



Programa de Pós-Graduação em  
**Computação Aplicada**

---

**Doutorado Acadêmico**

Tiago Zonta

*Predictive Maintenance & Schedule (PdMS): um novo processo de fabricação que integra manutenção preditiva e programação de produção*

São Leopoldo, 2022

Tiago Zonta

***PREDICTIVE MAINTENANCE & SCHEDULE (PDMS): UM NOVO PROCESSO DE FABRICAÇÃO QUE INTEGRA MANUTENÇÃO PREDITIVA E PROGRAMAÇÃO DE PRODUÇÃO***

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

Orientador:  
Prof. Cristiano André da Costa, PhD

São Leopoldo  
2022

Z87p

Zonta, Tiago.

*Predictive Maintenance & Schedule (PdMS)*: um novo processo de fabricação que integra manutenção preditiva e programação de produção / Tiago Zonta – 2022.

123 f. : il. color. ; 30 cm.

Tese (doutorado) – Universidade do Vale do Rio dos Sinos, Programa de Pós-Graduação em Computação Aplicada, São Leopoldo, 2022.

“Orientador: Prof. Cristiano André da Costa, PhD.”

1. Indústria 4.0. 2. Manutenção preditiva. 3. Computação Aplicada. 4. Aprendizado do computador. I. Título.

CDU 004

(Esta folha serve somente para guardar o lugar da verdadeira folha de aprovação, que é obtida após a defesa do trabalho. Este item é obrigatório, exceto no caso de TCCs.)

A minha família, amigos e mestres que contribuíram desde de minha alfabetização.

*"Quando o sonho de um professor se realiza, até ele se surpreende."*  
— EU MESMO

## AGRADECIMENTOS

Agradecer é sempre complicado pois, de uma forma ou de outra, muitas pessoas contribuem durante todo o processo. Mas inicio agradecendo minha família. Meus pais Jesué Zonta, Inês Sirena Zonta e minhas meninas Maria Cecília e Juliana Sá Zonta, motivadores incansáveis para que a busca do conhecimento fosse constante. Agradeço ao professor Itamar Leite de Oliveira que sempre me motivou a seguir na carreira acadêmica. A caminhada foi mais longa do que ele imaginava, mas aqui estou, buscando o título de doutor que poderia ter vindo há muito tempo. De qualquer forma, se eu tive a caminhada alongada, como professor, consegui várias conquistas e resultados importantes e, um deles, agradeço ao meu orientando e amigo Felipe André Zeiser. Assim como o professor Itamar sempre falava, "o aprendiz tem que superar o mestre senão não faz sentido".

Queria agradecer, também, à Unisinos e ao PPGCA por me aceitarem como aluno de doutorado. Queria lembrar das primeiras conversas com o professor Jose Vicente Canto dos Santos que manteve meu foco na construção de um projeto baseado em apenas uma ideia que eu tinha. Hoje entendo porque a entrevista foi tão complicada. A minha noção de pesquisa estava longe de algo que poderia ser aceito em um programa de doutorado. Por isso, fica o agradecimento. Acredito que o PPGCA deva abrir mais portas para profissionais iguais ao meu caso, que estão afastados há muito tempo da pesquisa, mas tem vontade e desejo de aprender. Não poderia esquecer da Unoesc, e amigos professores dos colegiados de Sistemas de Informação e Engenharia de Computação pelo apoio para busca de mais uma conquista.

Por fim, gostaria de agradecer aos professores do programa, especialmente meu orientador Cristiano André da Costa, mais um mestre a ser admirado juntamente com os meus parceiros de artigo, os professores Gabriel Ramos, Rafael Kunst e Rodrigo da Rosa Righi. Com eles descobri que meu Inglês, e até mesmo Português, não são muito bons. Brincadeiras à parte, saibam que vocês tem um ótimo programa, vocês são um exemplo de que a pesquisa pode ser feita em instituições privadas, mesmo tendo tantas atribuições em paralelo. Queria parabenizar a estrutura exemplar do programa e da instituição. Infelizmente não pude mais usufruir do ambiente neste último ano e nem ver mais a turma dos Consagrados do laboratório, mas, com certeza, o processo do doutorado vai deixar muito aprendizado, amigos e história para eu continuar minha caminhada como professor, ou, vai saber o que o futuro reserva.

