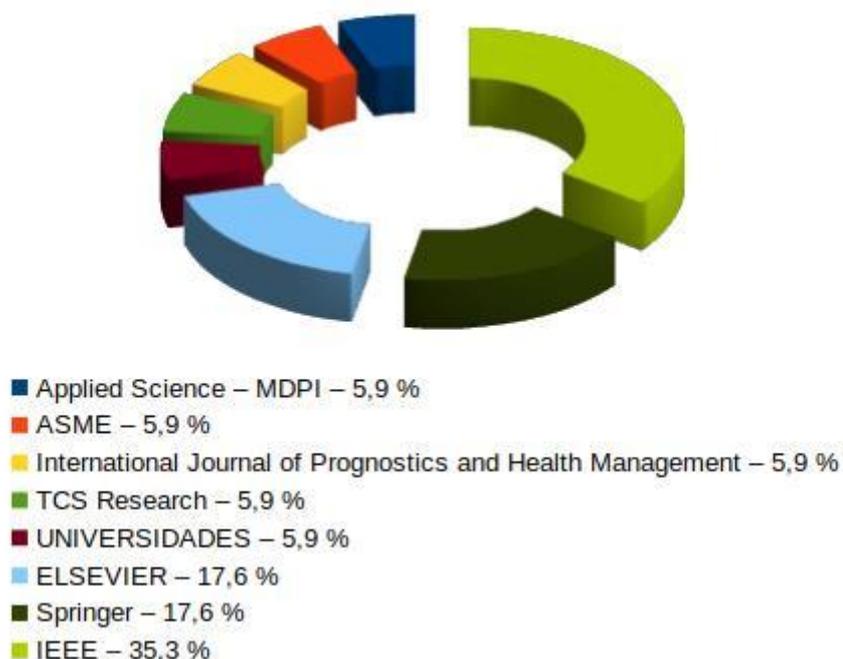
(
omo
critério de inclusão, o trabalho deveria propor uma abordagem relacionada ao monitoramento e/ou à predição para a indústria. Já, para o critério de exclusão, consideramos livros, teses, dissertações, artigos conceituais envolvendo apenas revisões na literatura, artigos duplicados, artigos com custo para sua aquisição, artigos desfocados do assunto da pesquisa, e artigos com links quebrados, aqueles que apresentam página não encontrada. O quarto passo consistiu em aplicar a *string* de busca na base do Google Scholar, que por sua vez "lincou" para outras bases como IEEE, Elsevier, Springer entre outras. A Figura 19 representa a pesquisa redirecionada para os diferentes portais de artigos. As quantidades mais significativas são 33 (%26,6)

Figura 21 – Processo de seleção dos artigos.



Fonte: Elaborado pelo autor

Figura 22 – Artigos selecionados



Fonte: Elaborado pelo autor.

Universidades, 19 (%15,3) IEEE, 18 (%14,5) Elsevier, 17 (13,7%) Springer. As outras menos significativas foram: 6 (%4,8) *General Electric Company*, com a mesma quantidade para livros, ASME resultou em 4 (3,2%). *Links*, quebras e trabalhos duplicados com a mesma quantidade de 3 (2,4%) para cada, 2 (1,6%) *Scientific Reports*. O saldo de 13 (10,5%) correspondeu as diversas fontes, sendo 1 trabalho de cada. Na Figura 20, esses mesmos trabalhos são classificados por tipo, cujas quantidades de cada tipo são descritas ao aplicar os critérios de exclusão. A Figura 21, por sua vez, revela o processo de seleção dos artigos.

Inicialmente, foram encontrados 124 artigos e, após refinamento, no qual foram removidos conforme critérios, foram excluídos 53 (42,74%) artigos. Ademais, foram removidos resultados que não eram artigos, tais como, livros, teses e dissertações, duplicados e *links* quebrados que foram listados a partir na aplicação da *string* de pesquisa. Após, aplicamos um filtro por leitura de título, resumos e palavras-chaves, no qual observamos artigos com o foco diferente daqueles almejados pela pesquisa, assim como aqueles que abordavam revisões e conceitos dentre os trabalhos selecionados. Essa etapa resultou em um total de 27 (43,55%) artigos excluídos. Restando 17 (13,71%) para realização da leitura e análise. Dos trabalhos selecionados, 6 (35,3%) correspondem as bases IEEE, 3 (17,6%) Elsevier e 3 (17,6%) Springer. Os outros 5 (29,4%) corresponderam as outras bases, sendo 1 artigo de cada base.

O quinto, sexto, sétimo e oitavo passos foram satisfeitos ao realizar a leitura dos artigos de modo a responder algumas às questões como:

- "Abordagem supervisionada?";
- "Abordagem não supervisionada/semi-supervisionada?";
- "Focado em máquina(s) específica(s)? Qual(ais)?";
- "Focado em partes de máquina(s) específica(s)? Qual(ais)?";
- "Aplica dados sintéticos ou reais para validação dos modelos?";
- "Foco em monitoramento?";
- "Foco em predição?".

Além dessas questões, que serão úteis à realização de uma análise comparativa, confere-se a Tabela 2, apresentada na Seção 3.3. Outras questões, como: (i) O que o artigo propõe? e (ii) Qual(ais) a(s) desvantagem(ns) do método/abordagem proposto com relação a abordagem HealthMon? Tais questões foram aplicadas no intuito de fomentar a discussão de modo que ambas as questões permitam alcançar as conclusões pretendidas, na qual constitui o nono e último passo, que consiste na divulgação dos resultados da pesquisa.

Na Seção 3.3, são apresentados os trabalhos relacionados, bem como suas tendências, na qual são ainda detalhados cada um dos pontos analisados na avaliação dos artigos. Por fim, na Seção 3.3, citamos as oportunidades de pesquisa e considerações parciais. A Tabela 2 mostra os trabalhos que foram encontrados na pesquisa sistemática realizada. Nessa seção, buscamos, com base na literatura, identificar as oportunidades de pesquisa via análise desses trabalhos.

3.2 Estado da Arte

Nessa seção, apresentamos o estado da arte. Compreendemos que esta é uma das partes mais importantes do trabalho em função de estudar e aprofundar os trabalhos já desenvolvidos, envolvendo os objetivos em comum deste trabalho, soluções para o monitoramento da saúde de máquinas.

3.2.1 Trabalhos Relacionados Obtidos em uma Revisão Sistemática

Nesta subseção, serão apresentados os trabalhos relacionados obtidos por meio das técnicas aplicadas para uma revisão sistemática, porém focando nos trabalhos mais recentes (últimos quatro anos) e de maior relevância de maneira que as palavras utilizadas para a busca filtrassem apenas trabalhos que essencialmente estejam relacionados com a manutenção envolvendo monitoramento e/ou predição, cujas implementações aplicam dados, sejam eles sintéticos ou reais. O objetivo da análise visa destacar a abordagem proposta, permeando suas contribuições, assim como vulnerabilidades percebidas. Para a execução de tal, será tomado como referência a Tabela 2, que permitirá relacionar a abordagem em análise com as demais trabalhos listados na tabela. Dessa forma, permitirá que a abordagem seja analisada de modo isolado ou em conjunto de outras, tendo como parâmetro a abordagem HealthMon.

Importante notar que foram utilizadas quatro notações distintas envolvendo o símbolo asterisco no preenchimento da Tabela 2, sendo elas: "*", "**", "***" e "****". Tais notações denotam que tais marcações contam com algum diferencial. No caso do símbolo "*" presente em alguns casos na coluna "Abord. NÃO supervisionada" indicam que foram identificados como abordagens que implementam algoritmos não supervisionado, no entanto alguns

autores classificam tais abordagens, redes neurais recorrentes (RNN) e redes neurais convolucionais (CNN), como abordagens semi-supervisionadas, partindo do princípio que a configurações semi-supervisionadas, apresentam poucos dados rotulados e muitos dados não rotulados (HUANG et al., 2014). Já o símbolo "***" adicionado em alguns casos da coluna "Máquina(s)" indica que a aplicação deve se estender para todas as máquinas daquele determinado tipo, porém um único tipo de máquina foi aplicado para a validação do modelo. O símbolo "****" associado à coluna "Parte Máquina(s)" indica que os autores não mencionaram a parte específica monitorada da máquina, nesse caso, presumimos que se aplica a toda a máquina. Por fim, o símbolo "*****" verificado na coluna "Dados sintéticos ou reais" aponta que os autores descrevem que receberam uma base de dados de parceiros, todavia, não descrevem se são dados reais ou sintéticos. Pelo fato de aplicarem para uma máquina com sensores que permitem a coleta dos dados, inferimos que são dados reais.

Ao realizar as análises dos trabalhos relacionados ao HealthMon, iniciando pela abordagem proposta por Amihai et al. (2018), na qual consistem em conceber um modelo envolvendo aprendizado de máquina para prever indicadores de integridade da máquina dentro de duas semanas. Foi possível verificarmos que a aplicação prática dessa abordagem, tornando a proposta compatível com o cenário real industrial, justificado pelo tempo de coleta e a origem dos dados. De acordo com os autores, o modelo foi desenvolvido usando uma arquitetura de rede neural recorrente (RNN) que incorpora entradas de dados reais de sensores, sendo aplicado uma abordagem supervisionada. Adicionalmente, o algoritmo k-means foi aplicado a fim de classificar dados de entradas dos sensores, sendo esta uma abordagem não supervisionada. Já a abordagem de Aremu et al. (2019) propõe um construtor de índice de saúde de máquina denominado "HI livre", no qual consiste em um modelo orientado a dados com base na divergência Kullback-Leibler (KLD). O intuito era construir uma representação por meio de um índice que descrevesse o desvio de um sistema em relação ao seu estado normal durante o monitoramento de condições. Logo, trata-se de um método que aplica entropia de informações para construir uma representação HI que descreve a ocorrência de falhas e suas influências durante o ciclo de vida de um sistema. Além de realizar a seleção de recursos para expor e remover sensores que não capturam informações relacionadas à condição de saúde do sistema. A aplicação dessa abordagem envolve ferramenta de pulverização em lote Cintillio SAT, com o foco no funcionamento do motor. As técnicas aplicam algoritmos de regressão de aprendizado de máquina (ML) de regressão aleatória de floresta (RFR) e regressão de processo Gaussian (GPR), as quais

foram implementadas para demonstrar a utilidade do HI construído pelo KLD para prognósticos sobre dados obtidos de sensores.

Em termos de abordagem robusta, a proposta de Zhang et al. (2019) merece especial atenção. Um bom motivo é o fato de estar focada em máquinas rotativas e vibrantes (deduzimos que seja para toda a máquina), algo que se assemelha com a abordagem HealthMon, outro motivo pelo fato de ter aplicado dados reais para validação do modelo. Notamos que diz respeito a uma abordagem híbrida, que combina o aprendizado automático (não supervisionado), cuja proposta é realizar o monitoramento da integridade da máquina com algoritmos supervisionados. Conforme os autores, os dados foram alimentados diretamente no modelo, que resultou em uma espécie de caixa preta, que torna a abordagem de baixa complexidade para aplicação real em uma planta industrial. A grande contribuição disso consiste em permitir que os modelos RNN capturem melhor informações de toda a sequência de sinais. Desse modo, os autores projetaram seu modelo, chamado AESGRU. Conforme mencionado, a validação do modelo contou com dois tipos de dados, dos quais, uma parte que envolvia rolamentos, que foram obtidos pelo *data center* (CWRU). A outra parte dos dados de vibração foram coletados pelos próprios autores. Segundo o artigo, os resultados experimentais mostram que a abordagem proposta supera as abordagens anteriores em termos de precisão. No entanto, os mesmos autores reconhecem uma grande desvantagem dessa abordagem, que consiste no custo computacional, exigindo enormes esforços dos computadores para os processamentos e, conseqüentemente, maiores valores de investimentos em *hardware*.

No tocante ao custo acessível, Li et al., (2020a) propõem uma abordagem para monitorar a degradação de lâmina de uma máquinas de serra de fita. Verificamos que a proposta prevê uma metodologia que resulta em um modelo de degradação de lâmina escalável, o qual seria adequado para implantação maciça na visão dos autores. Para isso, implementa modelo substituto baseado em rede neural convolucional profunda (DCNN) para substituir o modelo informado pela física. Sendo que o modelo substituto baseado em DCNN utilizará apenas dados alternativos de sensor de baixo custo. Para validação da abordagem foi aplicado dados reais que enriquecem ainda mais a proposta. De acordo com o autor, o modelo substituto construído pode ser facilmente implantado nas bordas da máquina ou plataformas remotas e com um custo muito mais baixo associado à implantação. Uma das ideias principais é gerar um indicador de saúde (HI) para monitorar a condição de desgaste da lâmina, utilizando os sinais críticos de vibração e acústicos.

No artigo desenvolvido por Campos et al., (2019), os autores não mencionam técnicas de *machine learning* (ML) aplicadas para a abordagem, porém realizam uma rica descrição sobre linguagem de programação, justificando o motivo de terem adotado a linguagem de programação Python. Apenas mencionam que sua abordagem é orientada a dados, envolvendo clusterização e classificação, o que leva a crer que se trata de uma abordagem não supervisionada. Nesse artigo é proposto um *Framework*, o *Arrowhead*, que é o resultado de um conjunto de projetos europeus (Arrowhead, SOCRADES, IMC-AESOP, ARUM, INTER-IoT etc.), nos quais os princípios das Arquiteturas Orientadas a Serviços (SOA) foram aplicados às aplicações industriais e de IoT. A abordagem dá ênfase a serviços que podem usar protocolos SOA diferentes como REST, COAP e XMPP, por igualmente se tratarem de *frameworks*; além de aplicar recursos de código aberto envolvendo integração com outros recursos da mesma natureza disponíveis como OSA-CBM e MIMOSA CRIS. Para validação foram aplicados dados sintéticos, nos quais utilizaram dados de falha de rolamento de um modelo de simulação com o objetivo de produzir sinais de vibração onde diferentes parâmetros do modelo podem ser controlados.

É possível afirmarmos que, de acordo com a literatura, muitas abordagens aplicam redes neurais como parte de suas propostas, evidenciando o quanto estas técnicas tem sido úteis para gestão de saúde de máquinas. A esse respeito, Wang et al. (2019) estipula um método para implementar a aquisição de dados em cenários industriais nesse novo modelo de diagnóstico de falhas baseado em dados chamado MetroNet; cujo foco é aplicado aos rolamentos de roda de trens do metrô. Esse artigo apresenta ainda um novo modelo de *deep learning* (DL), que combina efetivamente redes neurais convolucionais (CNN) com a bidirecional *Long Short Term Memory* (BiLSTM). Por meio da CNN e RNN, os dados são submetidos a fim de capturar correlação temporal e correlação espacial de dados brutos do sensor. Os autores explicam que sua abordagem funciona a partir dos dados de vibração coletados de modo que o método concatena três sequências sensoriais unidimensionais pela dimensão do eixo em um formato de matriz bidimensional. Esse método pode não apenas manter a correlação temporal dos dados sequenciais, mas também fazer pleno uso da correlação espacial. Para os autores, a CNN constitui um método inovador de convolução sobre altura e agregação sobrepeso. A validação desses modelos contou com dados reais, implantando nodes de sensores sem fio nos rolamentos de roda para coletar dados de aceleração de vibração como dados de treinamento. O módulo de detecção sem fio do nó do sensor sem fio consiste em um acelerômetro de 3 eixos, com uma taxa de amostragem de 5120 Hz para cada eixo. Segundo os estudiosos, para que a rede aprendesse com eficiência a

correlação temporal do vetor de característica de comprimento deveria ser fixa. O MetroNet adota um módulo BiLSTM para codificar as informações temporais. Comparado com o RNN tradicional, o LSTM oferece excelente desempenho na captura da dependência de dados sequenciais em longo prazo, envolvendo uma célula de memória e pode superar os problemas de desaparecimento de gradiente. Contrastado com outros modelos, o modelo proposto alcança a mais alta precisão, *recall*, *f-measure* e exatidão, cuja precisão é de até 97,20%. Além disso, o MetroNet proposto é apenas um pouco mais alto que o modelo CNN e o modelo BiLSTM em termos de tempo de treinamento e previsão de tempo.

A proposta apresentada por Zschech et al. (2019) reside no desenvolvimento de uma solução para superar a situação de falta de etiquetas no contexto de prognósticos de manutenção baseada na condição (CBM) e *machine learning* (ML). Os autores descrevem que para isso seja possível fora necessário incluir técnicas no domínio do tempo e no domínio da frequência, do tempo para extração de recursos, agrupamento hierárquico aglomerativo e agrupamento de séries temporais para detecção não supervisionada de padrões, bem como uma rede neural recorrente para o treinamento de modelos prognósticos. Eles ainda ressaltam que, para superar o problema de decisões subjetivas, é sugerida uma solução que visa a fornecer aos operadores de máquinas um modelo que reflita o curso do desgaste e, portanto, seja adequado para prever o tempo de vida remanescente (RUL) das ferramentas/máquinas. Conforme os autores, isso possibilita verificar se um limite crítico foi atingido ou se uma ferramenta ainda pode ser usada. Conforme os estudiosos, o desenvolvimento de um modelo prognóstico aproveita os ativos de dados disponíveis registrados durante as operações da máquina para extrair informações úteis por meio dos métodos de ML. A ideia era, na verdade, extrair o conhecimento implícito dos operadores que tomaram decisões corretas no passado, levando a uma vida útil mais longa da ferramenta. Para os autores, isso deveria permitir que toda a força de trabalho se beneficie do conhecimento empírico de operadores de máquinas mais experientes, usando o modelo prognóstico como uma ferramenta de comunicação e um ponto de referência para evitar preferências individuais de risco.

Apesar da abordagem proposta por Rögnvaldsson et al. (2018) não se referir diretamente à máquinas em uma planta industrial, podemos considerar esta correlação, uma vez que um veículo (objeto de estudo deste trabalho em análise) é uma máquina e apresenta comportamentos semelhantes com algumas máquinas industriais, porém com o diferencial da mobilidade. Verificamos que, tanto esta abordagem quanto a abordagem apresentada e, Wang et al. (2019), denominada MetroNet apresentam contribuições significativas que

constem na relação de trabalhos considerados relacionados. Por conseguinte, este trabalho descreve uma abordagem para o monitoramento inteligente de sistemas ciberfísicos móveis com base no consenso entre agentes auto-organizados distribuídos. A solução proposta, denominada COSMO, combina várias técnicas, permitindo aprendizado ao longo da vida sob restrições computacionais e de comunicação. De acordo com os autores, não é necessário a intervenção de especialistas para o funcionamento do sistema, o que conduz a classificar o sistema como sendo de baixa complexidade. Todavia, necessita-se de pessoas para a captura de dados, que pode comprometer a confiabilidade dos dados. Pelo que foi verificado, os autores aplicam técnicas de *data mining* para extração de conhecimentos dos dados. A validação do modelo contou com dados reais de modo a ser usado para criar uma base de conhecimento que se acumula ao longo da vida útil dos sistemas. Sendo estes coletados durante a operação regular de uma frota de ônibus da cidade europeia durante quase quatro anos. O foco dessa abordagem é o monitoramento, no qual a intenção é detectar falhas sem a necessidade de especialistas humanos, de modo a antecipá-las com antecedência. Os autores mencionam agentes ao invés de detalhar técnicas aplicadas, como supervisionadas ou não supervisionadas. Os autores explicam ainda que a abordagem consiste em três partes: encontrar modelos, detectar desvios e determinar causas. A primeira etapa é realizada, total ou parcialmente, a bordo dos sistemas e as outras duas são realizadas fora da placa. A abordagem envolve histogramas, auto-decodificadores, derivações e funções lineares. O fato de a abordagem ser focada em veículos, não desmerece as contribuições.

Do mesmo modo que veículos e trens foram incluídos nos trabalhos relacionados, aplicações focadas em aeronaves proposta por Arias et al. (Arias Chao, Manuel; Kulkarni, Chetan; Goebel, Kai; Fink, 2019) e a proposta por Li et al. envolvendo aerogerador (LI et al., 2020a) também compõe a lista de trabalhos relacionados, pelos mesmos motivos, são máquinas. O artigo Li et al., denominado *A novel scalable method for machine degradation* (LI et al., 2020b), sugere uma nova Rede Neural Profunda para Pequenos Mundo (DSWNN), com base em aprendizado não supervisionado para detectar as falhas iniciais de turbinas eólicas, aplicando o modelo desenvolvido em aerogerador para efeito de validação. Quanto aos dados, convém ressaltarmos que foram obtidos de sensores, ou seja, são dados reais; sendo estes dados coletados pelo período de um ano, de um sistema denominado SCADA, que contava com trinta turbinas eólicas de 2 MW em um parque eólico. Esse trabalho contou com abordagem supervisionada, na qual os pesos registrados e usados como valores anteriores para o treinamento supervisionado subsequente (ajuste fino). Também contou com abordagem não supervisionada aplicando rede neural profunda (DNN). A proposta

contempla tanto o monitoramento quanto a predição. O método conta ainda com limiar adaptativo proposto, baseado na teoria dos valores extremos, pode ser usado no monitoramento em tempo real de turbinas eólicas para reduzir o impacto das flutuações da velocidade e interferência externa na detecção de anomalias da turbina eólica. Além disso, os autores destacam que a estratégia combinada com o modelo DSWNN e o limiar adaptativo demonstram ser capaz de prever falhas do sistema de *pitch* com 3 horas de antecedência, que podem ser usadas para a detecção subsequente de anomalias e o diagnóstico de falhas de turbinas eólicas. Para finalizar os autores concluem que dois casos de falha na detecção de anomalias de turbinas eólicas são apresentados para demonstrar sua validade e precisão da metodologia proposta, contrastada com a rede de crenças profundas e a rede neural profunda.

Como já citado a abordagem de Arias et al. envolvendo aviões (Arias Chao, Manuel; Kulkarni, Chetan; Goebel, Kai; Fink, 2019), também pode contribuir no que diz respeito a monitoramento de saúde de máquinas. Esse artigo recomenda uma abordagem híbrida que combina modelos de desempenho físico com algoritmos de aprendizado profundo. Os autores explicam que a técnica combina *deep learning* (DL), ou aprendizagem profunda, com o processo de estimativa dos parâmetros de correção ideais é um problema de calibração estocástica. Nas experiências realizadas, os autores avaliaram o desempenho da metodologia híbrida proposta em combinação com dois algoritmos diferentes de aprendizado profundo: redes neurais de alimentação profunda e auto-encodificadores variacionais, os quais demonstram uma melhora significativa quando aplicados no quadro de detecção e diagnóstico de falhas híbridos. De acordo com os autores, o método sugerido é capaz de superar soluções puras orientadas a dados, principalmente, para sistemas com alta variabilidade. Durante a análise deste trabalho, notamos que a validação da abordagem usou dados sintéticos. Conforme os autores, para validar a eficácia do método foi gerado um conjunto de dados de monitoramento de condições de uma turbina a gás avançada durante condições de voo em condições saudáveis quatro com problemas operacionais, com base no modelo dinâmico da Simulação do Sistema de Aero-Propulsão (C-MAPSS), tendo o motores de aeronaves com alvo do monitoramento. De fato o foco desse trabalho estava no monitoramento, pois para os autores, o problema desafiador da detecção e diagnóstico de falhas em condições operacionais variáveis sinais altamente correlacionados, justificava a intenção desta abordagem. Todavia, o modelo requer acesso a um conjunto de dados de sinais de monitoramento de condições e estimativas de modelo de sistema de variáveis de processo.

Outra abordagem envolvendo aerogerador é apresentada por Santos et al. (2018), cujo objetivo é identificar a técnica de classificação mais adequada que dependerá menos do nível de desequilíbrio no conjunto de dados. Os autores explicam que aplicam abordagem supervisionada com finalidade de identificação de falhas nas caixas de engrenagens de turbinas eólicas de aerogeradores por ser este tipo de aplicação de grande interesse industrial. No entanto, de acordo com o artigo, na prática, não é possível obter conjuntos de dados balanceados sob condições reais de operação. Apesar de envolver estudos envolvendo diferentes técnicas de monitoramento e previsão, o artigo não chega a propor uma abordagem ficando apenas em abordagens já apresentadas, destacando as considerações dos autores quanto às técnicas já desenvolvidas.

O artigo intitulado *Lightweight Deep Residual CNN* de Shangjun et al. (2019) propõe um método de aprendizado profundo leve, eficiente e sem ruído, de ponta a ponta. Para isso, foi necessário uma estrutura de rede convolutiva residual profunda e unidimensional leve, que pode efetivamente melhorar a precisão do reconhecimento e garantir uma velocidade rápida de cálculo e um pequeno espaço de parâmetros. Conforme os autores, a estrutura de rede proposta possui uma forte capacidade de aprendizado de migração e desempenho de resistência ao ruído. Eles classificam essa abordagem como não supervisionada, sendo que o LDR-CNN (*lightweight deep residual / resíduo profundo leve*) não possui parâmetros a serem treinados na camada de rede de pacotes *wavelet*, e o cálculo do ponto flutuante pode ser negligenciado, de modo que apenas os dados da outra camada possam ser calculados. Conforme os autores o método sintetiza as características de uma transformação no domínio da frequência e de uma profunda rede neural convencional. As máquinas rotativas foram o alvo desse trabalho, visando a monitorar especificamente o rolamento. Os autores partem da premissa de que uma transformação de pacote *wavelet* pode efetivamente extrair informações no domínio da frequência e a quantidade de cálculo de uma convolução unidimensional é pequena, sendo proposto, então, um método leve de previsão de falhas de aprendizado profundo baseado em uma rede convolucional residual profunda.

A abordagem proposta por Al-Dulaimi et al. (2020) visa a recomendar uma nova arquitetura de aprendizado profundo ruidoso, que consiste em vários modelos projetados em paralelo, conhecidos como arquitetura profunda ruidosa e híbrida para a estimativa da vida útil restante (NBLSTM). O NBLSTM é projetado pela integração de duas arquiteturas paralelas com ruído profundo, ou seja, uma rede neural convolucional barulhenta (CNN) para extrair recursos espaciais e uma memória de longo prazo bidirecional ruidosa (BLSTM) para extrair informações temporais, aprendendo as dependências dos dados de entrada nas

direções para frente e para trás. Isso envolve aprendizado não supervisionado de uma rede neural convolucional ruidosa (CNN) tendo motores turbofan aplicado para aero-propulsão como objeto de estudo. Conforme os autores, o LSTM (memória de longo prazo) realiza cada sequência de medições (janela de tempo) com comprimento fixo e depois modela a sequência inteira com base no valor RUL desejado. A abordagem prevê uma etapa para treinamento, para posteriormente realizar a classificação dos sinais. Para a validação, verificamos o uso de dados sintéticos, a qual é avaliado usando o conjunto de dados de simulação de sistema de aero-propulsão modular comercial da NASA (C-MAPSS). De acordo com os autores, os métodos desenvolvidos com base em redes neurais profundas mostraram desempenho superior para lidar com questões prognósticas complexas associadas a sistemas com processos de degradação complexos e desconhecidos.

Uma nova estrutura denominada rede neural convolucional recorrente (RCNN) é proposta por Wang et al. (2020) para a previsão de vida útil remanescente de máquinas (RUL). O RCNN usa dados de séries temporais adquiridos por diferentes sensores como entrada. Conforme os autores, a arquitetura RCNN é formado por uma pilha de camadas convolucionais recorrentes (denominada RCL), agrupando camadas (denotadas como PL) e totalmente conectadas (denotadas como FCL). Trata-se, na verdade, de RNN + CNN, pois adota abordagem orientada a dados aplicada para monitoramento e predição de falhas em rolamento de fresas. Nas CNNs, as camadas convolucionais são os blocos de construção principais e são capazes de extrair automaticamente recursos discriminativos dos dados do sensor de séries temporais de entrada. Em termos de dados para validação, observamos o uso de sinais de vibração, nos quais foram coletados de testes de degradação acelerados de rolamentos de elementos rolantes para validar a eficácia da RCNN proposta. Na concepção dos autores, os conjuntos de dados do mancal FEMTO-ST são adquiridos por meio da realização de testes de degradação acelerada de mancais de rolamento na plataforma experimental PRONOSTIA. Também notamos o uso de dados sintéticos. Os dados de vibração usados, neste artigo, são os conjuntos de dados públicos do FEMTO-ST, fornecidos pelo Instituto de Ciências Térmicas da Mecânica da Franche-Comt Eletrônica e Instituto de Ciência e Tecnologia Ótica, dados estes disponíveis no site da NASA prognósticos. Os dados reais, sendo esses total de dezessete rolamentos são testados em três condições operacionais diferentes. Com o intuito de monitorar a progressão de falha dos rolamentos e obter seus dados de falha até a falha, dois acelerômetros são posicionados na parte externa dos rolamentos testados, cuja frequência de amostragem foi de 25,6 kHz e 2560 pontos de dados são registrados a cada 10 s. Nesse artigo igualmente foi empregado inferência variacional

para quantificar a incerteza de RCNN em prognósticos. Para os autores, o RCNN proposto pode ser visto como um modelo probabilístico com variáveis aleatórias ω após a distribuição prévia é gaussiana.

Outra abordagem envolvendo redes neurais é apresentada por Vishnu et al. (2018), cujo objetivo é construir um modelo a partir de dados de sensores de séries temporais coletados de várias ferramentas de gravação de moinhos de íons operando sob várias condições e configurações. Esse modelo tem a capacidade de examinar o comportamento de falha de uma ferramenta de gravação de moinhos de íons usada no processo de fabricação de wafer. Trata-se, na realidade, de uma Rede Neural Recorrente Profunda (RNN) aplicada para aprender a função de regressão métrica a partir de séries temporais multivariadas. A validação contou com dados reais. Conforme os autores explicam, a previsão do tempo dessas falhas pode ajudar na manutenção baseada em condições e agendar paradas das usinas de íons para operações de manutenção. Até aqui estamos em plena concordância. O ponto crítico dessa abordagem, que analisamos, consiste no desafio em diagnosticar falhas (ou seja, detectar e identificar) determinando o tempo restante, pois não verificamos claramente se fato uma abordagem semi-supervisionada é a melhor forma para mitigar falhas, tendo em vista a questão da falta deve ser apreendida com o tempo. No entanto, se a falha começar e o tempo de aprendizado não contemplar a evolução dessa falha, ou seja, o índice de saúde não evidenciar os sintomas de falha, o dano na máquina será eminente antes mesmos que o modelo apreenda. Desse modo, como o modelo RNN poderia ser usado para estimar o RUL somente após a alteração, comprometendo a confiabilidade do índice de saúde, uma vez que se demonstra ineficaz.

O artigo de Yu, Kim e Mechefske (2019), por sua vez, sugere um esquema orientado a dados baseado em sensor usando uma ferramenta de aprendizado profundo e a técnica de correspondência de curvas baseada em similaridade para estimar o RUL de um sistema. Tal abordagem abarca rede neural recorrente bidirecional. De acordo com os autores, trata-se de uma arquitetura de aprendizado profundo que tem a capacidade de aprender automaticamente as hierarquias espaciais dos recursos, tendo Aeronave e fresadora como máquinas para a validação, na qual o motor de uma aeronave e de uma fresadora são o objeto de estudo e experiência com o monitoramento e a predição de saúde. O esquema proposto foi testado em dois conjuntos de dados de execução de falha publicamente disponíveis: os conjuntos de dados do motor Turbofan (conjuntos de dados de simulação) e os conjuntos de dados de fresagem (conjuntos de dados experimentais). Conforme os autores, o procedimento consiste em duas etapas: na primeira, um auto-codificador bidirecional

recorrente baseado em rede neural é treinado de maneira não supervisionada para converter as leituras multissensoriais (alta dimensão) coletadas de instâncias históricas de falha até a execução (por exemplo, múltiplas unidades do mesmo sistema) para incorporações de baixa dimensão, que são usadas para construir os valores do índice de saúde unidimensional (HI) para refletir vários padrões de degradação da saúde das instâncias. Na segunda etapa, a curva HI de teste, obtida das leituras dos sensores coletadas de uma instância on-line, é comparada com os padrões de degradação construídos na fase off-line, usando a técnica de correspondência de curvas baseada em similaridade a partir da qual o RUL da unidade de teste pode ser estimado em um estágio inicial.

Por outro lado, a abordagem proposta por Avanzato et al. (2020) envolve aprendizado supervisionado e não supervisionado tendo como máquinas alvo, equipamento de tecnologia da informação e comunicação (TIC). Ela possui como objetivo uma nova abordagem baseada em uma inovadora plataforma de monitoramento industrial, denominada SMILE (*Smart Monitoring IoT Learning Ecosystem*). Para isso, aplica técnicas prescritivas automáticas combinadas com técnicas supervisionadas e não supervisionadas. Dentre estas, técnicas de aprendizado profundo e de máquina, inteligência artificial e sensores IoT inovadores, equipados com algoritmos avançados de comunicação. Além disso, o SMILE visa a automatizar a extração de informações, reduzindo os custos de implementação desse processo. Segundo os autores, as técnicas que dependem do uso de abordagens supervisionadas de aprendizado de máquina resolvem proativamente casos de falha e mau funcionamento, mas requerem tempo e habilidades de aplicação consideráveis, resultando em aumento de custos.

3.3 Análise e Oportunidades dos Trabalhos

Nesta seção, serão apresentados os pontos analisados de cada um dos artigos encontrados visando a utilizar os resultados para comparar com nossa abordagem a fim de evidenciar as contribuições geradas através de nossa solução. Cada característica apontada anteriormente será detalhada na presente seção. De modo resumido as principais lacunas observadas são:

1. Abordagem exclusivamente não supervisionada;
2. Dependências de intervenção de especialistas;

3. Carência de clareza quanto às fontes dos dados para avaliação da abordagem;
4. Abordagens restritas a tipo específico de máquina;
5. Abordagens restritas a partes específicas de máquina.

Ao aprofundar as análises, percebemos lacunas no que tange ao foco da pesquisa. Em particular, conforme já citado, as abordagens supervisionadas (AMIHAI et al., 2018; AREMU et al., 2019; ZSCHECH et al., 2019; SANTOS; MAUDES; BUSTILLO, 2018; VISHNU et al., 2018; ARIAS CHAO, MANUEL; KULKARNI, CHETAN; GOEBEL, KAI; FINK, 2019) visto como ponto crítico nos casos que realiza treinamentos *off-line*, implicando em períodos de tempos maiores para implantação, assim como a dependência dos modelos treinados. Outras abordagens necessitam de conhecimento empírico do especialista ou operador para criar, seleccione os recursos certos e, em seguida, elaborar um modelo de aprendizado de máquina adequado. Tal processo pode demorar, além de estar sujeito a falhas (AREMU et al., 2019; ZSCHECH et al., 2019). Os trabalhos anteriores também se concentraram em máquinas ou peças específicas deles (LI et al., 2020a; CAMPOS et al., 2019; MA et al., 2019; WANG et al., 2020). Em contrapartida, outros trabalhos consideraram apenas dados sintéticos para avaliação da abordagem (LI et al., 2020a; AL-DULAIMI et al., 2020). Ainda em termos de dados, identificamos que o artigo de Yu, Kim e Mechefske (2019) contou com bases de terceiro, abrindo questionamento quanto à confiabilidade desses dados no que compete à similaridade com a aplicação proposta. Por fim, ponderamos que o artigo de Avanzato et al. (2020), apesar de selecionado conforme os critérios, por fazer parte de máquinas industriais, porém sendo estes equipamentos de tecnologia da informação, diferente do foco de nossa pesquisa, que foca em máquinas vibrantes e rotativas.

Aliás, cabe enfatizarmos que ao realizar o processo de análise dos trabalhos, identificamos que grande parte destes se classifica como não supervisionada, mas que, na realidade, tratam-se de abordagens semi-supervisionadas, ou seja, em algum momento precisará de alguma intervenção para compor o modelo. Ressaltamos que grande parte dos trabalhos adotam abordagens híbridas a fim de apoiar suas soluções em diferentes técnicas com intuito de resolver os problemas de modo colaborativo, no qual cada técnica deve dar conta de parte da solução. Para muitos autores, estes têm sido os caminhos que tem

demonstrado melhores resultados. Dentre os vários aspectos analisados, o que mais chamou a atenção é a carência de abordagens que se propõe a monitorar a saúde de máquinas, que tenha sido validado de maneira consistente através de dados reais, algo que nossa abordagem HealthMon tem atendido com muita propriedade.

3.4 Considerações Parciais

Analisando as lacunas identificadas nos trabalhos relacionados, constatamos o esforço dos pesquisadores em suprir as demandas latentes, dada a importância dos temas relacionados com a emergente Indústria 4.0. Foi possível observarmos ainda que as abordagens giram em torno de soluções para medir a saúde das máquinas. Dessa forma, este trabalho está totalmente alinhado com o estado da arte. Aliás, identificamos lacunas para abordagem totalmente não supervisionadas, carência de soluções aplicáveis para ampla gama de máquinas vibrantes e rotativas, validações de abordagens incluindo dados sintéticos e dados reais, assim como carência de abordagens que aplicasse decomposição de sinais para a criação de um índice único que representasse o estado de saúde da máquina. Para a realização desta pesquisa aplicamos uma revisão bibliográfica sistemática com o intuito de buscar em bases literárias, artigos específicos que apresentassem abordagens semelhantes ao HealthMon. Para a execução de tal, fizemos uso do *string* de busca, almejando encontrar trabalhos relacionados. Com a finalidade de filtrar somente trabalhos de cunho relevante, utilizamos critérios de inclusão e critérios de exclusão.

4 O HEALTHMON

Este capítulo busca descrever o HealthMon, considerado uma nova abordagem para monitorar a integridade das máquinas na Indústria 4.0. Para facilitar a apresentação e compreensão do sistema, este capítulo encontra-se dividido da seguinte forma: em particular, apresentamos sua arquitetura, detalhando seus componentes e a relação entre eles, bem como os algoritmos propostos. Na Figura 24, destacamos que esse tipo de aplicação se mostrou particularmente relevante no contexto da Indústria 4.0, na qual novas tecnologias são empregadas de forma a maximizar a eficiência das fábricas inteligentes. Apresentamos, também, uma descrição de alto nível sobre como o HealthMon funciona. Para dar início a isso, assumimos que os sensores estão estrategicamente posicionados na máquina para medir variáveis relevantes na identificação da deterioração da máquina (consulte a Subseção 4.1), como vibração, consumo de energia etc. A saída de cada sensor pode ser vista como uma série temporal. O HealthMon recebe uma (série de) séries temporais e gera um único valor IGS/GHI, que representa o índice de integridade da máquina em relação ao período compreendido pela série temporal. Esse processo pode ser repetido sempre que necessário (por exemplo, a cada 10 minutos), permitindo, assim, que o IGS seja analisado ao longo do tempo. A Figura 1 apresenta o pipeline básico do HealthMon.

4.1 Arquitetura HealthMon

Nesta Seção apresentamos a arquitetura do HealthMon. Considerando que a dinâmica da abordagem consiste em receber sinais em forma de séries temporais como entrada, realizar processamento destes sinais, gerar um índice global de saúde de máquina, como saída, o IGS. Para calcular o IGS, o HealthMon realiza processamentos em seis fases, conforme mostrado na Figura 23. Para facilitar a compreensão de como o HealthMon funciona, além das fases, adicionamos o número de cada fluxo junto a figura que ilustra a arquitetura. Esses números correspondem à ordem em que as atividades são realizadas. A Fase 1 corresponde à preparação e parametrização da máquina (subseção 4.1.1).

Na Fase 2, o HealthMon aplica um processo chamado “trenderização”, que visa a realizar o rastreamento espectral das componentes das séries temporais, identificando o surgimento de novas componentes. Posteriormente, aplicando o processamento que decompõe as componentes espectrais com o intuito de detectar as tendências. Nesse sentido,

evidenciando o que podem ser tendência de deterioração ou simplesmente tendências de operação. Para diferenciar os tipos de tendências, temos como premissa o fato de que o processo de degradação/deterioração é monotônico. Já as tendências de operação podem não ser monotônicas (subseção 4.1.2). O conjunto resultante pode ser consideravelmente grande. Por conseguinte, a Fase 3 aplica técnicas de redução de dimensionalidade para obter um conjunto de tendências de baixa dimensão (Subseção 4.1.3). Na Fase 4, as séries temporais resultantes são agrupadas para que possamos analisar como essas tendências evoluem ao longo do tempo, que chamamos de meta tendências (Subseção 4.1.4). Com base nessas séries temporais, na Fase 5, o HealthMon calcula e gera o valor final de IGS (Subseção 4.1.5). Conforme mencionado anteriormente, todo esse processo é repetido sempre que necessário. Finalmente, observamos que nem todas as tendências obtidas na Fase 2 são relevantes na avaliação da saúde das máquinas. Diante disso, a Fase 6 inclui uma etapa de otimização para identificar as tendências mais representativas para o cálculo do IGS (subseção 4.1.6). Nas próximas seções, descrevemos a metodologia completa HealthMon, apresentando suas principais decisões de projeto (Seção 4.1) e detalhando suas fases (seções 4.1.1 até 4.1.6).