## RESUMO

**CONTEXTO:** A Indústria 4.0 (I4.0) fornece conectividade, volume de dados, novos dispositivos, miniaturização, redução de estoque, personalização e produção controlada. Nesta nova era, a customização da produção e a disponibilidade de dados são essenciais para gerar informações que permitam a tomada de decisões. A possibilidade de prever a necessidade de manutenção no futuro e utilizar essa informação para outros processos é um dos desafios do processo de fabricação. Neste contexto, a proposta desta tese transcende o fato específico da aplicação da manutenção preditiva (PdM) e sugere formas de integração de processos, focando nos agendamentos de manutenção e produção. **OBJETIVO:** O objetivo é criar o *Predictive Maintenance & Schedule* (PdMS) para integrar os cronogramas de manutenção e produção de forma preditiva. A cada leitura dos dados de sensores e informações operacionais, é estimada a vida útil remanescente (RUL) das máquinas, decidindo se a máquina fará parte do processo de produção ou não. Reforçando que, este novo cenário da indústria, permite que a aplicação da computação, juntamente com a inteligência artificial e computação distribuída, se torne mais efetiva nos processos de fabricação. Com a criação do PdMS, a ideia é reduzir o tempo de inatividade, melhorar a comunicação entre os setores de manutenção e produção e permitir uma integração futura com os setores de armazenamento e logística. **METODOLOGIA:** O processo de criação do PdMS foi dividido em duas fases: (i) relacionada à PdM, que descreve o processo utilizado para melhorar o prognóstico do RUL, com ciência de dados, criação e combinação de índices de degradação, utilizando padrões de similaridade e aplicação de filtros de suavização Savitzky-Golay e Kalman; (ii) relacionada ao problema de escalonamento e à integração com os resultados gerados pela PdM, que descreve a geração da agenda, verificação da manutenção e a geração de gráficos para controle e acompanhamento do cronograma da produção. Para avaliar o PdMS, foi utilizado um conjunto de dados de manutenção preditiva de amostra fornecido pela Microsoft. Foram buscado dados com características que pudessem contribuir com a ideia de definição de uma abordagem que estimule a adoção da manutenção preditiva em fábricas que já possuem telemetria em seus ativos, mas ainda realizam manutenção corretiva ou preventiva. **RESULTADOS:** Para avaliação dos resultados, foram comparados vários modelos baseados em Redes Neurais Profundas (DNN) e Redes Neurais Recorrentes (RNN). Foram utilizadas *Regression Random Forest* (RRF) para auxiliar com a seleção de características e foi realizada a comparação do desempenho da predição com *Convolutional Neural Network* (CNN), *Long short term memory* (LSTM), *Gated Recurrent Unit* (GRU), redes recorrentes e rede *Deep Feed Forward* (DFF). Os resultados foram avaliados de forma visual e por critérios baseados nos erros: *Root Mean Square Error* (RMSE), *Mean Absolute Error* (MAE), *Mean Squared Error* (MSE), coeficiente de determinação  $R^2$  e *Mean Absolute Percentage Error* (MAPE). Os melhores resultados apresentaram

$RMSE = 8.789$ ,  $MSE = 77.253$ ,  $MAE = 2.262$ ,  $R^2 = 0.848$ ,  $MAPE = 92.22$ .

**CONCLUSÃO:** Como contribuição, este trabalho traz uma revisão sistemática com a proposta de uma taxonomia, identificação de desafios e questões abertas referente a I4.0 com foco na PdM. A partir dos desafios apresentados foi criado o modelo PdMS que apresentou as decisões, estratégias e arquitetura que resultaram na predição de falhas em dados ruidosos com antecipação de cinco dias no conjunto de dados utilizado para o experimento, possibilitando assim, a simulação da integração pretendida.

**Palavras-chave:** Indústria 4.0. Manutenção Preditiva. Tempo de Vida Útil Remanescente. Problemas de Escalonamento. Aprendizado de Máquina.



## ABSTRACT

**CONTEXT:** Industry 4.0 (I4.0) provides connectivity, data volume, new devices, miniaturization, inventory reduction, personalization, and controlled production. In this new era, production customization and data availability are essential to generate information that allows decision-making. The possibility of predicting the need for maintenance in the future and using this information for other processes is one of the manufacturing process challenges. In this context, this thesis proposal transcends the specific fact of applying predictive maintenance (PdM) and suggests ways to integrate processes, focusing on maintenance and production schedules. **OBJECTIVE:** The objective is to create the Predictive Maintenance & Schedule (PdMS) to integrate maintenance and production schedules in a predictive way. At each sensor data reading and operational information, the machine's remaining useful life (RUL) is predicted, deciding whether the machine will be part of the production process or not. Reinforcing that, this new Industry scenario allows Computing Applications, together with artificial intelligence and distributed computing, to become more effective in manufacturing processes. With the PdMS creation, the idea is to reduce downtime, improve communication between the maintenance and production sectors and allow future integration with the production, storage, and logistics sectors. **METHODOLOGY:** The PdMS creation process was divided into two phases: (i) related to PdM, which describes to create and combine degradation indices using similarity patterns and application Savitzky-Golay and Kalman smoothing filters that allow noisy data to identify time-based failures; (ii) related to the scheduling problem and the integration with the results generated by the PdM, which describes the schedule generation, maintenance verification and graphics generation to control and follow up the production schedule. To evaluate the PdMS, a sample predictive maintenance dataset provided by Microsoft was used. We searched for data with characteristics that could contribute to the idea of defining an approach that encourages the adoption of predictive maintenance in factories that already have telemetry in their assets but still perform corrective or preventive maintenance. **RESULTS:** To evaluate the results, we compared several models based on Deep Neural Networks (DNN) and Recurrent Neural Networks (RNN). Regression Random Forest (RRF) was used to contribute to feature selection and was performed a comparison between Convolutional Neural Network (CNN), Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU), Recurrent Networks, and Deep Feed Forward (DFE) network. The results were visually evaluated and by criteria based on errors: Root Mean Square Error (RMSE), Mean Absolute Error (MAE) and Mean Squared Error (MSE), Determination Coefficient  $R^2$  and Mean Absolute Percentage Error (MAPE). The best results presents  $RMSE = 8.789$ ,  $MSE = 77.253$ ,  $MAE = 2.262$ ,  $R^2 = 0.848$ ,  $MAPE = 92.22$ . **CONCLUSION:** As a contribution, this work brings a systematic review with a taxonomy proposal, challenges identification, and open questions regarding I4.0 with a focus on PdM. The PdMS model was created from the challenges presented, which presented the decisions, strategies, and architecture that resulted in the prediction of failures in noisy data with five-day anticipation in the data set used for the experiment, thus enabling the intended outcome integration simulation.

**Keywords:** Industry 4.0. Predictive Maintenance. Remaining Useful Life. Scheduling Problems. Machine Learning.

## LISTA DE FIGURAS

Figura 1 –	Tarefas do PHM. . . . .	27
Figura 2 –	Propagação da degradação e falha do componente. . . . .	28
Figura 3 –	Perfil de deterioração com período determinado para o RUL. . . . .	29
Figura 4 –	5C - Arquitetura de CPS. . . . .	31
Figura 5 –	Pilha de tecnologias para suporte à IoT. . . . .	32
Figura 6 –	Metodologia para criação de um inovação sistemática. . . . .	35
Figura 7 –	String de pesquisa. . . . .	39
Figura 8 –	Triagem de pesquisa. . . . .	41
Figura 9 –	Distribuição das publicações por editor e tipo. . . . .	41
Figura 10 –	Distribuição das publicações por ano. . . . .	42
Figura 11 –	Metodologia criada para gerar a taxonomia. . . . .	49
Figura 12 –	Mapas gerados com termos relacionados diretamente a I4.0 com foco em PdM. (a) Mapa de conceitos relacionados. (b) Mapa de calor. . . . .	52
Figura 13 –	Mapeamento no VOSviewer do <i>cluster</i> de PdM. . . . .	53
Figura 14 –	Mapeamento no VOSviewer do <i>cluster</i> da IoT. . . . .	53
Figura 15 –	Taxonomia - Monitoramento no contexto da I4.0. . . . .	55
Figura 16 –	Cenários analisados para criação do PdMS. . . . .	63
Figura 17 –	Modelo PdMS. Visão geral do fluxo da aplicação, demonstrado de forma conceitual. . . . .	67
Figura 18 –	Entrada, pré-processamento e normalização dos dados. . . . .	68
Figura 19 –	Uso de janelas de atraso para modelar séries temporais e realizar a predição. . . . .	68
Figura 20 –	Visão geral da arquitetura para conhecimento do domínio. . . . .	69
Figura 21 –	Formas de estimar o RUL baseado nos dados disponíveis. . . . .	70
Figura 22 –	Exemplo de saída com previsão de manutenção. . . . .	71
Figura 23 –	Exemplo de classificação supervisionada realizada no <i>Azure Machine Learning Studio</i> . . . . .	74
Figura 24 –	Metodologia de análise visual dos dados. . . . .	77
Figura 25 –	Metodologia para gerar o RUL, DI e HI em um conjunto de dados ruidoso sem degradação expressiva. . . . .	79
Figura 26 –	Gráfico da regressão linear e logística utilizada para criar o HI. Característica similar a ideia da aplicação do <i>Piecewise</i> de (HEIMES, 2008). . . . .	81
Figura 27 –	Modelo PdMS. Adequação do fluxo da Figura 17, demonstrado de forma conceitual o aumento das hipóteses metodológicas. . . . .	84
Figura 28 –	Curva ROC do aprendizado de classificação supervisionada utilizando LSTM. . . . .	87
Figura 29 –	Resultado da PdM da máquina 75 utilizando CNN sem a criação dos índices de degradação. . . . .	88
Figura 30 –	Correlação da telemetria da máquina 75. . . . .	88
Figura 31 –	Análise de séries temporais e tendências para telemetria de cada sensor da máquina 75. Os primeiros quatro gráficos mostram a telemetria de todos os sensores, enquanto os quatro últimos apresentam apenas a média. . . . .	89
Figura 32 –	Histograma dos dados da telemetria e do RUL. . . . .	90
Figura 33 –	Resultado da PdM da máquina 75 utilizando CNN com a criação do DI. . . . .	90
Figura 34 –	Resultado da PdM da máquina 75 utilizando CNN com a criação do HI. . . . .	91
Figura 35 –	Arquitetura com melhor resultado aplicada à <i>Regression Random Forest</i> (RRF), <i>Deep Neural Networks</i> (DNN) e <i>Recurrent Neural Network</i> (RNN). . . . .	92