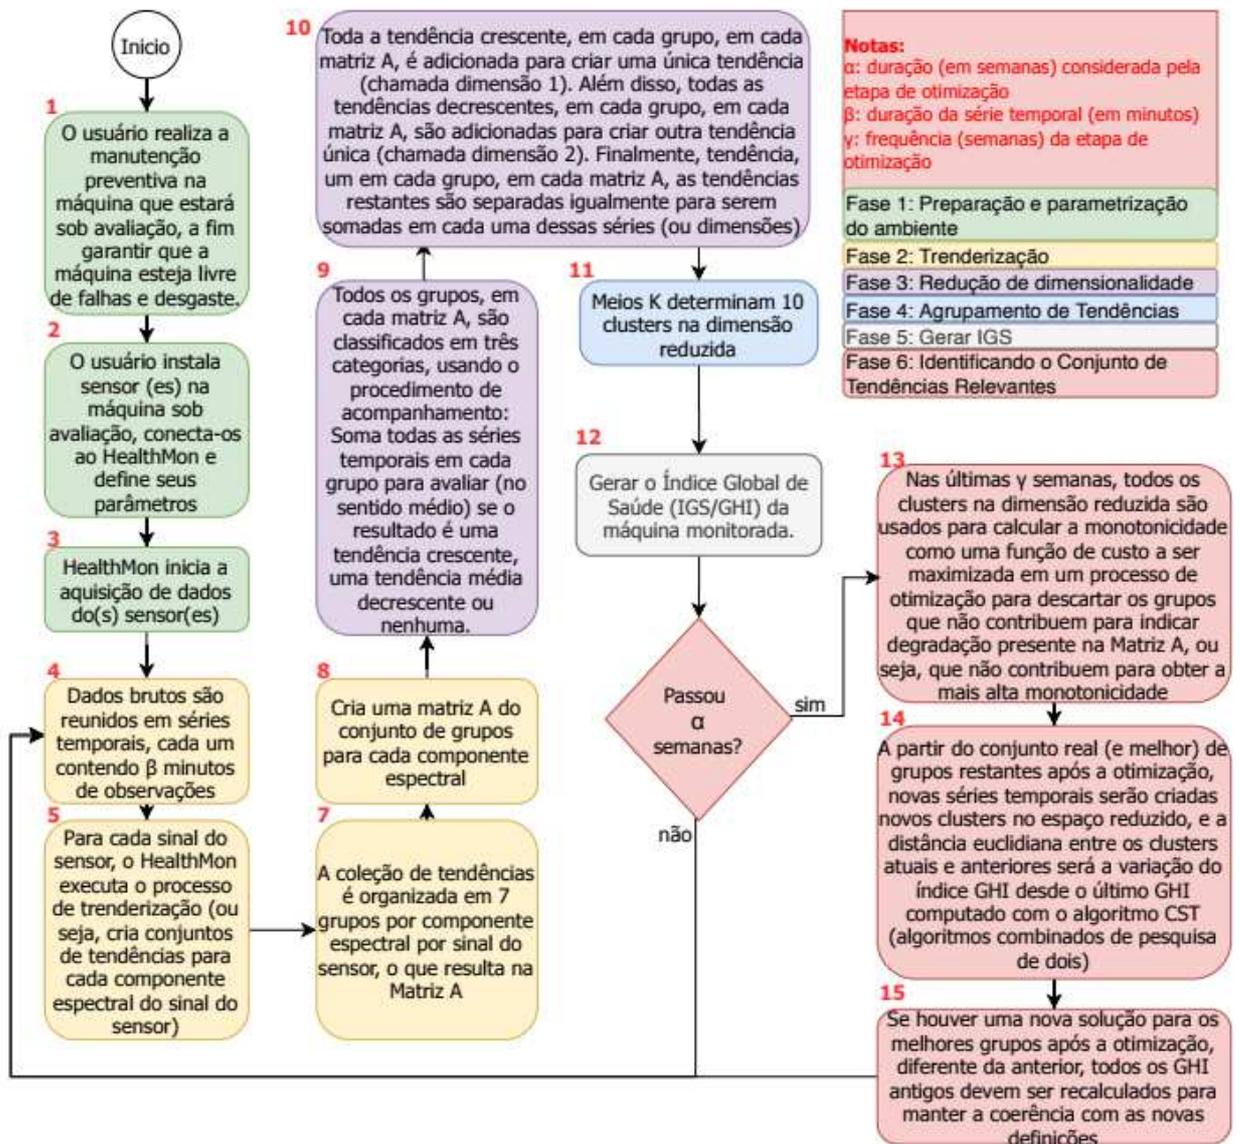
Desenvolvemos o HealthMon tendo como base as seguintes decisões de projeto:

- A abordagem se concentra em máquinas baseadas em vibração e/ou rotativas presentes na planta industrial, como motores de indução (IM).
- Precisamos da intervenção do usuário em apenas três momentos (veja Figura 24):
 - Conexão de sensores na máquina de destino;
 - Definição dos parâmetros de configuração a serem utilizados na fase de processamento do sinal e no nível da aplicação;
 - Verificação da saída do sistema, que corresponde ao índice global sobre a integridade da máquina.
- A abordagem deve ser compatível com diferentes tipos de sensores. No entanto, para alcançar os resultados esperados, as variáveis medidas devem manter uma relação física com a evolução da deterioração da máquina, como vibração, temperatura, corrente elétrica, pressão e nível de ruído.

- A abordagem usa técnicas de aprendizado de máquina não supervisionadas para obter um subconjunto reduzido e ideal de tendências após o processamento do sinal digital. Esse subconjunto pode ser usado para analisar a evolução da falha em uma máquina de destino.
- A abordagem gera um índice de integridade global, cuja evolução ao longo do tempo é exibida em um gráfico.
- A abordagem deve ser capaz de identificar os sinais que não agregam valor à detecção de evolução de falhas e ignorá-los a fim de otimizar o funcionamento do sistema.

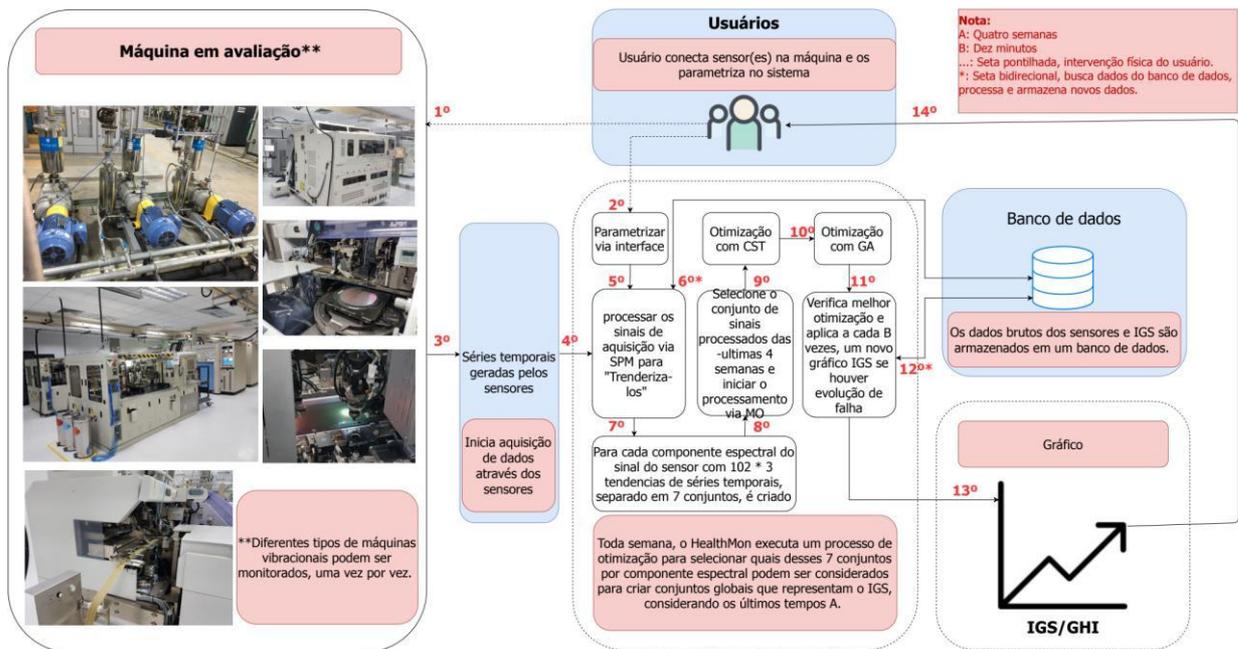
4.1.1 Fase 1: Preparação e parametrização do ambiente

A Fase 1 inicia no departamento de manutenção da fábrica, representado pelo usuário, para executar o serviço de manutenção preventiva em uma máquina, deixando-a em pleno funcionamento. Isso é necessário para garantir que a máquina esteja livre de falhas e desgaste. Após a manutenção, o usuário deve conectar o(s) sensor(es) às máquinas que serão monitoradas/avaliados. Essa fase termina com o HealthMon devidamente parametrizado pelo usuário, indicando que ele pode iniciar a aquisição de dados do(s) sensor(es). A parametrização consiste basicamente no usuário definir as propriedades para a operação correta do sistema. Essas propriedades se referem a períodos operacionais para análise e atualização de IGS. As configurações do sensor também estão entre os parâmetros. Por mais que o sistema que gera o IGS e o tipo de sensor (temperatura, vibração, etc.) não seja relevante, é importante que o sistema saiba qual é o sensor, pois um tipo de sensor pode ter um índice mais preciso, e isso tem relação direta com o sensor que está sendo obtendo os sinais da máquina, ou seja, reflete diretamente no monitoramento das falhas da máquina, em observação.



Fonte: Elaborado pelo autor.

Figura 24 – HealthMon Arquitetura de Alto Nível



Fonte: Elaborado pelo autor

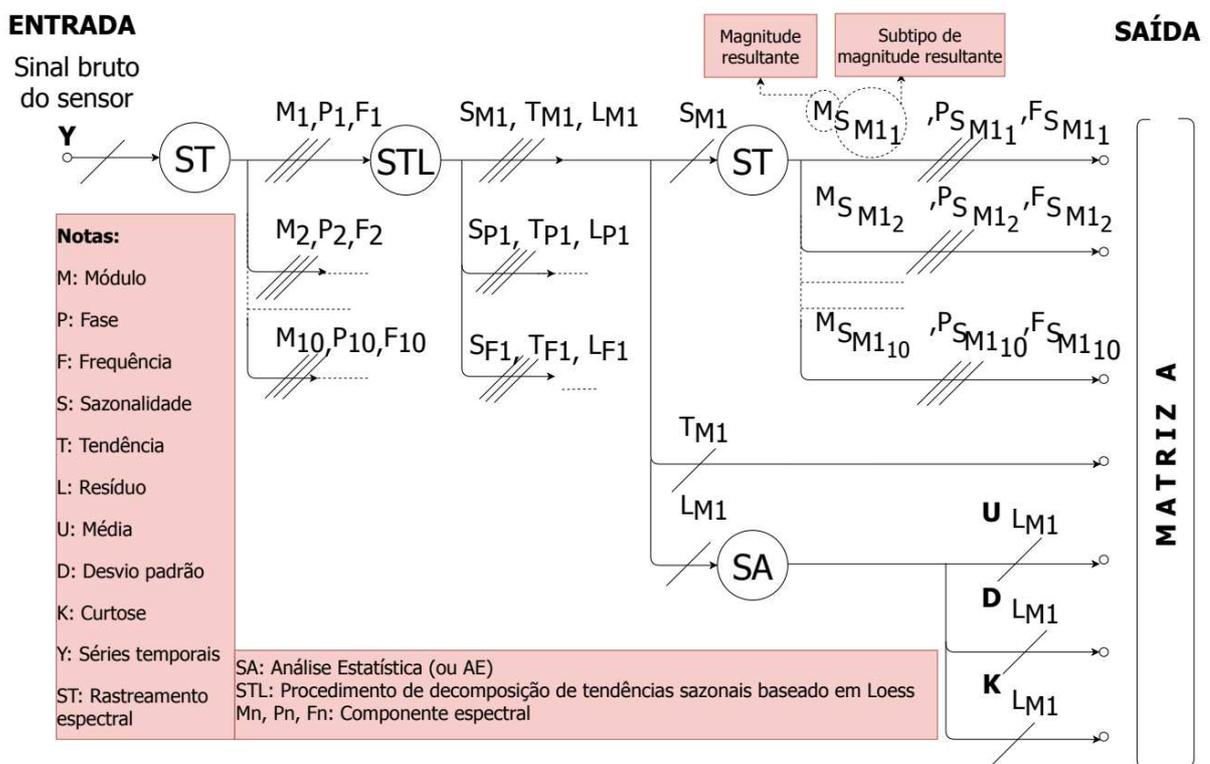
4.1.2 Fase 2: Trenderização - Processo de decomposição de sinal e identificação de tendências

Na Fase 2, com as configurações definidas corretamente, o HealthMon começa a adquirir dados do(s) sensor(es). Nessa etapa, deve-se observar que os dados brutos (séries temporais avaliados com dados reais de vibração) gerados pelo(s) sensor(es) conectado(s) à(s) máquina(s) são coletados pelo HealthMon em séries temporais por um período específico de tempo. Para cada sinal do sensor, o HealthMon executa o processo de tendências. Como os dados recebidos dos sensores resultaram em uma única série temporal, será necessário decompor essa série em novos sinais. Chamamos esse processo de Trenderização. Deste processamento resultará na criação de uma matriz de conjuntos, um para cada componente espectral, que chamamos de Matriz A, a qual é apresentada detalhadamente na Figura 26. Para gerar esse índice, aplicamos uma coleção de análises de séries temporais para identificar tendências monotônicas. Primeiramente, executamos um módulo de processamento de sinal (SPM), que recebe dados brutos na forma de séries temporais de um único sensor e os transforma em uma coleção de tendências processadas. Cada sinal do sensor pode ser decomposto em vários componentes espectrais, portanto, para cada componente espectral, criamos também várias tendências de séries temporais, que são

separadas em grupos. Para executar o processamento do sinal, o HealthMon aplica o procedimento sazonal de decomposição de tendências (STL) baseado em LOESS.

Esse procedimento é responsável pela decomposição dos sinais do sensor em seus componentes de tendência, sazonal e de ruído. O STL usa a configuração automática combinando dois resultados como saída: (i) um para a tendência; (ii) outro para a sazonalidade. O resíduo é obtido pelo cálculo da diferença no início e no final do processo (R. B. Cleveland, W. S. Cleveland, J.E. McRae; TERPENNING, 1990).

Figura 25 – Módulo de Processamento de Sinais (SPM). Processamento



Fonte: Elaborado pelo autor

Se algum comportamento atípico não for repentino, poderá estar associado ao desgaste cumulativo ou falha em andamento (ou seja, degradação, falha não consumada). A fim de que o HealthMon acompanhar a evolução do estado do conjunto, é necessário criar um índice para representar todo o comportamento da moda do conjunto. Um conjunto típico de série temporal é composto de comportamentos comuns (repetitivos e usuais) e atípicos (repentinos ou não). Ao remover todo o comportamento atípico comum e repentino do conjunto de séries temporais processadas, o HealthMon pode se concentrar apenas no comportamento atípico não repentino, que está relacionado à degradação da máquina em

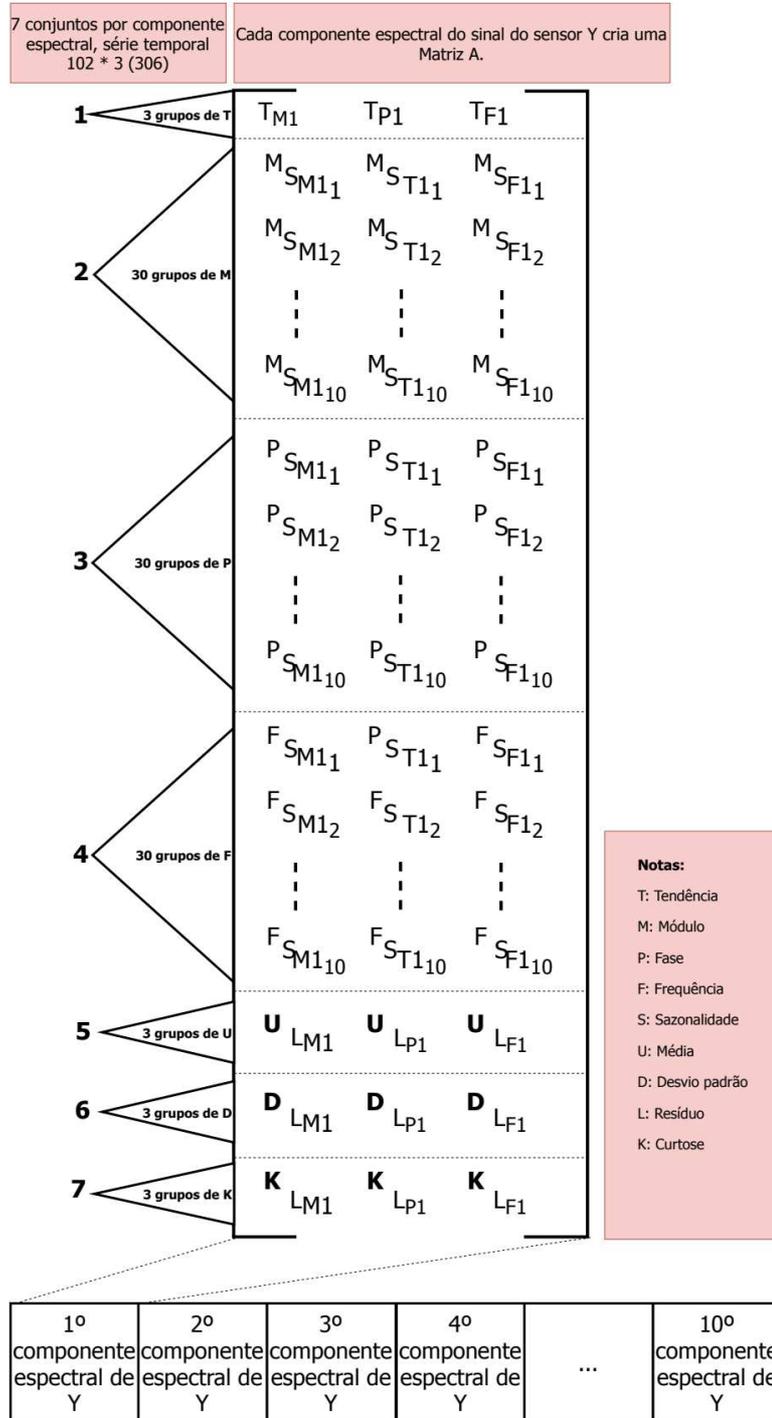
avaliação. Se a manutenção preventiva for realizada corretamente e se a instalação da máquina estiver dentro dos padrões estabelecidos pela empresa, eventos repentinos de falha serão minimizados (ZYABKINA et al., 2017), ou seja, as falhas abruptas que geralmente resultam em quebra da máquina.

Nessa linha, o SPM é usado para decompor os sinais dos sensores em várias tendências (processo de trenderização). A Figura 25 ilustra que a primeira operação de trenderização é denotada como *Spectral Tracking* (ST) (PINHO; WOJICHOWSKI; CROVATO, 2016), ou Rastreamento Espectral. Após concluir, escolhemos um número máximo de 10 componentes espectrais de tal maneira que cada um tenha módulos (M), fases (P), e frequências instantâneas (F). Dez componentes espectrais para ST são um bom compromisso entre esforço computacional e resolução e podem ser expandidos sem perda de generalidade. Combinamos esses dados em uma notação genérica representada por M_n , P_n , e F_n , onde n varia de 1 a 10. Os sinais M_n , P_n , e F_n são decompostos usando o algoritmo STL (CLEVELAND; MCRAE; TERPENNING, 1990), gerando três tipos de sinais: sazonal (SM_n , SP_n , SF_n), tendência (TM_n , TP_n , TF_n) e o resíduo (LM_n , LP_n , LF_n). Destacamos que esse tipo de aplicação se mostrou particularmente relevante no contexto da Indústria 4.0, na qual novas tecnologias são empregadas de forma a maximizar a eficiência das fábricas inteligentes. Em tal cenário, os módulos M_n devem ser normalizados em relação ao primeiro módulo componente denominado M_1 . O sinal TM_n , que corresponde à tendência após a decomposição do STL, permanece inalterado. Em outras palavras, nesse momento, ele está pronto para ser salvo no banco de dados como mostrado na Figura 24. Além disso, o sinal sazonal SM_n é rastreado novamente aplicando a mesma técnica ST, gerando sinais MSM_{nm} , PSM_{nm} , e FSM_{nm} , na qual m varia de 1 a 10. Finalmente, no sinal de resíduo LM_n , aplicamos algumas análises estatísticas (SA) (ver em Figura 25), como média aritmética (ULM_n), desvio padrão (DLM_n) e curtose (KLM_n), usando uma janela deslizante. Essa janela tem um tamanho que é o inverso da frequência fundamental do sinal sazonal SM_1 , reduzindo, dessa forma, a oscilação em todas as saídas SA.

De acordo com a Figura 25, o processamento de cada componente espectral resultará em uma matriz chamada “Matriz A”, como mostra a Figura 26. A denominada “Matriz A” é composta por 102 séries temporais multiplicadas por 3 colunas (módulo, fase e frequência), conforme se verifica na Figura 26. Cada série temporal resulta, portanto, em 306 componentes espectrais derivados da decomposição da série temporal Y (que é o sinal de um sensor na máquina em avaliação). Estes componentes são classificados em 7 conjuntos (T, M, P, F, S, U, D, L e K), sendo que cada um deles contempla diferentes tipos de tendências.

Os números 102 _ 3, como dito, são as tendências por componentes espectrais, que se classificam em: 90 séries temporais do componente ST do Sazonal, 3 séries temporais do componente “Trend” (conjunto de séries temporais após o processamento de trenderização) e 9 séries temporais de SA, para todo o SA gerado são decompostos ainda em módulo, fase e frequência. Essas quantidades de sinais para Matriz A estão relacionados à escolha inicial de 10 componentes espectrais para ST, quantidade esta suficiente para equilibrar esforço computacional com sinais decompostos que evidenciam o surgimento da falha. Como pode ser visto, a Figura 26 é composta de duas partes: uma matriz, que apresenta os sinais processados de acordo com seus respectivos grupos, e um vetor. Esse vetor corresponde aos 10 componentes espectrais ilustrados na Figura 25, representados de M1, P1, e F1, to M10, P10, e F10, respectivamente. Vale ressaltar que a quantidade de 10 componentes espectrais foi estabelecida com base nas experiências realizadas durante os ensaios, onde se verificou o melhor equilíbrio entre a quantidade de sinais decompostos com relação ao esforço computacional.

Figura 26 – Matriz A resultante do SPM - Dados Sintéticos e Reais



Fonte: Elaborado pelo autor.

4.1.3 Fase 3: Redução de dimensionalidade - Reduzindo de um espaço multidimensional para um espaço bidimensional.

Na Fase 3, os grupos de cada Matriz A são classificados em três categorias: tendência de alta, tendência de baixa e constantes. Para a execução desse processo, é necessário seguir alguns procedimentos. Primeiramente, realizamos a soma de todas as séries temporais em cada grupo para avaliar (obtendo o valor médio). A partir disso, classificamos as três categorias verificando se o resultado é uma tendência ascendente, tendência descendente média ou constante. O objetivo dessa fase é reduzir de uma matriz multidimensional para uma matriz bidimensional. Assim, obtivemos a Matriz A' (Matriz A 'linha', denotado por uma aspa simples junto a letra A), classificando em tendência crescente e tendência decrescente. As constantes, ou seja, aquelas categorias que não são crescentes nem decrescentes, são igualmente distribuídas entre as categorias de tendência ascendente e descendente. Essa classificação deve ser realizada para cada grupo, em cada Matriz A, resultando na matriz bidimensional (Matriz A'), que por sua vez nos permitirá uma melhor visualização das análises ao realizar o processo de agrupamento.

Figura 27 – Processo para criação da Matriz A', que é resultante do processamento da Matriz A (Fase 2, pode ser verificado na Figura 3).

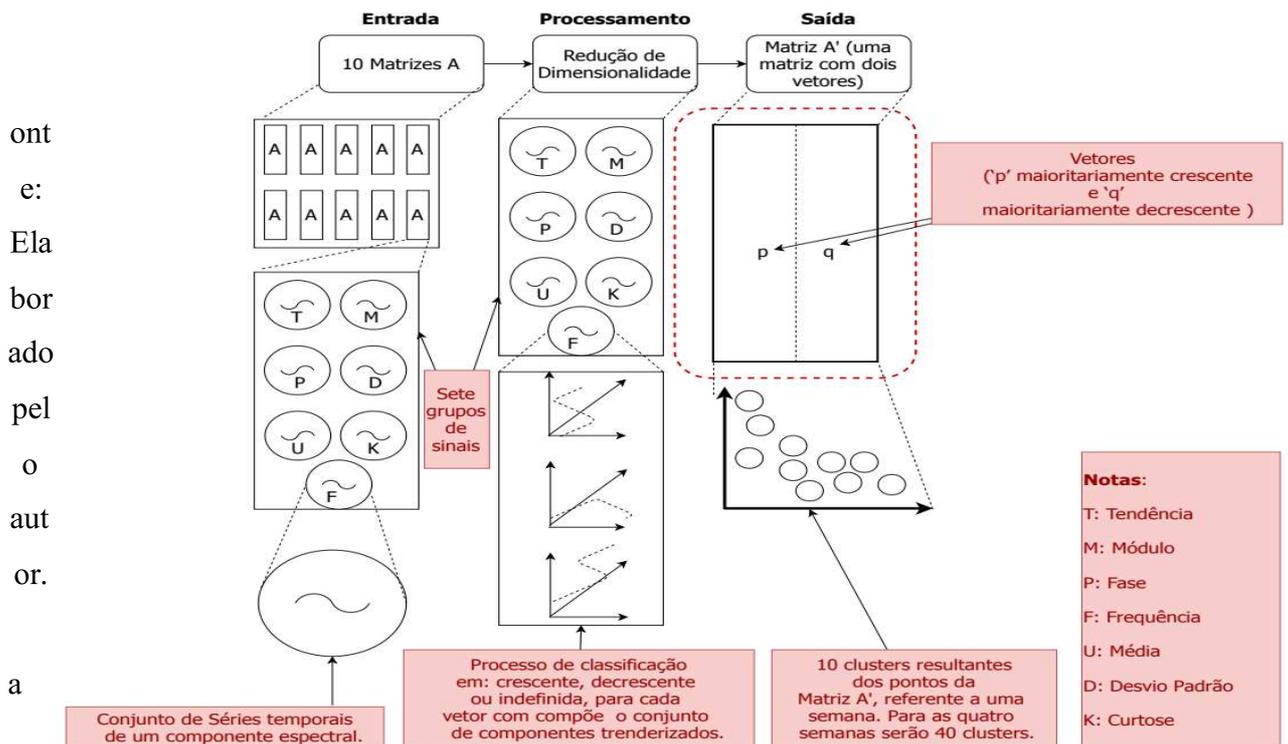


Figura 27, descrevemos o processo de redução de dimensionalidade que culmina na Matriz A'. É interessante frisar que, na Figura 26, é possível observar as entradas para processamento são “Matrizes As” resultantes do módulo SPM. Cabe ressaltarmos que cada Matriz A é composta por 7 conjuntos de sinais espectrais, sendo cada conjunto de sinais composto por séries temporais resultantes do processo de decomposição de sinais. Portanto, de forma sintetizada, o processo de redução de dimensionalidade consiste em analisar cada uma das séries temporais, classificando-as nos três tipos: (i) crescimento, (ii) diminuições e (iii) nenhuma. Essa classificação possui uma técnica de reamostragem, que consiste em reamostrar a fim de que todas as tendências possuam o mesmo tamanho por meio de uma normalização da frequência de amostragem. Para que todas as tendências tenham o mesmo tamanho, aplicamos a técnica de interpolação. Em seguida, as tendências crescentes devem ser analisadas para que todas as tendências crescentes se tornem apenas uma tendência crescente. Esse mesmo processo deve ser realizado para tendências decrescentes. Finalmente, as tendências que não crescem e não diminuem são igualmente distribuídas entre as que crescem e as que diminuem. Com esta etapa, a Matriz A' será constituída. Esse processo deve ser continuado até que todas as matrizes 'As' tenham sido analisadas e classificadas em um dos vetores da Matriz A'. Após a conclusão de todas as análises, a Matriz A' é constituída, permitindo, dessa maneira, a aplicação de algoritmos de *clustering* com a intuição de apreender a tendência dos *clusters* no espaço bidimensional.

Como um centróide de *clusters* se move ao longo do tempo, isso significa que o conjunto está descrevendo um movimento de tendência e selecionando tendências processadas, cuja ascensão ou queda consistente de acordo com a evolução da falha da máquina. Ele pode estabelecer uma ligação entre esses movimentos do centróide e o desgaste da máquina. A redução de dimensão é fundamental não apenas para reduzir as não linearidades na pesquisa de tendências nesse espaço (MASULLI; ROVETTA, 2015), mas também para eliminar componentes irrelevantes que não colaboram para rastrear a saúde da máquina em avaliação. Durante o processo de desenvolvimento, testes, avaliação e análises, verificamos que o HealthMon precisará de dados de pelo menos quatro semanas para recalcular a melhor base para criar valores IGS/GHI mais precisos. Na maioria dos casos, quatro semanas fornecem a quantidade certa de dados para ajustar um determinado índice (no nosso caso o GHI) usando um procedimento de otimização, mas esse tempo pode ser alterado sem perda de generalidade (SAIDI et al., 2017).

4.1.4 Fase 4: Agrupamento dos Sinais em Tendências

Na Fase 4, começamos verificando o período de uma semana que já passou. Nesse caso, aplicamos o algoritmo de agrupamento k-means, que agrupará os dados em 10 *clusters*, obtidos da Matriz A'. Devemos considerar o caso de não ter passado uma semana. Nessa situação, usaremos os dados da Matriz A' já classificados para calcular a monotonicidade como uma função de custo. Essa função deve maximizar por intermédio do processo de otimização, visando a descartar os grupos em cada Matriz A, o que mais contribui para a obtenção do maior valor de monotonicidade.

Anomalias como *outlier* (ponto fora da curva) no conjunto de séries temporais não acarretam em defeitos na máquina em que os sensores estão conectados. Essas anomalias em séries temporais, nesses casos, podem ser um comportamento súbito e atípico da máquina, por exemplo, o início de um novo modo de operação, que é geralmente imprevisível e, em última análise, depende do esforço que está sendo realizado pela máquina. Um motor de indução com carga variável pode executar tarefas variadas ao longo do dia sem repetibilidade, criando discrepâncias em séries temporais, não relacionadas a qualquer tipo de falha. Por outro lado, anomalias em séries temporais, com características de comportamento repentinos e atípicos também podem ser associados a eventos de falha (ou seja, falha consumada) em uma máquina. A diferenciação de ambos os casos pode ser difícil para algoritmos de aprendizado de máquina supervisionados (ZYABKINA et al., 2017).

4.1.5 Fase 5: Gerar IGS - Índice Global de Saúde de Máquina

Na Fase 5, calculamos o Índice Global de Saúde (IGS ou GHI). O HealthMon cria um único índice de tendência com base em deterioração da máquina/equipamento, visando a refletir o estado de saúde da mesma. Para isso, ele realiza processamentos em conjuntos de séries temporais. Com isso, é possível obtermos dados dos sensores instalados na máquina monitorada, que os decompõe em novas séries temporais. Em seguida, processa, analisa e recombina essas séries temporais para que um único índice possa ser calculado, o IGS.

O Índice Global de Saúde (IGS) representa a principal contribuição deste trabalho, pois é através deles que representamos a evolução de falhas em máquinas. O cálculo do IGS é realizado através da distância euclidiana entre os clusters deste conjunto. Uma vez que este IGS é gerado, ele deve ser apresentado graficamente ao usuário.

Para gerar o IGS, são necessárias três etapas, a saber, como mostra a Equação (4.1):

1. Definir o pivô, sendo este o centróide dos *clusters* mais próximos da origem. Uma vez definido esse pivô, ele não deve ser alterado até que um novo processo de otimização seja executado.

2. Definir a indexação do centróide do *cluster* para cada semana de observação. Portanto, devemos levar em consideração a que distância está o centróide do cluster do pivô definido para cada ponto que compõe a semana.

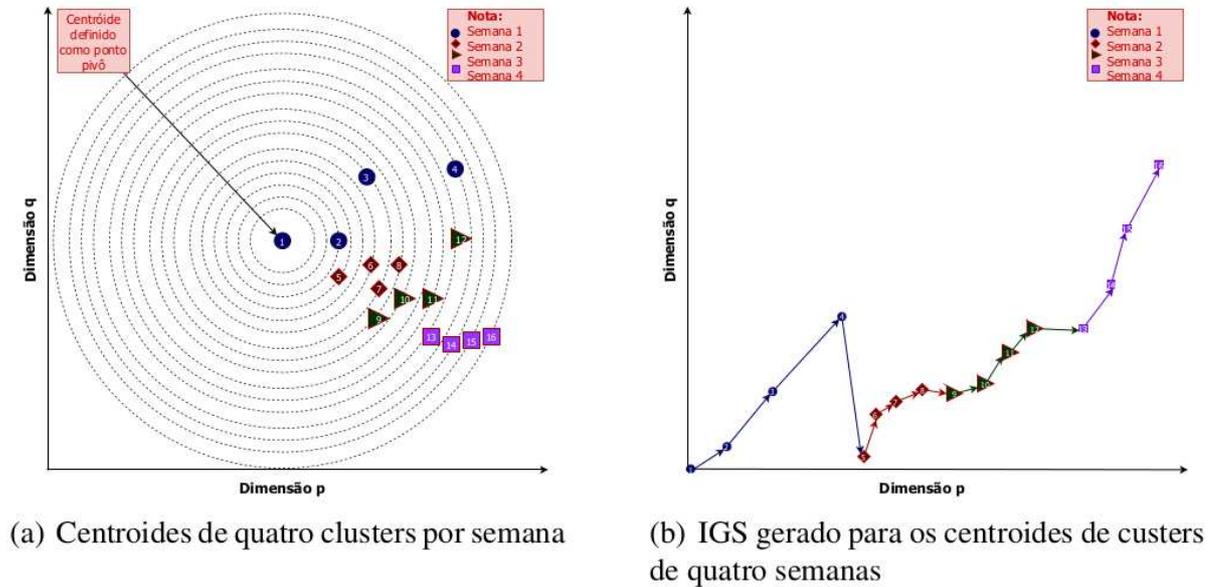
3. Calcular o IGS com base nas definições de pivô e na indexação do centróide.

$$IGS(nT) = \sqrt{(p_i - p_a)^2 + (q_i - q_a)^2} \quad (4.1)$$

Onde n é um instante de tempo, portanto um valor discreto dependente de T . O símbolo i representa o índice que identifica um centro de *cluster* quando organizado de acordo com as etapas descritas acima. Os símbolos p e q representam as coordenadas dos pontos no espaço. O símbolo a , que segue após o p ou q , indica qual elemento é o pivô. Em resumo, o IGS é uma série temporal discreta no tempo.

A Figura 28 ilustra a criação do IGS transpondo da perspectiva de centróides de *clusters* para a visualização gráfica do IGS em forma de índice. Para efeito de simplificação consideramos apenas quatro semanas nesta ilustração, porém lembrando que a aplicação final foi projetada para considerar dez centróides de *clusters* para cada semana. Chamamos a atenção para a mudança de tendência entre a semana 1 e a semana 2. Observamos que existe uma queda significativa do ponto 4 para o ponto 5. Isso ocorre pelo fato de ambos os pontos manterem praticamente a mesma distância do ponto pivô, ou melhor, o ponto 1 da Figura 28(a) que tem sua origem no ponto 0 da Figura 28(b), mantêm distâncias aproximadas entre o ponto 2 e o ponto 5, como pode ser observado na Figura 28(a). Notamos ainda que a distância entre de cada ponto, Figura 28(a), conforme os critérios descritos, irão resultar no índice apresentado na Figura 28(b). A ideia é ilustrar que esta distância é proporcional a distância do ponto em questão com relação a origem, ou seja, o ponto 1.

Figura 28 – Resultados obtidos para o cenário de teste com dados reais – CST



Fonte: Elaborado pelo autor.

4.1.6 Fase 6: Identificando o Conjunto de Tendências Relevantes

A Fase 6 realiza otimização. Nesse contexto, a função de monotonicidade está sendo aplicada em conjunto com o algoritmo k-means, mas como parte do processo de otimização. Para a execução desse processo, também utilizamos os algoritmos CST e GA, cujo objetivo é buscar e identificar os melhores conjuntos de sinais (após todo o processo de tenderização) que mais contribuem para gerar os mais altos índices de monotonicidade; consequentemente as indicações mais consideráveis da evolução da degradação. A partir da identificação do melhor conjunto de sinais, calculamos o IGS. Em tal caso, precisamos receber quatro semanas de dados para calcular a monotonicidade a fim de realizar uma janela deslizante de uma semana para recalculá-la novamente. Já, para calcular a monotonicidade por um conjunto de quatro semanas, usamos a Equação (2.2).

Nesse cálculo, no HealthMon, x_j representa o vetor de medições de um recurso no j th sistema, para nós, o vetor é formado pelos *clusters* de cada semana. A variável M é o número de sistemas monitorados que, para o HealthMon, cada sistema é formado por cada período de observação semanal. A variável N_j é o número de medições no sistema, que para nós é o

número de *clusters* por semana. O símbolo k , por sua vez, representa o índice dentro do vetor x . Em nossa abordagem, a Equação (2.2) deve ser maximizada para descartar grupos em cada Matriz A que não contribuem para a mais alta monotonicidade.

A monotonicidade da distribuição de centróides dos *clusters* está altamente relacionada à evolução de uma falha. Sabemos que isso ocorre porque uma falha pode ficar mais estável ou piorar, mas nunca pode diminuir (pois isso significa que a integridade da máquina não pode melhorar à medida que envelhece). Por conseguinte, podemos interpretar a evolução de falhas como sempre monotônica quando houver monotonicidade nos centróides de *clusters* no período de quatro semanas.

Como parte da técnica de otimização, executamos o CST (Algorithm 1) e Algoritmos Genéticos (AG ou GA) para obter a maior monotonicidade possível. Estes algoritmos são combinados iterativamente com o módulo de redução de dimensionalidade gerando nova as “Matrizes A’s” com base nas “Matrizes As”. Em particular, verificamos, na literatura, que vários estudos experimentais mostram que os AGs têm uma eficiência impressionante em funções objetivas ruidosas em matrizes de alta dimensão, conforme apresentado em 4.1.4 fazendo parte da Fase 4. e por isso este algoritmos compõe o módulo de otimização do HealthMon, sendo executado logo após a execução do CST.

Algorithm 1 CST (*Combinatorial Search Of Two*/Pesquisa combinatória de dois)

Entrada: Matriz Binária(BM), (Matrix A’) e Matriz A

Saída: Vetor de Bits (ou VB, contendo as coordenadas da BM)

```
1 inicialização de variáveis
2 enquanto existe iteração para a linhas na Matriz Binária ... faça
3   enquanto existe iteração para a colunas na Matriz Binária ... faça
4     realiza redução de dimensionalidade da Matriz A para gerar Matriz A’ executa o pro-
        cesso de agrupamento na Matriz A’ aplica cálculo de monotonicidade com os centrói-
        des dos clusters
5     se solução encontrada é maior que a solução atual então
6       | registra as coordenadas da matriz binária no VB
7     senão
8       | encontrar o melhor resultado ...
9     fim
10    pare continue; itera colunas
11  fim
12  itera linhas
13 fim
14 apresenta a melhor solução encontrada na forma de VB chama função para executar o algoritmo
    genético
```

Como mostrado no Algoritmo 1, Pseudocódigo, o algoritmo CST é uma implementação que visa a passar por uma matriz com valores binários, a Matriz Binária (MB), inicialmente preenchida por zeros, inicialmente. A lógica por trás do algoritmo 1 é definir o número de colunas no BM representa o número de conjuntos presentes na Matriz A. Nesse sentido, o número de linhas representa o número de componentes espectrais levados em consideração (na etapa ST) para a construção da Matriz A, após o processo de trenderização. A ideia é avaliar a monotonicidade ao escolher sempre apenas um par de conjuntos. O algoritmo CTS sempre definirá qual par de conjuntos deve ser escolhido para a construção da Matriz A', para que a Matriz A' seja avaliada entre todos os conjuntos em pares. O processamento de sinais envolve o acesso à Matriz A, reduzindo a dimensionalidade da Matriz A'. Para esse uso, recomendamos utilizar apenas o par de conjuntos definido iterativamente escolhido pelo CTS, agrupando-o através do algoritmo k-means. Finalmente, aplicando a função de monotonicidade com dados de 4 semanas de observação de funcionamento da máquina, através dos sensores, nela conectado(s). Quanto ao loop, que é executado iterativamente sobre a MB, em linhas e / ou colunas, o algoritmo CST deve habilitar 1 dos elementos do MB, de acordo com a lógica do *loop over*. Por exemplo, na primeira iteração, ele estará na primeira linha e na segunda coluna, definindo que os conjuntos de sinais 1 e 2 serão considerados para o processamento do sinal, o restante será desconsiderado neste momento. Está obtendo como resultado deste processamento uma Monotonicidade (2.2) valor de retorno. Durante as iterações o algoritmo visa obter o melhor resultado deste processamento, sendo este a maior Monotonicidade (2.1), como valor de retorno. Assim, podemos obter os dois melhores conjuntos de Matriz A levados em consideração nas próximas etapas da otimização.