Figura 36 – Resultado da PdM da máquina 75 utilizando CNN combinando os índices DI e HI. . . . .	93
Figura 37 – Comparação de sinais sem e com filtros da média diária de rotação dos dados de teste da máquina 50. . . . .	94
Figura 38 – Comparação de resultados sem aplicação de filtros de suavização em telemetria. (a) RMSE. (b) MSE. (c) MAE. (d) $R^2$ . (e) MAPE. . . . .	96
Figura 39 – Comparação de resultados usando o filtro de Kalman na telemetria. (a) RMSE. (b) MSE. (c) MAE. (d) $R^2$ . (e) MAPE. . . . .	97
Figura 40 – Comparação de resultados usando o filtro Savitzky-Golay na telemetria. (a) RMSE. (b) MSE. (c) MAE. (d) $R^2$ . (e) MAPE. . . . .	98
Figura 41 – Comparação da predição do RUL nos dados de teste da máquina 75 usando CNN e LSTM com filtro de Savitzky-Golay. . . . .	99
Figura 42 – Resultado do escalonamento para a semana 6 do ano de 5 máquinas sendo uma retornou como necessidade de manutenção pela PdM. Gráfico de Gantt máquina x tarefa . . . . .	101
Figura 43 – Resultado do escalonamento para a semana 6 do ano de 5 máquinas sendo uma retornou como necessidade de manutenção pela PdM. Gráfico de Gantt tarefa x máquina . . . . .	102

## LISTA DE TABELAS

Tabela 1 –	Comparação da fábrica atual com a indústria 4.0 . . . . .	23
Tabela 2 –	Questões de Pesquisa . . . . .	39
Tabela 3 –	Critérios de avaliação . . . . .	40
Tabela 4 –	Classificações da predição. . . . .	42
Tabela 5 –	Aplicações com RNAs, ML e soluções algorítmicas. . . . .	45
Tabela 6 –	Termos importantes para o prognóstico. . . . .	48
Tabela 7 –	Arquivo de configuração de termos de co-ocorrência . . . . .	50
Tabela 8 –	Termos-chave para gerar uma raiz para o Indústria 4.0 com foco em PdM .	50
Tabela 9 –	Termos-chave e <i>clusters</i> relacionados mapeados . . . . .	50
Tabela 10 –	Matriz para identificar o domínio da inovação. . . . .	65
Tabela 11 –	Notações no JSSP de produção e manutenção preditiva . . . . .	82
Tabela 12 –	Comparação do melhor e pior resultado de cada situação . . . . .	95
Tabela 13 –	Comparação das contribuições deste trabalho com as abordagens de PdM dos trabalhos relacionados . . . . .	100
Tabela 14 –	Comparação dos diferenciais deste trabalho com as abordagens de integração dos trabalhos relacionados . . . . .	102
Tabela 15 –	Artigos selecionados ordenados por ano. . . . .	116
Tabela 16 –	Modelos, métodos ou arquitetura. . . . .	118
Tabela 17 –	Comparação entre os trabalhos relacionados . . . . .	122

## LISTA DE SIGLAS

AE	Emissões Acústicas
ACM	<i>Association for Computing Machinery</i>
BP	<i>Backpropagation</i>
BPNN	<i>Back-propagation Neural Network</i>
CASE	<i>Conference on Automation Science and Engineering</i>
CBI	<i>Conference on Business Informatics</i>
CBM	Manutenção Baseada na Condição
CBPdM	Manutenção Preditiva Baseada em Condições
CI <sub>s</sub>	Indicadores de Condição de Vibração
CNN	<i>Convolutional Neural Network</i>
CPS	Sistemas Ciber-Físicos
C-MAPSS	<i>Commercial Modular Aero-Propulsion System Simulation</i>
CWTS	Centro de Estudos de Ciência e Tecnologia
DBN	<i>Deep Belief Network</i>
DFE	<i>Deep Feed Forward</i>
DL	<i>Deep Learning</i>
DI	Índice de Degradação
DNN	Redes Neurais Profundas
FFc	<i>Flexible Flow Shop</i>
FJc	<i>Flexible Job Shop</i>
FIS	<i>Factory Information System</i>
GRU	<i>Gated Recurrent Unit</i>
HI	Índice de Saúde
I4.0	<i>Indústria 4.0</i>
IA	Inteligência Artificial
ICE/ITMC	<i>International Conference on Engineering, Technology and Innovation</i>
IIoT	<i>Industrial Internet of Things</i>
IJCNN	<i>International Joint Conference on Neural Networks</i>
INDIN	<i>International Conference on Industrial Informatics</i>
IoT	Internet das Coisas
Jm	<i>Job-Shop</i>
JSSP	<i>Job Shop Scheduling Problem</i>
KCI <sub>s</sub>	<i>Key Condition Indices</i>

KNN	<i>k-Nearest Neighbors</i>
LSS	<i>Laser Sintering System</i>
LSTM	<i>Long short term memory</i>
M2M	<i>Machine to Machine</i>
MAE	<i>Mean Absolute Error</i>
MES	<i>Manufacturing Execution Systems</i>
ML	Aprendizado de Máquina ( <i>Machine Learning</i> )
MLE	<i>Maximum Likelihood Estimation</i>
MAPE	<i>Mean Absolute Percentage Error</i>
MQ	Questão Principal
MRL	Vida Residual Média
MVP	Produto Mínimo Viável
NPS	<i>Naval Propulsion Sys</i>
NSF	<i>National Science Foundation</i>
ODM	Massa de Detritos de Óleo
Om	<i>Open-Shop</i>
PCA	Análise de Componentes Principais
PCoE	<i>Prognostics Center of Excellence</i>
PdMS	<i>Predictive Maintenance &amp; Schedule</i>
PdM	<i>Predictive Maintenance</i>
PHM	<i>Prognostics and Systems Health Management</i>
PLA	<i>Poly lactide</i>
PRFs	<i>Parallel Random Forests</i>
PoF	<i>Physics-of-Failure</i>
PwC	PricewaterhouseCoopers
QFD	Desdobramento da Função Qualidade
RF	<i>Random Forest</i>
RMSE	<i>Root Mean Square Error</i>
RNAs	Redes Neurais Artificiais
RNN	Redes Neurais Recorrentes
ROC	<i>Receiver Operating Characteristic Curve</i>
RPaRT	<i>Recursive Partitioning and Regression Tree</i>
RRF	<i>Regression Random Forest</i>
RUL	<i>Remaining Useful Life</i>

SAMI	<i>International Symposium on Applied Machine Intelligence and Informatics</i>
SDA	<i>Stacked Denoising Autoencoder</i>
SQ	Subquestões
SLM	<i>Smart Local Moving</i>
SVR	<i>Support Vector Regression</i>
SVM	<i>Support Vector Machine</i>

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>17</b>
1.1	Motivação	19
1.2	Questão de Pesquisa	19
1.3	Contribuições científicas	20
1.4	Objetivos	20
1.4.1	Objetivos específicos	20
1.5	Organização do documento	21
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>22</b>
2.1	Indústria 4.0	22
2.2	Manutenção Preditiva	24
2.2.1	Problemas de qualidade de dados	25
2.2.2	Redes Neurais Profundas e Modelos de Regressão	26
2.3	<i>Prognostics and Health Management (PHM)</i>	26
2.3.1	<i>Remaining Useful Life (RUL)</i>	29
2.4	Sistemas Ciber-Físicos (CPS)	30
2.5	<i>Internet das Coisas (IoT)</i>	32
2.6	Problemas de escalonamento de produção	33
2.6.1	Classificação dos problemas de escalonamento	33
2.7	Matriz de inovação sistemática	35
2.8	Considerações finais	36
<b>3</b>	<b>TRABALHOS RELACIONADOS</b>	<b>38</b>
3.1	Manutenção Preditiva na I4.0: Uma Revisão Sistemática da Literatura	38
3.1.1	Questões de Pesquisa	38
3.1.2	Estratégia de pesquisa	39
3.1.3	Seleção dos Artigos	39
3.1.4	Resultados e Discussão	40
3.2	Trabalhos relacionados a integração da PdM com problemas de escalonamento	56
3.3	Oportunidades de pesquisa	58
3.4	Considerações finais	60
<b>4</b>	<b>MODELO PDMS</b>	<b>62</b>
4.1	Aplicação da metodologia da matriz de inovação sistemática	64
4.2	Decisões do projeto	66
4.2.1	Pré-processamento dos dados	66
4.2.2	Análise e modelagem das séries temporais	67
4.2.3	Estratégia para estudo dos dados, parametrização e avaliação de modelos ML	68
4.2.4	Avaliação da predição, integração com o escalonamento e saída desejada	69
4.3	Considerações finais	70
<b>5</b>	<b>MATERIAIS E MÉTODOS</b>	<b>72</b>
5.1	Busca e descrição do conjunto de dados	72
5.2	Modelagem dos dados e testes de aprendizado de classificação supervisionada	73



5.3	Escolha da forma de estimar o RUL e divisão do conjunto de dados . . . . .	75
5.4	Critérios de avaliação das características de degradação dos dados . . . . .	76
5.4.1	Estratégias para avaliação dos dados e séries temporais . . . . .	77
5.5	Proposta de metodologia para adequação do conjunto de dados . . . . .	78
5.6	Processo de integração das agendas de manutenção e produção . . . . .	81
5.7	Incremento do fluxo lógico do modelo PdMS . . . . .	82
5.8	Considerações finais . . . . .	83
<b>6</b>	<b>RESULTADOS E DISCUSSÃO</b>	<b>86</b>
6.1	Avaliações iniciais e análise visual dos resultados . . . . .	86
6.2	Criação de características de degradação baseado na similaridade do dados	89
6.3	Combinação dos índices baseados na similaridade dos dados e melhoria dos hiperparâmetros . . . . .	91
6.4	Testes comparativos com aplicação de filtros de suavização . . . . .	93
6.5	Modelagem do problema do escalonamento e integração com a PdM . . . . .	100
6.6	Considerações finais . . . . .	101
<b>7</b>	<b>CONCLUSÃO</b>	<b>104</b>
7.1	Publicações . . . . .	105
7.2	Trabalhos Futuros . . . . .	106
	<b>REFERÊNCIAS</b>	<b>108</b>
	<b>APÊNDICES</b>	<b>116</b>
A	Artigo selecionados na revisão sistemática . . . . .	116
B	Modelos, métodos ou arquiteturas . . . . .	118
C	Comparação com os trabalhos relacionados . . . . .	122