A monotonicidade consiste em verificar o alinhamento construído conectando os centróides do *cluster*, levando em consideração o sinal da derivada entre dois centróides. Ao identificar a maior monotonicidade, o Bit de Controle (BC) é selecionado, ou seja, muda de zero para um. Os BCs são os valores memorizados na MB que correspondem aos conjuntos de sinais processados, sendo "0" ou "1". Quando o CST é executado, para indicar que um conjunto específico de sinais contribui para elucidar mais degradação na máquina em teste, ele altera o valor necessário para "1". Com relação ao Algoritmo 1, este pode ser verificado na linha 1, que é a inicialização das variáveis. É importante notarmos que, entre eles, diferentes tipos de estruturas de dados são utilizados como números inteiros, matrizes e vetores. Na linha 2, está a condição para que toda a matriz binária seja um *loop over*. A ideia é que, de maneira mais eficiente possível, todas as posições do MB devem ser verificadas em

relação a todos os outros lugares em pares definidas como '1' apenas duas posições ao mesmo tempo para maximizar a monotonicidade do *cluster* ao longo do tempo.

A função chamada na linha 4 tem como objetivo verificar o índice de monotonicidade usando um dado par de conjuntos da Matriz A, escolhido pela posição da linha e colunas iteradas pelos "enquantos" nas linhas 2 e 3. Na linha 4, o CST busca obter os melhores valores de monotonicidade dos conjuntos de sinais da Matriz A, conforme já descrito. Na linha 5, é testado se o resultado pesquisado é mais significativo do que a melhor solução alcançada momentaneamente. Se verdadeiro, a melhor solução é atualizada e o vetor que contém o melhor par de conjuntos é armazenado em um vetor de bits (VB). Para finalizar a execução dessa etapa, antes de iniciar o processamento com o GA, na linha 14. A função que retornará a execução do CST, a melhor solução encontrada na forma de vetor de índice, contida na VB, deve ser apresentada, indicando a melhor representam os conjuntos de sinais com provável evolução de degradação.

Com o melhor conjunto de grupos restante após o processo de otimização, temos uma nova coleção de séries temporais e novos *clusters* com o algoritmo K-means. Dessa forma, calculamos a distância euclidiana entre os *clusters* atuais e os anteriores, gerando o valor do índice IGS. Assim, com cada novo conjunto de tendências processadas, um novo *cluster* é calculado e a distância euclidiana entre esse *cluster* e o *cluster* calculado anteriormente representa a variação entre o IGS já calculado e o atual. Esses *clusters* estarão "se movendo" como uma tendência junto com esse espaço, pois cada tendência está evoluindo. No momento da realização da manutenção preventiva da máquina, que geralmente é programada e periódica, o IGS deve ser redefinido para zero. Em longo prazo, é possível monitorar o comportamento da função IGS e determinar com antecedência quando o indicador estará em níveis semelhantes aos da manutenção preventiva anterior.

4.2 Considerações parciais

Este Capítulo apresentou o HealthMon, cuja finalidade é gerar um índice que represente a saúde de máquinas ou equipamento vibrante e/ou rotativos. Para essa apresentação, o capítulo, além de apresentar a arquitetura, se dividiu em seis fases, a fim de explicar o HealthMon de forma detalhada. No que se refere às fases, como já verificamos: Fase 1: Preparação e parametrização do ambiente, que se concentra em preparar o ambiente por meio do usuário, cujo finalidade é colocar o HealthMon em operação; Fase 2: Trenderização - Processo de decomposição de sinal e identificação de tendências, o qual

consiste basicamente no módulo de processamento de sinais envolvendo o rastreamento espectral e o processo de tenderização, ou seja, converter as séries temporais em tendências; Fase 3: Redução de dimensionalidade - Reduzindo de um espaço multidimensional para um espaço bidimensional, no qual realizamos um processo das *trends*, ou seja, as séries temporais já processadas pela tenderização, em três grupos, (i) crescentes, (ii) decrescentes ou (iii) nenhuma. No caso de nenhuma, os valores são distribuídos igualmente entre crescente e decrescente para que resultem em uma matriz com dois vetores, a Matriz A'; Fase 4: Agrupamento dos Sinais em Tendências, aplicando ML, por intermédio do algoritmo K-means combinado com métodos matemáticos como o cálculo da monotonicidade; Fase 5: Gerar IGS - Índice Global de Saúde de Máquina, onde aplicamos o módulo de otimização através dos Algoritmos de busca, o CST e o GA; Por fim a Fase 6: Identificando o Conjunto de Tendências Relevantes, no qual será gerado o IGS, que indicará o estado de saúde da máquina.

5 METODOLOGIA DE AVALIAÇÃO

Neste Capítulo, descrevemos a metodologia para avaliar o HealthMon, contemplando os detalhes da implementação, a carga de trabalho de entrada e os parâmetros observados. A metodologia de avaliação foi desdobrada em duas abordagens de avaliações distintas, sendo elas: (i) aplicando dados sintéticos (produzidos em um software simulador de falhas, tendo sinais elétricos de corrente de estator de motores de indução, como dados para processamentos); (ii) aplicando dados reais, providos de sensores de vibração instalados em pontos estratégicos em um motor elétrico de indução de uma MFS (máquina que permite a simulação de falhas, sendo esta uma bancada de testes). Para facilitar a identificação de qual tipo de abordagem está sendo descrita, conforme o tipo de dados utilizado, será complementado junto a descrição da Seção ou Subseção "Dados Sintéticos" e "Dados Reais".

Em algumas Subseções poderão estar descritas como "Dados Sintéticos e Reais", indicando que tais descrições se aplicam para ambas as implementações.

5.1 Modelo de falha do motor de indução - Dados Sintético

De acordo com a literatura, existe uma base analítica bem fundamentada para descrever problemas em motores de indução (MI ou IM) com base na análise espectral da corrente do estator. Em todos os casos, a gravidade da falha é avaliada pela magnitude relativa dos componentes espectrais em relação ao componente fundamental (THOMSON; GILMORE, 2003; KUMSAR; KUMAR; SELVAKUMAR, 2011; GHEITASI, 2013; MILJKOVIC, 2015; SINGHAL; KHANDEKAR, 2013; MEHALA; DAHIYA, 2007). Assim, um aumento na magnitude relativa dos componentes espectrais em relação ao fundamental representa um aumento na gravidade da falha (MILJKOVIC, 2015; MEHALA; DAHIYA, 2007; TERRA et al., 2005).

Dessa forma, criamos um banco de dados sintético que representa uma observação de 4 semanas em uma amostra de corrente do estator IM de 4 pólos a 10 kHz durante 200 ms em intervalos de 10 min. O comportamento dessa corrente é o resultado da soma de duas formas de onda senoidais, correspondentes a duas componentes espectrais laterais associados a 6 tipos de falhas: (1) curto-circuito nos enrolamentos do estator, (2) desequilíbrio do rotor, (3) excentricidade diferencial do ar, (4) efeitos de carga, (5) barra quebrada e (6) assimetria do rotor. No entanto, todos esses tipos de falhas têm pelo menos um ponto em comum. No espectro atual do módulo, há o componente fundamental e duas bandas laterais, que aumentam à medida que a gravidade da falha também aumenta. A amplitude da corrente sinusoidal fundamental segue um algoritmo de caminhada aleatória, que consiste na sucessão de etapas aleatórias cuja mudança depende de um valor de probabilidade de significância ou valor p . Diferentes valores de p foram considerados na modelagem atual da assinatura quando o motor opera nos dias úteis e nos finais de semana, nos quais o valor de p é menor. Para as outras duas formas de onda sinusoidais, as amplitudes relativas seguem o comportamento da corrente fundamental que difere dela por uma constante multiplicativa chamada Gravidade da falha (em $p.u.$ da amplitude da fundamental). Finalmente, um ruído gaussiano é adicionado aos sinais para obter uma relação sinal-ruído de 80 dB.

5.1.1 Mecanismo SPM - Dados Sintéticos e Reais

Conforme mencionado na Seção 4, Fase 2 (Subseção 4.1.2), para cada componente espectral do sinal adquirido, o SPM cria uma Matriz A. Para reduzir a carga computacional, algumas simplificações podem ser feitas no caso particular de um IM como uma máquina em avaliação. A Subseção 5.1.3 descreve o Mecanismo ou Módulo de processamento de sinais, denominado SPM, através da Figura 29, elucidando a metodologia envolvendo este módulo durante a realização dos testes e validação.

5.1.2 Mecanismo de Otimização - Dados Sintéticos e Reais

Após os conjuntos de sinais serem pré-processados pelo mecanismo SPM, preenchendo as Matrizes A e A', a próxima etapa será identificar entre os conjuntos de sinais que melhor contribuem para elucidar no espaço do cluster a evolução das falhas no IM. Para isso, são definidos os algoritmos de otimização CST e GA, com o módulo chamado Mecanismo de Otimização.

Conforme mencionado, o processo de otimização deve começar com o algoritmo CST e, em seguida, aplicar o GA, que usa meta-heurísticas para procurar aleatoriamente melhores soluções que não foram identificadas pelo CST. Para uma melhor compreensão da implementação, permitindo possíveis reproduções para qualquer linguagem de programação, optamos por representar o CST 1.

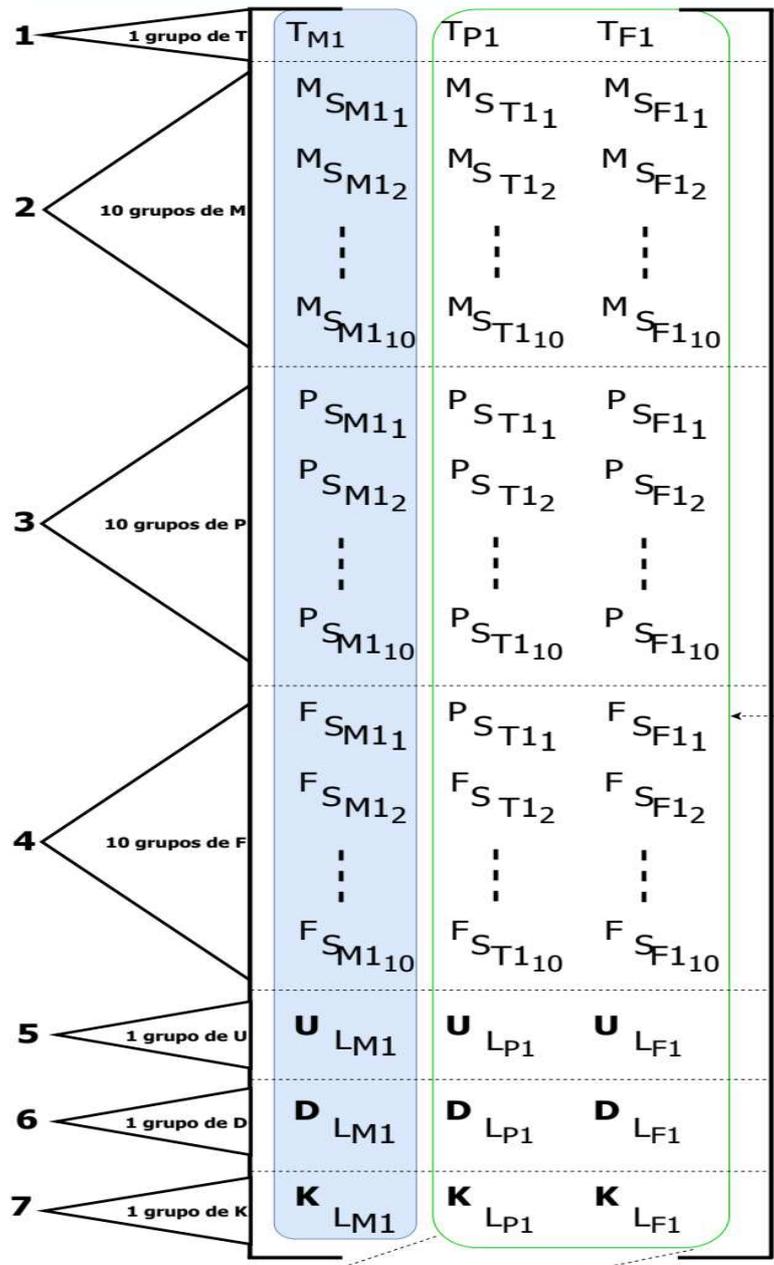
5.1.3 Modelagem de testes - Dados Sintéticos

Como pode ser visto na Figura 29, algumas áreas preenchidas em azul formam o conjunto de sinais. Isso ocorre porque sabíamos que para IMs as partes da Figura marcadas em verde correspondem a séries temporais que não contribuem para a detecção de falhas, como qualquer tendência relacionada à fase e frequência dos componentes espectrais do motor (THOMSON; GILMORE, 2003; Vinoth Kumar; Suresh Kumar; Immanuel Selvakumar, 2011; Alireza Gheitasi, 2013). Em outras palavras, apenas o componente do módulo é importante e, sabendo disso, as séries temporais verdes foram desativadas para economizar tempo de processamento ao avaliar o sistema. Da mesma forma, como o sinal

criado sinteticamente tinha apenas 3 componentes espectrais (conforme descrito na Seção 5.1), não fazia sentido considerar todas as 10 decomposições sugeridas pelo SPM mais generalizado representado na Figura 26. Dessa maneira, para acelerar a execução do código HealthMon na fase de teste, essas simplificações foram feitas.

Figura 29 – Matriz A resultante do SPM em testes - Dados Sintéticos

7 conjuntos por componente espectral, usando apenas 102 *
1 séries temporais



Os valores correspondentes as colunas destacadas em verde foram zerados no testes, como é de conhecimento que eles não são suscetíveis a nenhum tipo de falha do MI

Valores correspondentes da 4ª à 10ª componentes espectrais, destacados em verde, foram zerados nos testes, porque o gerador de falhas sintéticas utiliza apenas 3 componentes espectrais: 1 componente fundamental e 2 componentes de banda lateral



Fonte: Elaborado pelo autor.

5.2 Protótipo - Dados Sintéticos

A Figura 29 apresenta a Matriz A resultante do processamento de sinais do HealthMon, na fase de avaliação envolvendo dados sintéticos de corrente do estator em MIs. Para melhor ilustrar, ressaltamos em verde os componentes que não foram implementados no protótipo. Implementamos o protótipo em duas frentes. Nesse caso, é válido mencionarmos que ambas as implementações utilizaram a linguagem MatLab R2018a.

5.2.1 Avaliação com Protótipo - Dados Sintéticos

Após a apresentação do modelo para representar o HealthMon, apresentaremos nessa Seção os testes realizados para a avaliação no sentido de obter os resultados.

5.2.2 Cenários de avaliação - Dados Sintéticos

Durante a avaliação do HealthMon envolvendo dados sintéticos, utilizamos um sinal de corrente sintético para emular dados obtidos de um IM de 4 polos com três componentes espectrais. Além disso, também consideramos que a gravidade da falha aumentou gradualmente durante um intervalo de observação de quatro semanas. A severidade selecionada das falhas usadas para verificar a correção da melhor solução para quantificar o IGS adequadamente foi:

- a) Aumento interno de 0 [pu] para 0,2 [pu] na 1ª semana, permanecendo 0,2 [pu] a partir da 2ª semana até a 4ª semana.
- b) Valor constante de 0 [pu] desde a 1ª semana até a 3ª semana e aumento linear de 0 [pu] para 0,2 [pu] na 4ª semana.
- c) Aumento linear de 0 [pu] para 0,2 [pu] a partir da 1ª semana até a 4ª semana.
- d) Valor constante de 0 [pu] desde a 1ª semana até a 2ª semana, e aumento linear de 0 [pu] para 0,2 [pu] na 3ª semana, permanecendo valor constante de 0,2 [pu] na 4ª semana.

Para a implementação do sistema, o MatLab R2018a foi usado como ferramenta de desenvolvimento. A infraestrutura física era um computador pessoal com processador Intel Core i7 com 8 GB de RAM e 1 TB de HD. Todas as camadas e módulos do sistema foram executados localmente, desconsiderando as interfaces de rede, entre outros elementos que devem compor a infraestrutura ao colocar o HealthMon em operação na indústria.

5.2.3 Parâmetros dos Algoritmos de Otimização - Dados Sintéticos

Os algoritmos de otimização GA se caracterizam por determinados parâmetros, sendo eles: os parâmetros populacionais, o número de gerações e a taxa de mutação, que são parâmetros diretamente relacionados ao tempo de execução. Quanto ao algoritmo de otimização ILS, seus parâmetros são outros como: o número máximo de tentativas de pesquisa e taxa de perturbação, que por sua vez também estão diretamente relacionados ao tempo de execução desta técnica. Desse modo, uma métrica diretamente relacionada aos resultados para o HealthMon seria a monotonicidade (ver Equação: (2.2)), que deveria ser obtida em um tempo de execução predefinido dos algoritmos GA e ILS.

Entretanto, para estabelecer uma análise comparativa entre o algoritmo GA e o algoritmo ILS, usamos o número de interações como métrica-padrão entre eles, definindo o mesmo "número de iterações" para os dois algoritmos, esperando tempos de execução semelhantes. Optamos por fazer isso porque não é possível predefinir o tempo de execução para cada algoritmo ML como um parâmetro configurável, pois depende não apenas de outros parâmetros operacionais, mas também da implementação do código.

Da mesma forma, não é possível determinar a monotonicidade (ver Equação: (2.2)) como critério de parada dos algoritmos de ML, uma vez que a busca no espaço da solução é não-linear, levando a conclusões errôneas sobre o desempenho de cada algoritmo. Embora o significado de "número de iterações" seja ligeiramente diferentes para ambos os algoritmos, é o ponto de partida adotado para a comparação de desempenho entre eles. Da mesma maneira, para uma comparação mais justa entre algoritmos, a taxa de perturbação ILS e a taxa de mutação GA foram definidas como o mesmo valor. Com o intuito de avaliar esses parâmetros, definimos o número inicial de 50 interações, que é um valor relativamente baixo e um valor inicial de perturbação e taxa de mutação de 1%. Após um curto tempo de execução, os resultados obtidos com os parâmetros selecionados exibem monotonicidade

muito baixa, valores inferiores aos esperados; então, o número de iterações foi ajustado para 100 iterações para GA e ILS.

Depois disso, nenhum novo número de iterações foi incrementado após essas definições, porque o algoritmo ILS levou um tempo de execução muito longo para executar suas iterações de modo a comprometer os objetivos finais do sistema como um todo, independentemente do número da interação e diretamente proporcional ao tempo de execução dos algoritmos. Assim, concluímos que não era possível comparar os dois algoritmos ao mesmo tempo de execução, pois, apesar dos baixos números de interação com ILS, o tempo de execução aumentou exponencialmente. O GA permitiu pelo menos 100 vezes mais iterações do que o ILS pelo mesmo tempo de execução. Além disso, o GA retorna o resultado, em termos de índice de monotonicidade, mais alta que o ILS, operando em um tempo consideravelmente mais curto.

Dessa forma, temos as seguintes definições finais para GA: uma população composta por 100 indivíduos, o número de gerações foi 10000 e a taxa de geração foi definida em 1%. Para o ILS, o número máximo de 100 tentativas foi selecionado e a taxa de perturbação foi definida como sendo 1%. Juntamente com os algoritmos GA e ILS, aplicamos o algoritmo CST 1, como já mencionamos. Como a CST pesquisa o espaço de busca, utilizando o critério de comparação entre dois elementos, não foi necessário aplicar heurísticas.

5.3 Testes e Avaliação - Dados Reais

Os testes e os resultados realizados evidenciam a eficácia da abordagem HealthMon. Após a validação da presente proposta por meio dos experimentos envolvendo dados sintéticos, conforme a Seção 5.2.1, percebemos que a abordagem é muito promissora no sentido de atender aquilo que se propõe, gerar o índice de saúde de máquina informando a evolução de condições de falhas na respectiva máquina. Todavia, cabe ressaltarmos que, a fim de que a validação se tornasse ainda mais confiável, se fez necessário o mesmo procedimento de validação, porém desta vez envolvendo dados reais com máquina reais, sendo este o objetivo desta Seção.

5.3.1 Cenários de Avaliação - Dados Reais

Para a realização dos testes com dados reais, foram necessários alguns *hardwares* específicos, entre eles uma bancada com um motor elétrico de indução (*Machinery Fault Simulator* - MFS) e sensor de vibração ADXL345. Com ênfase ao equipamento MFS, pelo fato de estar equipado com funcionalidades que permitem a introdução de falha no motor, por meios de mecanismos desenvolvidos especificamente para este fim. De modo que os dados possam ser coletados em diferentes cenários simulados, ou seja, com esta máquina é possível reproduzir diferentes estados de funcionamento, permitindo a realização de testes considerando estados sem falhas evoluindo até altos graus de severidades. Com a utilização dessa poderosa máquina de simulação de cenários, acreditamos ser possível estabelecer um alto grau de confiabilidade quanto à qualidade dos dados obtidos, pois os cenários projetados são tão reais quanto os de uma planta industrial com as máquinas realizando suas operações. O sensor ADXL345 é um componente de baixo custo, em torno de 1 dólar, que foi adquirido apenas para os testes iniciais, e por isso seriam interessantes avaliar a aplicação de sensores mais robustos ao colocar o HealthMon em operação na indústria. Ao testar este sensor em motores de baixa potência, em torno de 500cv com vibrações máxima aproximada de 1kHz, os resultados foram promissores. Motores de potências superiores a esta ainda devem ser testados.

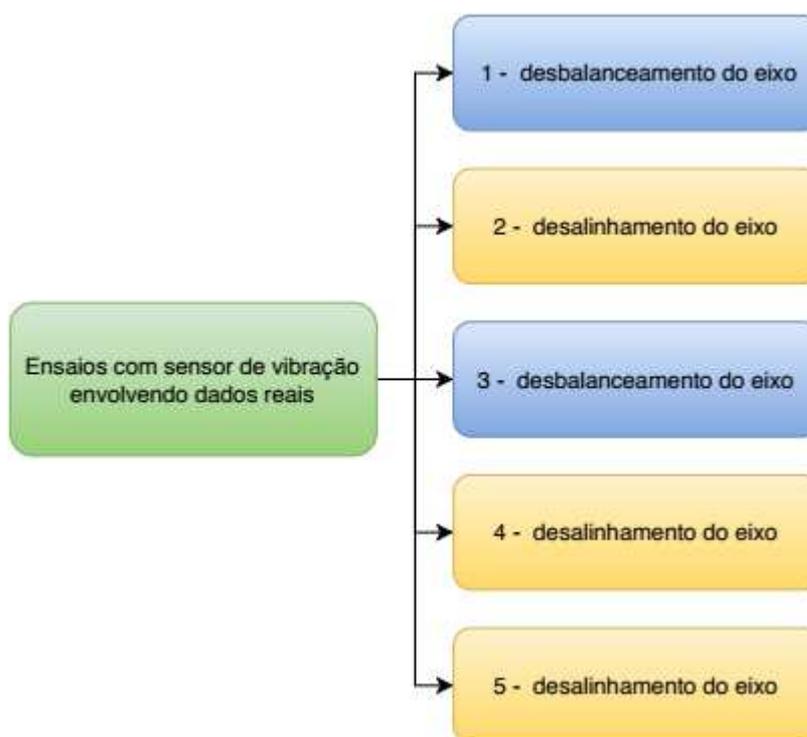
O MatLab R2018a foi usado como uma ferramenta de desenvolvimento para a implementação do sistema como protótipo envolvendo sintéticos. Porém, esta mesma implementação foi ajustada para o processamento com os dados reais. Paralelamente a isso, uma nova aplicação foi desenvolvida com a linguagem de programação Python e banco de dados PostgreSQL. A infraestrutura física em termos de computador, se manteve a mesma utilizada para o protótipo, com processador Intel Core i7 com 8 GB de RAM e 1 TB de HD. Da mesma forma que no protótipo, todas as camadas e módulos do sistema foram executados localmente, desconsiderando as interfaces de rede, entre outros elementos que devem compor a infraestrutura da solução final.

Foram planejados cinco ensaios envolvendo dados reais, conforme apresenta a Figura 30. Cada ensaio contou com quatro cenários distintos, que correspondia a um estado específico da máquina, que periodicamente foi ajustado para que apresentasse comportamentos diferentes, de modo que o HealthMon deveria identificar o comportamento dos sinais de acordo com tais estados, conseqüentemente as degradações provocadas

conforme o planejamento dos cenários. A Figura 31(b), 32(a) e 32(b) apresentam a bancada simuladora de falhas de máquinas (SQI SPECTRAL QUEST, 2020) em diferentes perspectivas.

O ensaio pode ser compreendido como uma sequência de coleta de dados, na qual cada ensaio é subdividido em quatro etapas. Cada etapa corresponde a um cenário, ou seja, um estado de funcionamento da máquina, no caso o motor elétrico. Onde o cenário corresponde ao período de uma semana para coleta de dados, pois a abordagem foi desenvolvida para trabalhar com quatro períodos de tempos distintos, visto que identificamos o período de uma semana seria tempo suficiente para a atualização do IGS de modo satisfatório.

Figura 30 – Ensaios Realizados.



Fonte: Elaborado pelo autor.

5.3.2 Modelagem de testes - Dados Reais

Os testes envolvendo dados reais de vibração tiveram a Matriz A completa como artefato resultante do processamento de sinais, conforme evidencia a Figura 26 (4). É importante notar que esta Matriz A contém as séries temporais originadas dos dados dos sensores após o processamento (SPM), conforme mostra a Figura 33. Nesta figura,

visualizamos o fluxo prático aplicado à realização da validação da abordagem via testes e envolvendo dados reais, permeando desde a definição de cenários, perpassando pelo mecanismo de otimização, até a geração de dados para análises. Dois tipos de falhas foram o alvo deste estudo: (i) desbalanceamento do eixo, que é provocado com a adição de parafusos junto ao eixo acoplado ao motor; e outro tipo de falha (ii) desalinhamento do eixo, que é provocado com o deslocamento da base que mantém o eixo acoplado ao motor. Para a realização destes testes, foram criados cinco cenários. A ideia seria obter uma confirmação dos resultados com tipos de falhas e com situações diferentes, como motor com carga e sem carga. Segundo a Figura 30, foram dois ensaios avaliando desbalanceamentos e três avaliando desalinhamentos. O número de ensaios com desalinhamento foi maior, visto que verificamos resultados inferiores aos ensaios envolvendo desbalanceamentos. Estes ensaios são apresentados na Figura 30, na Subseção 5.3.1.



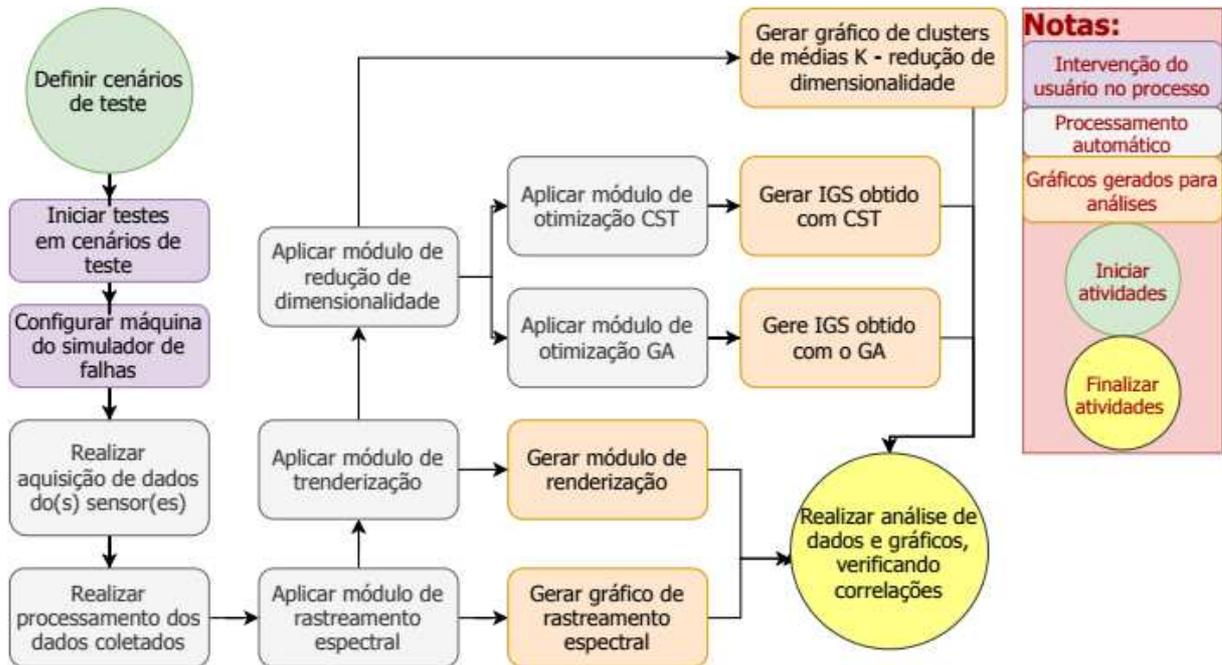
(a) Sensor de vibração ADXL345 (utilizado para coleta de dados reais)

(b) Bancada de simulações de falhar com motor elétrico (MFS) (SQI SPECTRAL QUEST, 2020)

Figura 31 – Equipamento usado para experimento com dados reais

Fonte: Elaborado pelo autor

Figura 32 – Fluxograma para avaliação do HealthMon com dados reais.



Fonte: Elaborado pelo autor

Na Seção 6.2, serão apresentados os gráficos gerados a partir desses processamentos, a saber: Gráfico de Rastreamento Espectral, Gráfico de Trenderização, Gráfico de Clusterização para o algoritmo CST e GA e Gráfico IGS (CST e GA).

5.4 Considerações parciais

Neste Capítulo apresentamos a Metodologia de Avaliação para validar o HealthMon. Para isso dividimos em duas etapas. Uma para avaliação com dados sintéticos e outra para avaliação com dados reais.

Figura 33 – Bancada de simulações de falhar com motor elétrico (MFS)



(a) Bancada de simulações de falhar com motor elétrico - Painel programável



(b) Bancada de simulações de falhar com motor elétrico com carga

Fonte: Elaborado pelo autor.

Para a avaliação com dados sintéticos aplicamos dados sintético de motor de indução, no qual cada módulo do HealthMon foi testado e avaliado. Para isso contou com um protótipo desenvolvido em Matlab que permitiu uma verificação do HealthMon de forma simplificada, utilizando apenas três componentes espectrais. Isso foi possível pelo fato de já serem suficientes para verificar a eficácia da solução. Já avaliação com dados reais, além de contar com a implementação em Matlab, também contou com uma aplicação desenvolvida em Python. Além disso, também foi aplicado sensor de vibração ADXL345 e uma máquina

simuladora de falhas equipada com um motor de indução. Nessa máquina, aplicamos os Cenários de Avaliação, que consistiram na modelagem de cinco ensaios simulando dois tipos de falha, (i) desbalanceamento do eixo e (ii) deslocamento do eixo. Ambos os cenários serviram para confirmar e consolidar a eficácia do HealthMon.

6 RESULTADOS

Neste Capítulo, são apresentados os resultados obtido através das avaliações, tendo em vista duas configurações: (i) uma com base nos resultados com dados atuais do estator, obtidos sinteticamente (consulte a Subseção 6.1), e outra (ii) com base nos dados de vibração obtidos via coleta de dados usando o sensor ADXL345 (consulte a Subseção 5.3). Ambos os tipos de dados foram aplicados às funcionalidades que envolvem os módulos SPM (Subseção 5.1.1) e Módulo de Otimização (Subseção 5.1.2).

6.1 Avaliação com Dados Sintéticos

Nesta abordagem, usamos um banco de dados para processar os dados sintéticos de IM (subseção 5.1). Apresentamos os resultados em duas partes. A primeira parte envolve análises comparativas entre os algoritmos, conforme descrito na Subseção 5.2.3. A segunda parte concentra-se nos cenários de teste usados para ilustrar como o IGS funciona, conforme descrito em 5.2.2. Por fim, apresentamos uma breve discussão envolvendo os resultados obtidos. Conforme descrito na Subseção 5.2.3, foram realizadas duas análises comparativas, uma envolvendo desempenho, como mostra a Tabela 3. A outra referente ao melhor resultado, neste caso, o maior índice de monotonicidade, conforme mostrado na Tabela 3. Lembrando que para identificar a evolução das falhas da máquina, é necessário aplicar o método de otimização de pesquisa. Este requisito justifica a avaliação dos três métodos: CST, GA e ILS.

Na Tabela 3, avaliamos o desempenho dos algoritmos parametrizados, conforme descrito na Seção 5.2.3. Nesse caso, podemos notar que usando o algoritmo CST [1], no nosso caso, sempre obtivemos a melhor combinação de tendências para criar a mais alta monotonicidade no espaço reduzido dos *clusters*. Para propósitos gerais, uma combinação de CST seguida de GA pode ser aplicada. O Algoritmo CST surpreendeu ao realizar buscas e encontrar os valores máximos (0,997) em menos de 30 minutos. O algoritmo GA foi

executado em 3 horas e 20 minutos e obteve um valor de monotonicidade menor do que a pesquisa anterior (0,275). Finalmente, o algoritmo ILS demorou mais que os outros algoritmos e obteve o menor valor de monotonicidade (0,125), como pode ser visto na Figura 36(a-b). Dados esses resultados indesejados pelo algoritmo ILS, esse método foi descartado das experiências com o módulo de otimização. A seta apontando para a CST que indica que é técnica obteve o melhor resultado em relação às demais.

Os resultados envolvendo dados sintéticos focaram basicamente na análise dos melhores resultados em termos de performance dos algoritmos para a realização das buscas e os maiores índices de monotonicidades obtidos. Desse modo, descrevemos as experiências de cada algoritmo: CST, GA e ILS. Os testes foram realizados com a aplicação de uma técnica de otimização em cada vez. Para várias rodadas de simulação, os resultados descritos acima foram muito semelhantes, portanto, para esta aplicação, o GA foi mais adequada que o ILS. Ao aplicar o GA, o BS (best solution, ou melhor resultado) obtido ao final de 3 horas de simulação resultou em monotonicidade de 0,275. Por outro lado, ao aplicar o ILS, o BS obtido ao final de 20 horas de simulação culminou em monotonicidade de 0,125. Nesse cenário, ao usar o algoritmo CST [1], no nosso caso, sempre obtemos a melhor combinação de tendências para criar a mais alta monotonicidade no espaço reduzido dos clusters. Para propósitos gerais, uma combinação de CST seguida por GA pode ser aplicada. Como mostrado na Figura 36(a), uma análise de desempenho dos três algoritmos (CST, GA e ILS) é realizada.

Tabela 3 – Análise Comparativa Algorítmica - Monotonicidade e Desempenho.

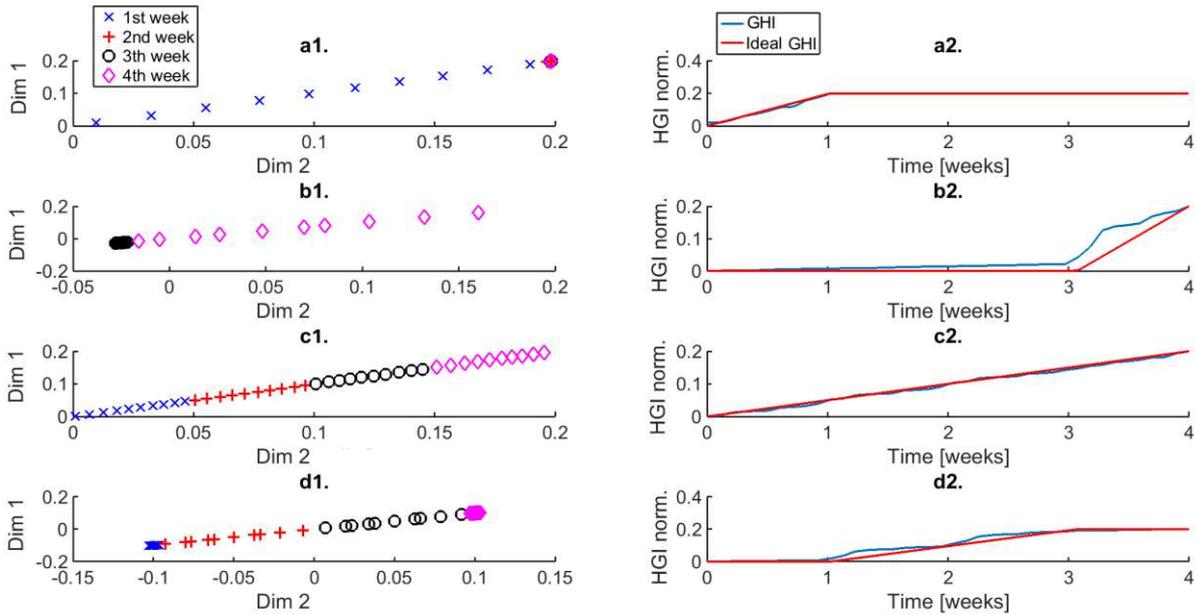
Algoritmo	Índice de Monotonicidade	Tempo para a execução (em horas)
CST	0.997	0.3
GA	0.275	3.2
ILS	0.125	20

Fonte: Elaborado pelo autor.

O Algoritmo CST se demonstrou eficaz ao realizar pesquisas e encontrar os valores máximos (0,997) em menos de 30 minutos. O segundo foi o algoritmo GA com um tempo de execução de 3 horas e 20 minutos e com um valor de monotonicidade menor que a pesquisa

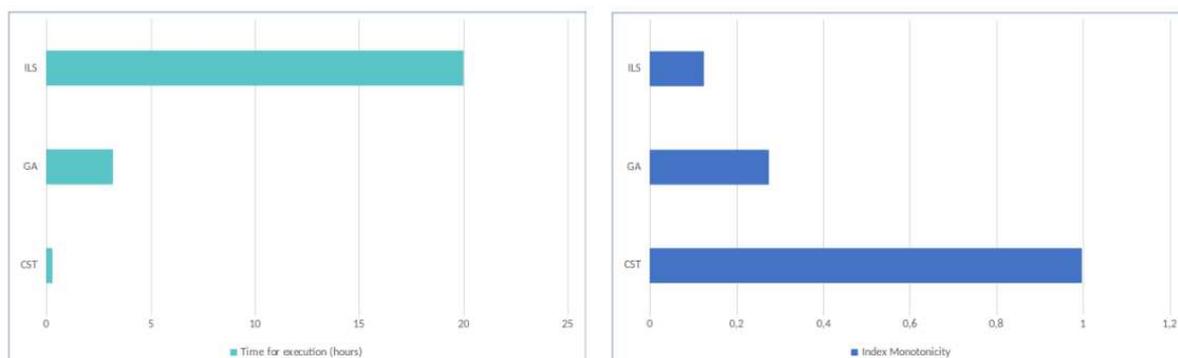
anterior (0,275). Finalmente, o algoritmo ILS com o maior tempo de processamento, sendo 20 horas, e obtendo o menor valor de monotonicidade (0,125), conforme revela a Figura 35(b). Dados esses resultados indesejados pelo algoritmo ILS, esse método foi descartado para processamento no módulo de otimização.

Figura 34 – Resultados obtidos em cenário de teste com dados sintéticos



Fonte: Elaborado pelo autor

Figura 35 – Comparação envolvendo os algoritmos CST, GA e ILS, avaliando métricas de monotonicidade e tempos de execução.



(a) Desempenho de algoritmos com dados sintéticos (b) Monotonicidade obtida a partir dos algoritmos com dados sintéticos

Fonte: Elaborado pelo autor

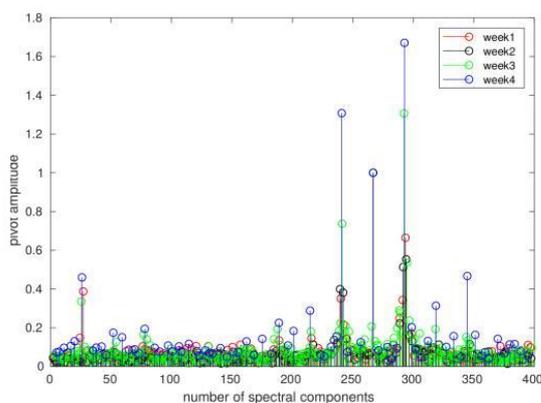
Usando todos os cenários de teste definidos na Seção 5.2.2, é possível ver na Figura 34 (a1), (b1), (c1), e (d1) a distribuição dos *clusters* de quatro semanas após a BS. Essa gravidade pré-selecionada pode ser vista como "IGS Ideal" na Figura 34 (a2), (b2), (c2) e (d2), em linhas vermelhas, respectivamente. O IGS calculado é mostrado em (a2), (b2), (c2) e (d2) linhas azuis. Uma visão qualitativa simples pode revelar uma alta correlação, o que significa sucesso no rastreamento da gravidade da falha do MI.

6.2 Avaliação com Dados Reais

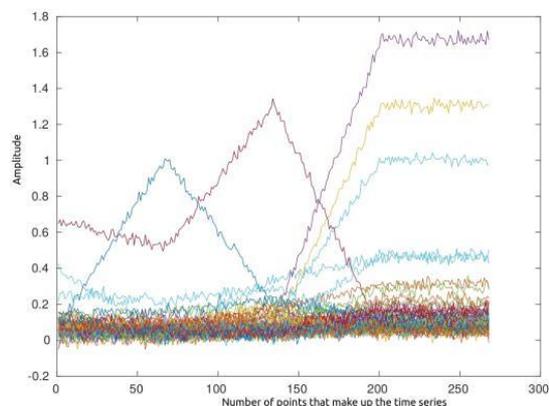
Nesta seção, apresentamos os resultados obtidos através dos dados reais. Figuras 36, 37 e 38 mostram os resultados obtidos com o motor com desequilíbrio de eixo simulado. Foi realizado com a adição de quatro parafusos para cada cenário simulado, resultando em doze parafusos, o que mostra um desequilíbrio crescente nos quatro cenários ao longo das quatro semanas. Para a execução de tal, na primeira semana, foi testado sem a adição de parafusos. A cada 45 minutos, o processo era interrompido para a colocação de mais quatro parafusos. Como consequência, um novo cenário foi criado. Esse processo foi repetido até que os ciclos do cenário fossem concluídos. Este foi o primeiro teste a verificar se havia componentes espectrais com alteração monotônica entre uma condição e a seguinte mais grave.