## 1 INTRODUÇÃO

Com os constantes efeitos e reflexos da revolução tecnológica e do desenvolvimento humano, o tempo parece cada vez mais escasso. A convergência entre processos industriais manuais para automatizados é necessária. Nesse sentido, nasceu o conceito da indústria 4.0 (I4.0), que se refere, justamente, à evolução e possibilidade de integração e comunicação de diferentes processos e tecnologias (LEE; AZAMFAR; SINGH, 2019). As mudanças nos ambientes de produção da I4.0 proporcionam maior disponibilidade de recursos motivada pela miniaturização de dispositivos e distribuição de informações. A customização de produtos e diminuição de estoques trazem o crescimento de soluções aplicadas no funcionamento constante de uma fábrica (ZHANG; YANG; WANG, 2019).

As demandas pela produtividade e diminuição de margens de lucro aumentaram a importância da manutenção. A preservação de um equipamento industrial em uso é a chave para diferenciais de produção (NIKOLAKIS et al., 2018). Embora os desafios de manutenção devam prevenir o *downtime*, a conexão com outros processos se torna um diferencial nos resultados. De acordo com o relatório de 2017, da PricewaterhouseCoopers (PwC), realizado em 280 empresas da Bélgica, Alemanha e Holanda, os custos de paralisação podem chegar a meio milhão de Euros por dia em receita perdida (HAARMAN; MULDER; VASSILIADIS, 2017).

Por este motivo, este trabalho está relacionado à confiabilidade e disponibilidade de recursos de forma inteligente e integrada. Para isso, foi analisado um cenário e proposto um modelo para aplicação da integração do agendamento de manutenção e produção. Este modelo foi baseado nos conceitos do *Prognostics and Systems Health Management* (PHM), *Predictive Maintenance* (PdM) para estimativa do *Remaining Useful Life* (RUL) das máquinas integrando com o problema de escalonamento da produção.

Durante o levantamento de trabalhos relacionados, foram identificadas diversas metodologias aplicadas a contextos específicos, sem a integração do RUL com o escalonamento de processos. Referente às soluções ligadas à PdM, é possível destacar análise da similaridade dos dados coletados nas máquinas e suas informações de operação para prever uma falha utilizando Inteligência Artificial (IA) (LIU et al., 2007; WANG et al., 2008; DUDEK, 2015; ZHENG et al., 2017; DONG; LI; SUN, 2017; BRUNEO; De Vita, 2019; LIANG et al., 2019; JIMENEZ-CORTADI et al., 2020; CAI et al., 2020). Os avanços na aplicação da IA, sensores e Internet das Coisas (IoT) potencializam a análise de dados do funcionamento das máquinas, permitindo identificar padrões que preveem problemas antes que aconteçam (XIA et al., 2020). Em relação aos problemas de agendamento e integração de manutenção, foram encontradas soluções que pressupõe que as máquinas não estão continuamente disponíveis (SCHMIDT, 2000; PINEDO, 2016). Em alguns casos, é considerado um índice de desgaste para cada tarefa, controlado por limites mínimos ou máximos (FITOURI et al., 2016; CUI et al., 2018). Outros exemplos consideram uma

categoria de manutenção denominada oportunista, que sincroniza a manutenção em espaços existentes na programação da produção (LEVRAT; THOMAS; IUNG, 2008; LI; WANG; LIN, 2021).

A contribuição deste trabalho é criar o *Predictive Maintenance & Schedule* (PdMS) a fim de integrar os processos de manutenção das máquinas, podendo prever o escalonamento da produção de forma inteligente. O estudo da integração das agendas de manutenção e produção é iniciado pela ideia de que a manutenção deva ser preditiva, e que, além de prever o desgaste de um ativo, também possa apontar um possível período de vida baseado no tempo. Essa característica vai de encontro com algumas práticas hoje utilizadas, principalmente em plantas fabris com algum tempo de uso, e que adotam a manutenção corretiva ou preventiva baseadas em manuais ou tempo de utilização do ativo previsto pelo fornecedor (SARKER et al., 2013).