Os componentes espectrais, mostrados na Figura 36(a), destacam a amplitude de cada pivô por meio de um círculo com cores diferentes, conforme mostrado na legenda. A Figura 36(b) apresenta tendências, na forma de séries temporais, de uma perspectiva diferente. Dessa forma, podemos verificar a existência de tendências crescentes, que resultarão em

evidências de monotonicidade. Os triângulos formados dentro desta figura representam séries temporais que começaram a apresentar evoluções, porém, em dado momento, deixou de ser crescente. Por intermédio dos picos existentes nessas figuras, observamos ainda a existência de monotonicidades. Essas ilustrações foram obtidas via pré-processamento realizado para fins de validação. Como mostrado, essas figuras revelam que existem componentes espectrais em evolução, que serão identificados pelos algoritmos de busca.



(a) Rastreamento Espectral

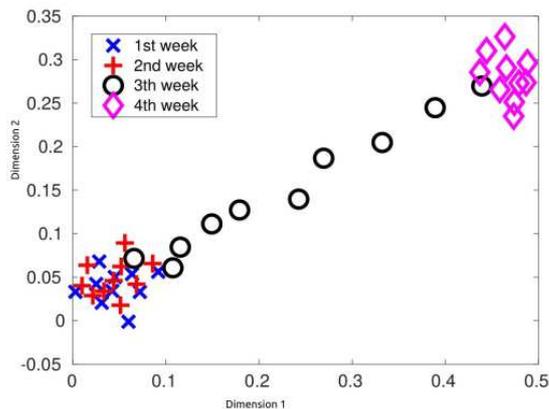


(b) Trenderização (Amplitude de várias séries temporais)

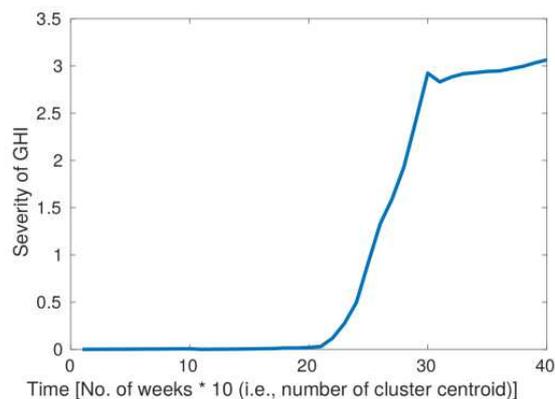
Figura 36 – Resultados obtidos para o cenário de teste com dados reais – Sinais

Fonte: Elaborado pelo autor

Figura 37 – Resultados obtidos para o cenário de teste com dados reais – CST



(a) Clusters gerados com o CST

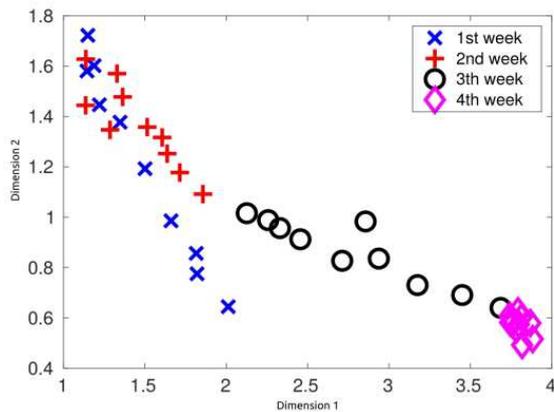


(b) IGS gerados com o CST

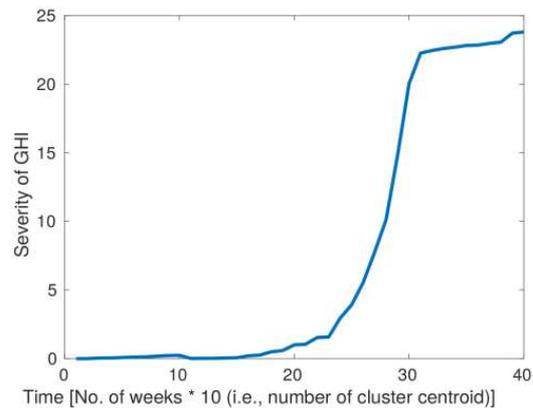
Fonte: Elaborado pelo autor

Como podemos observar, os resultados foram animadores, pois tanto o IGS gerado pela CST (Figura 37(a)) bem como o GA (Figura 37(b)) demonstraram monotonicidades crescentes, o que significa, a evolução da degradação causada na MFS foi confirmada por meio do IGS. Isso foi possível graças à monotonicidade, a qual pode ser vista nas Figuras 38(a) e 38(b). Embora os agrupamentos estejam posicionados de maneiras diferentes, ambos possuem bons índices de monotonicidade. Aliás, cabe mencionarmos que mesmo os centróides dos *clusters* apresentaram tendências para diferentes direções, conforme mostrado nas Figuras 37(a) e 38(a), enquanto os IGSs apresentam formas semelhantes, como evidenciam as Figuras 37(b) e 38(b). Isso ocorre porque as duas técnicas identificaram valores aproximados de monotonicidade durante pesquisas otimizadas. Vale apontarmos ainda que há também a correspondência entre os *clusters* e as Figuras 37(a) e 38(a), com as Figuras 37(b) e 38(b), em relação ao índices. Ambas as figuras de *clusters* mostram pouca evolução das falhas nas semanas 1 e 2. No entanto, na semana 3, parece que a falha evolui de forma consistente até parecer estabilizar na semana 4. Da mesma forma, as figuras que representam os índices descrevem esse comportamento.

Figura 38 – Resultados obtidos para o cenário de teste com dados reais – GA



(a) Clusters gerados com GA



(b) IGS gerados com GA

Fonte: Elaborado pelo autor

Durante o teste, realizamos a avaliação da CST, primeiramente, para verificar os resultados da AG. Entretanto, ao implementar a versão final do HealthMon, definimos que: (i) o resultado obtido pela CST deverá ser o parâmetro do melhor resultado para o GA a fim de permitir que o GA conduza sua pesquisa em busca de melhores resultados; (ii) se encontrar um resultado melhor do que o gerado pela CST, o GA deve atualizar seus parâmetros para obter os melhores resultados encontrados, o que corresponde às melhores tendências que mostram a evolução da falha. No caso de corrente IM e com dados de vibração, o CST obteve melhores resultados. Talvez com outros tipos de variáveis, o GA possa ser mais eficiente. Portanto, esta técnica visa a obter o melhor resultado entre os dois algoritmos.

Assim como realizamos as análises dos resultados com os dados sintéticos, também achamos conveniente aplicar estas análises envolvendo dados reais, porém considerando diferentes ensaios. Destarte, os ensaios focaram em duas métricas: (i) o desempenho, observando o tempo de execução dos algoritmos para a geração do IGS, e (ii) a monotonicidade. Como são dois algoritmos com técnicas distintas, os resultados em termos de monotonicidade podem ser diferentes daqueles que, por sua vez, refletem diretamente na geração do IGS. Estes resultados podem ser visualizados nas Figuras 39 e 40. Ambas as figuras foram geradas a partir de dados já compilados das Tabelas 4 e 5. Com base no gráfico da Figura 40, foi possível constatar que o algoritmo CST precisa de muito mais tempo para realizar o processamento. Embora alguns casos apresente a necessidade de um tempo menor, como é o caso do Ensaio 2, que aplicou um volume menor de dados para o processamento.

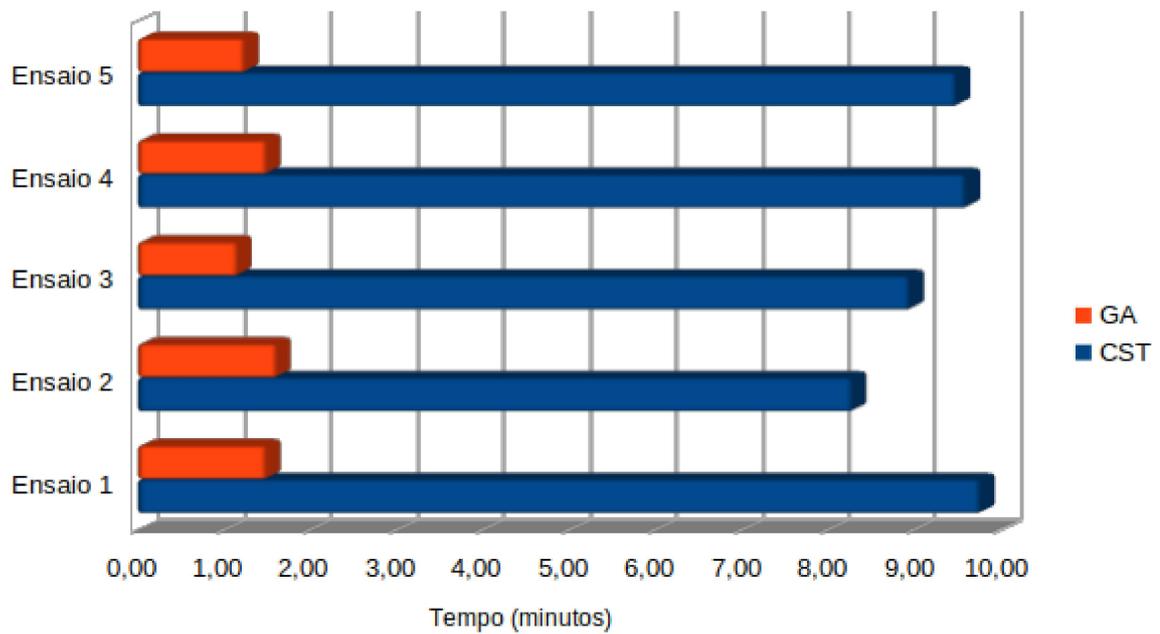
O fenômeno que explica tamanha diferença entre o tempo do CST e o algoritmo GA para os processamento é o fato do CST realizar a verificação de maior monotonicidade entre as duas *trends*, realizando combinações por meio de força bruta. Isto é, o algoritmo CST irá verificar a maior monotonicidade da primeira *trend* com relação à segunda. Isso na primeira iteração. Na próxima, iteração ele manterá a primeira *trend* e irá comparar com a monotonicidade da *trend* 3. E assim será feito até que todas as *trends* tenham sua monotonicidade comparada coma monotonicidade da primeira. Ao concluir este ciclo, o CST irá calcular a monotonicidade da segunda *trend* e comparar com as demais, conforme já explicado para a primeira iteração.

Tabela 4 – Análise Comparativa Desempenho de Tempo em minutos

Ensaio/Algoritmo	CST (min)	GA (min)
Ensaio 1	9,77	1,49
Ensaio 2	8,29	1,61
Ensaio 3	8,95	1,16
Ensaio 4	9,60	1,50
Ensaio 5	9,49	1,24

Fonte: Elaborado pelo autor.

Figura 39 – Comparação de desempenho de algoritmos com dados reais



Fonte: Elaborado pelo autor

Tabela 5 – Análise de Índice de

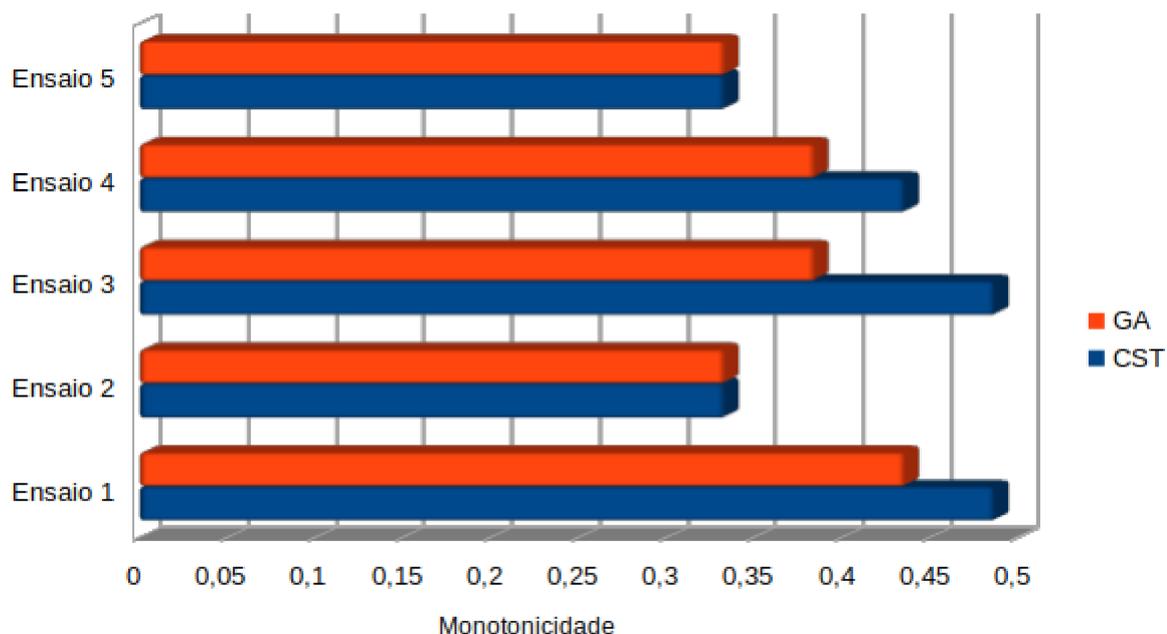
Ensaio/Algoritmo	CST (IGS)	GA (IGS)	Comparativa Monotonicidad
Ensaio 1	0,4872	0,4359	
Ensaio 2	0,3333	0,3333	
Ensaio 3	0,4872	0,3846	
Ensaio 4	0,4359	0,3846	
Ensaio 5	0,3333	0,3333	

Fonte: Elaborado pelo autor.

Ao fim do processamento, será gerado o IGS com as duas *trends* de maior monotonicidade. O resultado desse processo refletirá em uma busca otimizada, porém com um custo, em termos de tempo, maior do que o GA, que aplica heurística para realizar suas buscas, ou seja, não verifica todo o espaço de busca. O fato de o GA ter obtido esse excelente resultado em termos de desempenho com relação ao CST nos surpreendeu, pois, nos testes envolvendo dados sintéticos de corrente elétrica, o CST apresentou resultados

superiores em termos de tempo de execução, além de ainda obter os melhores resultados em termos de monotonicidades. Cabe lembrar que os testes com dados reais envolveram variáveis de vibração, possivelmente ao aplicar esta técnica para variáveis de outra natureza o desempenho seja outro.

Figura 40 – Comparação de monotonicidade obtida a partir dos algoritmos com dados reais



Fonte: Elaborado pelo autor

Vale salientarmos ainda que os testes de desalinhamento do eixo, conforme Figura 40, no ensaio 2 e 5, não apresentaram resultados tão promissores quanto os obtidos com a simulação do desequilíbrio do eixo. Diante disso, levantamos algumas hipóteses, tais como: (i) ou o motor da bancada é de tão baixa potência que as vibrações nesse caso não se evidenciam (teríamos que fazer o teste com motores de maior potência); (ii) ou nosso sensor acelerômetro não tem sensibilidade para captá-las; (iii) ou ambas; (iv) ou ainda há também a hipótese do ruído de fundo de nosso sensor que é elevado, e pode ser melhorado pela escolha de um outro sensor melhor, (algo parecido com o item ii).

6.3 Considerações Parciais

Esta Seção apresentou os resultados obtidos conforme as definições descritas no capítulo de Metodologia de Avaliação. Pelo fato de termos realizado a avaliação com dois tipos de dados, conseqüentemente, obtivemos duas perspectivas de resultados, uma envolvendo dados sintéticos e outra envolvendo dados reais. Os resultados envolvendo dados sintéticos foram realizados em duas frentes. Uma utilizando o protótipo avaliando tempo de execução e resultados obtidos na busca de melhores monotonicidade para cada algoritmo de busca, CST, GA e ILS. A outra por meio da avaliação da criação de índices degradação ideal comparando com a o índice do HealthMon, o IGS/GHI, com diferentes situações. Os resultados alcançados com dados reais consistiram basicamente na análise dos dois algoritmos adotados para a realização do processo de otimização: o CST e o GA. As análises se concentraram no desempenho, como tempo de execução e melhores resultados obtidos na busca, no caso os melhores índices de monotonicidade. Essa etapa levou em consideração os cinco ensaios realizados. Verificamos que ambas as abordagens produziram resultados encorajadores. Por isso, foi possível verificar a eficácia da abordagem HealthMon na identificação evolução de falhas e geração do índice global de saúde da máquina, o IGS.

7 CONCLUSÃO

Neste trabalho, apresentamos o HealthMon, que trata-se de uma abordagem para calcular o índice global de saúde (IGS) de máquinas vibrantes, cuja finalidade é permitir a análise de seu progresso de degradação. Ao abordar o momento da manutenção preventiva de uma máquina, primeiro capturamos a medida IGS para, posteriormente, a manutenção pudesse ser feita. Nesse momento, levamos em consideração que o motor está próximo de perfeitas condições de funcionamento. A cada semana, podemos capturar valores adicionais de IGS, observando até a curva atingir o valor obtido antes da manutenção. O HealthMon fornece uma solução que compreende aquisição de dados, processamento de sinal, transformações de matrizes, algoritmos de aprendizado não supervisionado e técnicas de otimização. Até o presente momento, o HealthMon é a primeira abordagem não supervisionada a executar o monitoramento de falhas da máquina, aplicando técnicas de decomposição de sinal com base no reconhecimento de tendências, incluindo apenas o uso de sensores simples e técnicas matemáticas para gerar o índice IGS. Além disso, outra vantagem, quando comparado com trabalhos relacionados, é a escalabilidade, uma vez que o HealthMon não está restrito a uma máquina específica, mas pode funcionar em diferentes máquinas vibrantes e/ou rotativas dos setores industriais.

HealthMon é uma abordagem que pertence ao contexto da Indústria 4.0. Assim, visa a agregar valor em termos de estratégias industriais no que tange a realização de manutenção com foco no gerenciamento de saúde de máquinas (KHAN et al., 2020; MERKT, 2019; CARVALHO et al., 2019); tendo como consequência a eficiência, prolongando a vida útil das máquinas ou permitindo que elas operem em suas melhores condições de operação, consumo eficiente de energia (TESCH DA SILVA et al., 2020).

7.1 Contribuições

O processo de validação do HealthMon se baseou em dados sintéticos e reais. Em ambos os casos, o HealthMon provou ser eficiente. Para validar com dados sintéticos, modelamos um motor de falha de indução para nos servir como entrada para os testes. Os resultados revelaram resultados encorajadores com diferentes cenários de falha que emularam sinais de vibração de IM. No painel do IGS, podemos verificar a evolução da falha, tanto em termos de gravidade (índice y), quanto de agressividade (ângulo tangente). Para avaliar com dados reais, usamos dados de vibração obtidos do MFS. Ambos os testes alcançaram resultados promissores. Estamos confiantes de que o IGS pode ser usado em muitos setores industriais em todo o mundo, trazendo benefícios para os administradores do setor. Aliás, esperamos, como contribuição à sociedade, que os produtos derivados do setor atinjam os consumidores finais com menor custo, uma vez que os processos industriais são beneficiados anteriormente.

As principais contribuições científicas do presente trabalho podem ser enumeradas da seguinte forma:

1. Índice global de saúde: o HealthMon propõe um novo índice de funcionamento da máquina, que oferece uma visão direta e intuitiva da degradação da máquina.
2. Baixa complexidade: o HealthMon é a primeira abordagem capaz de estimar o índice de integridade de uma máquina de uma maneira completamente não supervisionada, com base em sensores instalados na máquina considerada.
3. Vasta gama de aplicabilidade: o HealthMon funciona em qualquer tipo de máquina vibratória ou rotativa. Dessa forma, visa a atender aos requisitos da chamada indústria 4.0 em termos de aplicação a uma ampla variedade de setores industriais.

Além disso, igualmente constatamos os impactos no que tange aos ganhos para a sociedade. Visto que a indústria apresenta melhor eficiência na gestão de manutenção industrial, o resultado da redução de custos e o consequente aumento da margem de lucros permitem que, por uma questão de competitividade, as companhias possam repassar estas vantagens para seus clientes em forma de redução de preços.

7.2 Limitações e Trabalhos Futuros

Em termos de limitações, podemos considerar um fator relacionado ao tipo de dados processados envolvendo diferentes sensores. Para aplicações em larga escala, não foi possível validar a abordagem com outros tipos de variáveis; não foi medido usando sensores como pressão, temperatura ou ultrassom. Portanto, isso ainda é desconhecido. Obtivemos ainda resultados satisfatórios com os algoritmos CST e GA com dados de corrente do estator e vibração, Contudo muitos outros algoritmos podem ser testados. Em vista disso, como trabalho futuro, destacamos a possibilidade de avaliar outros algoritmos no módulo de otimização. Outra oportunidade para trabalhos futuros seria explorar diferentes técnicas para a decomposição de sinais obtidos pelos sensores.

REFERÊNCIAS

A DIMENSION REDUCTION TECHNIQUE FOR K-MEANS CLUSTERING ALGORITHM, 2012, India. Anais. IEEE, 2012. p. 531-535.

AL-DULAIMI, A. et al. NBLSTM: noisy and hybrid convolutional neural network and blstm-based deep architecture for remaining useful life estimation. Journal of Computing and Information Science in Engineering, v. 20, n. 2, 01 2020. 021012.

Alireza Gheitasi. Motors Fault Recognition Using Distributed Current Signature Analysis., [S.l.], p. 48, 2013.

AMIHAI, I. et al. Modeling machine health using gated recurrent units with entity embeddings and k-means clustering. In: IEEE 16TH INTERNATIONAL CONFERENCE ON INDUSTRIAL INFORMATICS, INDIN 2018, 2018, Canada. Proceedings. . . ASME, 2018.

AMINIKHANGHAHI, S.; COOK, D. J. A survey of methods for time series change point detection. Knowledge and Information Systems, [S.l.], v. 51, n. 2, p. 339-367, 2017.

AREMU, O. O. et al. Kullback-leibler divergence constructed health indicator for data-driven predictive maintenance of multi-sensor systems. IEEE International Conference on Industrial Informatics (INDIN), [S.l.], v. 2019-July, p. 1315-1320, 2019.

Arias Chao, Manuel; Kulkarni, Chetan; Goebel, Kai; Fink, O. Hybrid deep fault detection and isolation: combining deep neural networks and system performance models. ETH Zurich Research Collection, Switzerland, p. 12-19, 2019.

ARIZA, C. F. Manutenção preventiva de máquinas elétricas rotativas. [S.l.]: MC Grawhill do Brasil LTDA, 1977. v. 1. Ed.

AURÉLIO, M.; PACHECO, C. Algoritmos genéticos: princípios e aplicações. 2020.

AVANZATO, R. et al. Smile: smart monitoring iot learning ecosystem. International Journal on Advanced Science, Engineering and Information Technology, Italy, n. 1, p. 413-419, 2020.

AZEEM, N. et al. Experimental condition monitoring for the detection of misaligned and cracked shafts by order analysis. Advances in Mechanical Engineering, [S.l.], v. 11, n. 5, p. 168781401985130, 2019.

BANKOVIC, Z. et al. Proceedings of the third international workshop on hybrid artificial intelligence systems (hais'08). , [S.l.], v. 5271/2008, n. June 2014, 2008.

BHASIN, H.; BHATIA, S. Application of genetic algorithms in machine learning. International Journal of Computer Science and Information Technologies, India, v. 2, n. 5, p. 2412-2415, 2011.

BRESSER-PEREIRA, L. C. Desenvolvimento, progresso e crescimento econômico. Lua Nova, São Paulo, v. 1, n. 93, p. 33-60, 2014.

CAMPOS, J. et al. Arrowhead framework services for condition monitoring and maintenance based on the open source approach. 2019 6th International Conference on Control, Decision and Information Technologies, CoDIT 2019, [S.l.], p. 697-702, 2019.

CARVALHO, T. P. et al. A systematic literature review of machine learning methods applied to predictive maintenance. *Computers and Industrial Engineering*, Brazil, v. 137, n. August, p. 106024, 2019.

CHAN, J. O. An architecture for big data analytics. , United States, v. 13, n. 2, p. 1–14, 2013.
CHESWORTH, D.; BENG, D. C. Industry 4.0 techniques as a maintenance strategy (a review paper). , [S.l.], n. January, p. 0-8, 2018.

CHOUDHARY, P. K.; DUBEY, S. P. Energy efficient operation of induction motor drives: economic and environmental analysis in cement manufacturing. *Environmental Progress and Sustainable Energy*, [S.l.], v. 38, n. 2, p. 672-679, 2019.

Da Silva, M. G.; SELLITTO, M. A. Impactos da automação em sistemas produtivos: análise com apoio da árvore da realidade atual. *Revista Gestão Industrial*, BRAZIL, v. 6, n. 1, 2010.

de Pinho, G. L. G.; Wojichowski, G. S.; Crovato, C. D. P. Tool for power quality assessment of motor fed by variable speed electric drivers. In: INTERNATIONAL CONFERENCE ON HARMONICS AND QUALITY OF POWER (ICHQP), 2016., 2016. Anais. . . [S.l.: s.n.], 2016. p. 109-114.

DERIGENT, W.; CARDIN, O.; TRENTESAUX, D. Industry 4.0: contributions of holonic manufacturing control architectures and future challenges. *Journal of Intelligent Manufacturing*, [S.l.], 2020.

DHILLON, B. S. *Engineering maintenance: a modern approach*. EUA: CRC Press, 2002. 1–224 p.

DIEZ-OLIVAN, A. et al. Data fusion and machine learning for industrial prognosis: trends and perspectives towards industry 4.0. *Information Fusion*, Spain, v. 50, n. September 2018, p. 92–111, 2019.

DING, C.; HE, X. K -means clustering via principal component analysis . , [S.l.], p. 29, 2004.

DIVYA, K. S.; BHARGAVI, P.; JYOTHI, S. Machine learning algorithms in big data analytics. *International Journal of Computer Sciences and Engineering*, [S.l.], v. 6, n. 1, p. 63-70, 2018.

DONATO, H.; DONATO, M. Stages for undertaking a systematic review. *Acta Medica Portuguesa*, Portugal, v. 32, n. 3, p. 227-235, 2019.

DOYLE, F. The impact of control technology [publication activities]. *IEEE Control Systems Magazine*, Spain, v. 31, n. 5, p. 26-27, 2011.

EHLERS, R. S. Análise de séries temporais. Laboratório de Estatística e Geoinformação. Universidade Federal do Paraná, Curitiba, Brasil, 2007.

EL, M.; BENBOUZID, H.; MEMBER, S. A review of induction motors signature analysis as a medium for faults detection. , [S.l.], v. 47, n. 5, p. 984-993, 2000.

ELETROBRAS; PROCEL- INFO. Pesquisa de posse de equipamentos e hábitos de uso - ano base 2005. classe industrial - alta tensão - brasil. [S.l.: s.n.], 2008.

FAHIM, H. Comparing machine learning methods on concept drift detection for predictive maintenance. , United Kingdom, n. c, p. 1–16, 2013.

FELIX, F.; FUENTES, E. Metodologia para inovacao da gestao de manutencao industrial. 2006. 192 p. Dissertação (Mestrado em Ciência da Computação) — , 2006.

Fosso Wamba, S. et al. How 'big data' can make big impact: findings from a systematic review and a longitudinal case study. *International Journal of Production Economics*, [S.l.], v. 165, n. January 2018, p. 234–246, 2015.

GERRIKAGOITIA, J. K. et al. Digital manufacturing platforms in the industry 4.0 from private and public perspectives. *Applied Sciences*, Spain, v. 9, n. 14, p. 2934, 2019.

Goldreich, O. et al. Testing monotonicity. In: ANNUAL SYMPOSIUM ON FOUNDATIONS OF COMPUTER SCIENCE (CAT. NO.98CB36280), 39., 1998.

Proceedings. . . COMBINATORICA, 1998. p. 426-435.

GUPTA, Y. B. S.; RAO, S. S. Experimental evaluation of direct torque-controlled 3-phase induction motor under inverter faults. *International Journal of Electronics*, [S.l.], v. 00, n. 00, p. 1–21, 2019.

Heiner Lasi. Hans Georg Kemper. Peter Feltke. Thomas Feld. Michael Hoffmann. *Industry 4.0 in business & information system engineering*. *Business& Information System Engineering*, India, v. 6, n. 4, p. 239–242, 2014.

HUANG, G. et al. Semi-supervised and unsupervised extreme learning machines. *IEEE Transactions on Cybernetics*, [S.l.], v. 44, n. 12, p. 2405–2417, 2014.

ISHIBUCHI, H.; MURATA, T. A multi-objective genetic local search algorithm and its application to flowshop scheduling. *IEEE Transactions on Systems, Man and Cybernetics Part C: Applications and Reviews*, USA, v. 28, n. 3, p. 392–403, 1998.

J. Rangel-Magdaleno, J. d. et al. Novel methodology for online half-broken-bar detection on induction motors. *IEEE Transactions on Instrumentation and Measurement*, [S.l.], v. 58, n. 5, p. 1690–1698, May 2009.

JAIN, A. K. Data clustering: 50 years beyond k-means. *Pattern Recognition Letters*, [S.l.], v. 31, n. 8, p. 651-666, 2010.

JAVADI, A. A.; FARMANI, R.; TAN, T. P. A hybrid intelligent genetic algorithm. *Advanced Engineering Informatics*, Devon, v. 19, n. 4, p. 255-262, 2005.

KANKAR, P. K.; SHARMA, S. C.; HARSHA, S. P. Fault diagnosis of ball bearings using machine learning methods. *Expert Systems with Applications*, [S.l.], v. 38, n. 3, p. 1876–1886, 2011.

KEYUR K PATEL, S. M. P. P. S. A. P. Internet of things-iot definition articl. *Ijesc*, [S.l.], v. 6, n. 5, p. 10, 2016. 110

KHAN, A.; TUROWSKI, K. A perspective on industry 4.0: from challenges to opportunities in production systems. IoTBD 2016 - Proceedings of the International Conference on Internet of Things and Big Data, Germany, n. IoTBD, p. 441–448, 2016.

KHAN, W. Z. et al. Industrial internet of things: recent advances, enabling technologies and open challenges. Computers and Electrical Engineering, [S.l.], v. 81, p. 106522, 2020.

KOTHAMASU, R.; HUANG, S.; VERDUIN, W. Handbook of maintenance management and engineering. [S.l.]: Springer, 2009. v. 1. Ed.

KOTSIANTIS., S. B. Supervised machine learning: a review of classification techniques. University of Peloponnese, [S.l.], v. 237, n. 1, p. 1–8, 2007.

LAFRAIA, J. Manual de confiabilidade, manutenibilidade e disponibilidade. [S.l.]: Qualitymark R, 2001. v. 1. Ed.

LEE, J.; BAGHERI, B.; KAO, H. A. A cyber-physical systems architecture for industry 4.0-based manufacturing systems. Manufacturing Letters, United States, v. 3, p. 18–23, 2015.

LEE, J. et al. Recent advances and trends in predictive manufacturing systems in big data environment. Manufacturing Letters, United States, v. 1, n. 1, p. 38–41, 2013.

LI, M. et al. Anomaly detection of wind turbines based on deep small-world neural network. Applied Sciences (Switzerland), China, v. 10, n. 4, 2020.

LI, P. et al. A novel scalable method for machine degradation assessment using deep convolutional neural network. Measurement: Journal of the International Measurement Confederation, USA, v. 151, p. 107106, 2020.

LORENZ, R. D. et al. Motion control with induction motors. , [S.l.], v. 82, n. 8, 1994.

LUGER, G. F. Artificial intelligence. [S.l.]: Person Education do Brasil LTDA, 2013. v. 6. Ed. MA, S. et al. Lightweight deep residual cnn for fault diagnosis of rotating machinery based on depthwise separable convolutions. IEEE Access, [S.l.], v. 7, p. 57023–57036, 2019.

MANYIKA, J. et al. Big data: the next frontier for innovation, competition and productivity. McKinsey Global Institute, [S.l.], n. June, p. 156, 2011.

MASULLI, F.; ROVETTA, S. Clustering high-dimensional data. Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), [S.l.], v. 7627, n. 1, p. 1–13, 2015.

MEHALA, N.; DAHIYA, R. Motor Current Signature Analysis and its Applications in Induction. International Journal of systems applications, [S.l.], v. 2, n. 1, p. 29–35, 2007.

MERKT, O. On the use of predictive models for improving the quality of industrial maintenance: an analytical literature review of maintenance strategies. Proceedings of the 2019 Federated Conference on Computer Science and Information Systems, FedCSIS 2019, [S.l.], v. 18, p. 693–704, 2019.

MIGON, H. Análise de séries temporais. Disponível em: . Acesso em: 03 maio 2019.

MILJKOVIC, D. Brief review of motor current signature analysis. IEEE Industry Applications Magazine, [S.l.], v. 5, n. 1, p. 14–26, 2015.

MORETTIN, P. A.; CASTRO TOLOI, C. M. de. Modelos para previsão de séries temporais. Rio de Janeiro, Brasil: Instituto de matematica pura e aplicada, 1981. v. 1. N., S. P. The industrial revolution in world history. , [S.l.], v. 4, p. 330, 2018.

NEVES, C. et al. Os dez maiores desafios da automação industrial: as perspectivas para o futuro. II Congresso de Pesquisa e Inovação da Rede Norte NOrdeste de Educação Tecnológica, [S.l.], n. 1, 2007.

NOWLAN F S ; HEAP, H. F. Reliability-centered maintenance. [S.l.]: NATIONAL TECHNICAL INFORMATION SERVICE, 1978. v. 1. Ed. OWENS, A. R. Trends in digital instrumentation. Electronics and Power, [S.l.], v. 18, p. 116–120, 2018.

OZGUR, A. Supervised and unsupervised machine learning techniques for text document

categorization. 2015. Tese (Doutorado em Ciência da Computação) — , 2015. (January 2004).

PRESENTO. Framework to scale industry 4.0 predictive maintenance. , [S.l.], 2018.

R. B. Cleveland, W. S. Cleveland, J.E. McRae; TERPENNING, I. STL: a seasonal-trend decomposition procedure based on loess. *journal of official statistics*. 1990. 3–73 p. v. 6.

RAN, Y. et al. A survey of predictive maintenance: systems, purposes and approaches. , [S.l.], v. XX, p. 1–36, 2019.

RÖGNVALDSSON, T. et al. Self-monitoring for maintenance of vehicle fleets. [S.l.: s.n.], 2018. 344–384 p. v. 32, n. 2.

ROH, Y.; HEO, G.; WHANG, S. E. A survey on data collection for machine learning: a big data - ai integration perspective. , [S.l.], p. 1–19, 2018.

RUSSELL, S. J.; NORVIG, P. Artificial intelligence. [S.l.]: Elsevier Editora Ltda, 2004. v. 8. Ed.

SAIDI, L. et al. Wind turbine high-speed shaft bearings health prognosis through a spectral kurtosis-derived indices and svr. *Applied Acoustics*, EUA, v. 120, p. 1 – 8, 2017.

SANTOS, P.; MAUDES, J.; BUSTILLO, A. Identifying maximum imbalance in datasets for fault diagnosis of gearboxes. *Journal of Intelligent Manufacturing*, [S.l.], v. 29, n. 2, p. 333–351, 2018.

SATHYA, R.; ABRAHAM, A. Comparison of supervised and unsupervised learning algorithms for pattern classification. *International Journal of Advanced Research in Artificial Intelligence*, India, v. 2, n. 2, p. 34–38, 2013.

SHAPIRO, J. Genetic algorithms in machine learning. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, USA, v. 2049 LNAI, p. 146–168, 2001.

SHI, H.; WORDEN, K.; CROSS, E. J. A cointegration approach for heteroscedastic data based on a time series decomposition: an application to structural health monitoring. *Mechanical Systems and Signal Processing*, United Kingdom, v. 120, p. 16–31, 2019.

SINGH, A. et al. A review of induction motor fault modeling. *Electric Power Systems Research*, [S.l.], v. 133, p. 191–197, 2016.

SINGH, K. J.; KAPOOR, D. S. Create your own internet of things: a survey of iot platforms. *IEEE Consumer Electronics Magazine*, [S.l.], v. 6, n. 2, p. 57–68, 2017.

SINGHAL, A.; KHANDEKAR, M. A. Bearing fault detection in induction motor using motor current signature analysis. *International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering*, India, v. 2, n. 7, p. 3258–3264, 2013.

SLACK, N.; CHAMBERS, S.; JOHNSTON, R. *Administração da produção*. [S.l.]: Editora Atlas S. A., 2009. v. 3. Ed.

SÖDERHOLM, P. Maintenance and continuous improvement of complex systems linking stakeholder requirements to the use of built-in test systems. 2005. 302 p. Tese (Doutorado em Ciência da Computação) — Luleå University of Technology, 2005.

SONI, D. Supervised vs. unsupervised learning. [S.l.: s.n.], 2019. Disponível em: . Acesso em: 24 nov. 2019.

SONI, D. Supervised vs unsupervised learning: key differences. [S.l.: s.n.], 2019. Disponível em: . Acesso em: 24 nov. 2019.

SQI SPECTRAL QUEST, I. *Simuladores de falhas de máquinas*. 2020.

STETCO, A. et al. Machine learning methods for wind turbine condition monitoring: a review. *Renewable Energy*, United Kingdom, v. 133, p. 620–635, 2019.

T. Stock, G. S. *Opportunities_and_challenges_for_constru.pdf*. *Procedia*, [S.l.], p. 536–541, 2016.

TERRA, J. et al. Faults Detection and Remote Monitoring System for Induction Motors using MCSA Technique. *Ie.Fing.Edu.Uy*, [S.l.], 2005.

Tesch da Silva, F. S. et al. Looking at energy through the lens of industry 4.0: a systematic literature review of concerns and challenges. *Computers and Industrial Engineering*, [S.l.], v. 143, n. June 2019, p. 106426, 2020.

THOMSON, W.; GILMORE, R. 13 Motor current signature analysis to detect faults in induction motor drives-fundamentals, Data interpretation, and industrial case histories. *Proceedings of 32nd Turbo . . .*, [S.l.], n. 1987, p. 145–156, 2003.

Vinoth Kumar, K.; Suresh Kumar, S.; Immanuel Selvakumar, A. A review of voltage and current signature diagnosis in industrial drives. *International Journal of Power Electronics and Drive Systems, India*, v. 1, n. 1, p. 75–82, 2011.

VISHNU, T. V. et al. Recurrent neural networks for online remaining useful life estimation in ion mill etching system. *Proceedings of the Annual Conference of the Prognostics and Health Management Society, PHM*, [S.l.], n. September, 2018.

WAKIRU, J. M. et al. A review on lubricant condition monitoring information analysis for maintenance decision support. *Mechanical Systems and Signal Processing*, [S.l.], v. 118, p. 108–132, 2019.

WANG, B. et al. Recurrent convolutional neural network: a new framework for remaining useful life prediction of machinery. *Neurocomputing*, [S.l.], v. 379, p. 117–129, 2020.

WANG, H. et al. Metronet: a novel data-driven fault diagnosis method applied to wheel bearings of metro trains. *Proceedings of 2019 IEEE 4th Advanced Information Technology, Electronic and Automation Control Conference, IAEAC 2019*, [S.l.], n. Iaeac, p. 2540–2544, 2019.

WEG/SEBRAE. Eficiência energética para pequenos negócios: motores elétricos. [S.l.: s.n.], 2016. YAROWSKY, D. Unsupervised word sense disambiguation rivaling supervised

methods. , USA, p. 189–196, 1995.

YU, W.; KIM, I. Y.; MECHEFSKE, C. Remaining useful life estimation using a bidirectional recurrent neural network based autoencoder scheme. *Mechanical Systems and Signal Processing*, [S.l.], v. 129, p. 764–780, 2019.

ZHANG, P. et al. A survey of condition monitoring and protection methods for medium-voltage induction motors. *IEEE Transactions on Industry Applications*, [S.l.], v. 47, n. 1, p. 34–46, 2011.

ZHANG, W. et al. Aesgru: an attention-based temporal correlation approach for end-to-end machine health perception. *IEEE Access*, [S.l.], v. 7, n. D1, p. 141487–141497, 2019.

ZHAO, Z.; LIU, H. Spectral feature selection for supervised and unsupervised learning. *ACM International Conference Proceeding Series*, USA, v. 227, p. 1151–1157, 2007.

ZHONG, R. Y. et al. Intelligent manufacturing in the context of industry 4.0: a review. *Engineering*, Germany, v. 3, p. 616–630, 2017.

ZSCHECH, P. et al. Prognostic model development with missing labels: a condition-based maintenance approach using machine learning. *Business and Information Systems Engineering*, [S.l.], v. 61, n. 3, p. 327–343, 2019.

ZYABKINA, O. et al. Classification and identification of anomalies in time series of power quality measurements. *IEEE PES Innovative Smart Grid Technologies Conference Europe*, [S.l.], p. 1–6, 2017.