O primeiro passo do trabalho foi a previsão do RUL usando telemetria em dados ruidosos sem informações de características técnicas de operação das máquinas. Para avaliar a proposta, foi utilizado um conjunto de dados disponibilizado pelo *Microsoft Azure Artificial Intelligence* (AZURE, 2020), com medições de telemetria de tensão, rotação, pressão e vibração a cada hora (ciclo) referente a um ano. É descrito um novo processo de avaliação, criação e combinação de índices de degradação. Neste processo é apresentada uma metodologia que verifica a qualidade dos dados baseado em Chen, Zhu e Lee (2013), que avalia e cria, para cada ciclo de telemetria, um Índice de Degradação (DI) combinado com o Índice de Saúde (HI) proposto por Wang et al. (2008). São usados padrões de similaridade, regressão linear e logística, filtros de suavização Savitzky–Golay e Kalman e função por partes (*Piecewise*), a fim de melhorar a estimativa do RUL.

Depois de aplicar a metodologia, com os dados gerados, foi possível comparar os resultados da PdM baseados em arquiteturas de Redes Neurais Profundas (DNN) e Redes Neurais Recorrentes (RNN). Foi utilizado *Regression Random Forest* (RRF) para contribuir com a seleção de *features* e foi realizada predição com *Convolutional Neural Network* (CNN), *Long short term memory* (LSTM), *Gated Recurrent Unit* (GRU), redes recorrentes e rede *Deep Feed Forward* (DFF) (ZHENG et al., 2017; DONG; LI; SUN, 2017; BRUNEO; De Vita, 2019; MODE; CALYAM; HOQUE, 2019; XIA et al., 2020).

Como diferencial, é apresentada a predição de falhas com aprendizagem contínua, utilizando detecção de similaridades e métodos de ML integrados à complexidade do problema de agendamento com apontamento de disponibilidade dos ativos envolvidos. Na PdM são comparados critérios como: coeficiente de determinação  $R^2$  e MAPE, que ficaram acima de 90%, permitindo a previsão de falhas com, pelo menos, cinco dias de antecedência.

É destacado o resultado do processo realizado, pois são geradas agendas semanais de produção em que a predição permitiu considerar, ou não, uma máquina no processo de produção que pode ser alterada a cada 24 horas após uma nova aquisição de dados de sensores e operação das máquinas. Foram utilizados os algoritmos de JobShop do OR-Tools software *open source* de otimização combinatória da Google Developers (2020). Com os

agendamentos, foi possível atender o objetivo de gerar agenda da produção de forma visual, como se fosse um indicador, através do gráfico de Gantt.

## 1.1 Motivação

Como principal motivação, estão as mudanças nos ambientes de produção que a I4.0 vem proporcionando. A necessidade de disponibilidade, customização de produtos e diminuição de estoques fazem crescer soluções e pesquisas alinhadas à produtividade e ao funcionamento constante de uma fábrica. Este trabalho está baseado em uma revisão sistemática, na qual constatou-se que, o aumento do uso de tecnologias ligadas à IA e a possibilidade de previsão de uma falha tornam-se foco para diversas linhas de pesquisas (ZONTA et al., 2020). De qualquer forma, é necessário ficar atento aos desafios e, se possível, conectá-los, exigindo estratégias para aplicação de problemas conhecidos na Computação, como o aprendizado de máquina e os problemas de escalonamento.

A integração dos agendamentos de manutenção com os de produção tem exemplos na literatura e tem atraído atenção devido a resolução de problemas incertos (LI; WANG; LIN, 2021; MOURTZIS; ANGELOPOULOS; ZOGOPOULOS, 2021). A preservação de um equipamento industrial em uso é a chave para diferenciais de produção, mas, ao mesmo tempo em que desafios de manutenção devem prevenir o *downtime*, suas conexões com outros processos muitas vezes são estudados ou tratados em separado.

A motivação deste trabalho, além de integrar as duas agendas, buscou contribuir com a compreensão de dois desafios complexos, esclarecendo a interdisciplinaridade envolvida nos novos desafios da I4.0, apresentando e comparando soluções, sejam elas algorítmicas ou de processo. A integração de processos fabris é uma linha de pesquisa em expansão para a Computação, cuja aplicação traz modificações e melhorias consideráveis ao ambiente industrial.

## 1.2 Questão de Pesquisa

Após a realização de uma revisão sistemática relacionada à PdM foram identificados alguns desafios e oportunidades em aberto, entre eles, a possibilidade de integração entre os processos de agendamento da manutenção e produção (ZONTA et al., 2020). Deste desafio, foi elencada a seguinte questão de pesquisa:

Um modelo para integração das agendas de manutenção e produção é capaz de utilizar os dados de sensores e informações de operação das máquinas para realizar a predição de falhas para otimizar o escalonamento da produção usando Redes Neurais Profundas (DNN)?

A questão de pesquisa, bem como o tema deste trabalho, ficam relacionados à:

- Possibilidade de integração e otimização de dois processos: agendamento e programação da manutenção e produção;
- Melhorar o desempenho da I4.0 e diminuir o *downtime* de forma inteligente e integrada;
- Avaliar a realização da predição de falhas utilizando os dados normalmente ruidosos de sensores e informações de operação das máquinas baseado em padrões de similaridade.

### 1.3 Contribuições científicas

As principais contribuições científicas deste trabalho são:

1. Proposta de uma taxonomia, identificação de desafios e questões abertas referente à I4.0 com foco na PdM;
2. Criação de um índice de degradação utilizando padrões de similaridade que permitem a identificação de falhas em dados ruidosos com base no tempo, o que possibilita o uso desta previsão em problemas de escalonamento;
3. Proposta de um novo modelo de manutenção preditiva para otimizar o cronograma de produção. O modelo tem o objetivo de ajustar o cronograma de manutenção com base nas condições e operação da máquina;

Além das contribuições científicas, este trabalho pôde apontar algumas contribuições tecnológicas como: utilização de um conjunto de dados sem publicações relacionadas ao problema de regressão e predição do RUL; adaptação dos resultados da PdM para serem utilizados com a suite de otimização *OR-Tools* (DEVELOPERS, 2020); apresentação do cronograma gerado pela integração das agendas de forma visual.

### 1.4 Objetivos

O objetivo geral desta tese é apresentar um modelo para auxiliar no processo de disponibilidade de máquinas na indústria 4.0, diminuindo o *downtime* de forma inteligente e integrada, levando em consideração a realização de predição de falhas nos cronogramas de manutenção otimizando o escalonamento da produção.

#### 1.4.1 Objetivos específicos

Como objetivos específicos, citam-se:

- Realizar uma revisão sistemática para entender os desafios e aplicações relacionadas à PdM na I4.0;

- Delimitar os requisitos e possíveis tecnologias a serem utilizadas para criação de uma arquitetura que permita a predição de falha baseada na aquisição de dados dos sensores e informações de operação das máquinas;
- Realizar estudo da integração e suas variações a partir da pesquisa bibliográfica e experimental, descrevendo, assim, as abordagens existentes;
- Identificar e validar as métricas de avaliação da arquitetura de DLL e do modelo PdMS.

## **1.5 Organização do documento**

Finalizada a parte introdutória, este trabalho está organizado em sete capítulos. O Capítulo 2 traz a fundamentação teórica dos conteúdos utilizados para formulação desta tese, informações sobre a I4.0 e métodos da PdM, descrição do método de PHM, arquiteturas de Sistemas Ciber-Físicos (CPS) e IoT, finalizando com os problemas de escalonamento. O Capítulo 3 destaca os trabalhos relacionados baseado na revisão sistemática Zonta et al. (2020) já publicada. Neste capítulo são justificadas a intenção e as hipóteses para realização deste trabalho buscando o estado da arte. No Capítulo 4 são apresentadas as abordagens e necessidades para criação do modelo PdMS. O Capítulo 5 detalha a metodologia para atender os objetivos desta tese. Para finalizar, no Capítulo 6 são apresentados e discutidos os experimentos e resultados obtidos. Por fim, a conclusão, juntamente com os trabalhos futuros.

## 2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo, os conteúdos necessários para construção deste trabalho serão contextualizados. Inicialmente, os desafios e tecnologias aplicados à I4.0 serão discutidos e relatados levando em consideração os processos de manutenção e produção. Na sequência, são apresentados os conteúdos relacionados à PdM, à metodologia do PHM, às tecnologias de IoT e CPS e aos problemas de escalonamento de produção e suas classificações, conteúdos estes considerados fundamentais para a criação desta tese.

### 2.1 Indústria 4.0

O desafio deste trabalho vem da necessidade das indústrias em adaptar-se e utilizarem novas tecnologias, fazendo com que elas evoluam para uma nova era. Conectividade, volume de dados, novos dispositivos, miniaturização, redução de estoques, personalização e produção controlada deram origem à chamada indústria 4.0, termo criado para atender às demandas de inovação e mudanças, anunciado na Alemanha como "a quarta revolução industrial" (LEE; BAGHERI; KAO, 2014). As diferenças entre as fábricas de hoje e o modelo 4.0 podem ser divididas em três linhas principais: componentes (autoconscientes, auto-preditivos); máquinas (autoconscientes, auto-estimadas, auto-comparáveis); sistema produtivo (autoconfiguração, auto-manutenção, auto-organização) e são apresentadas com detalhe na Tabela 1. A customização e a disponibilidade de dados gerando informações, permitindo ações de pessoas ou máquinas são algumas das características essenciais da I4.0 (LEE; BAGHERI; KAO, 2014; JIN et al., 2017).

A ideia de que "a indústria de manufatura precisa se transformar em manufatura preditiva", publicada por Lee et al. (2006), Lee et al. (2013), motivou este estudo. A PdM é baseada em dados históricos, modelos e conhecimento de domínio e pode prever tendências, padrões de comportamento e correlações por modelos estatísticos ou de aprendizado de máquina. O objetivo é antecipar falhas para melhorar o processo de tomada de decisão da atividade de manutenção, evitando paradas conhecidas como *downtime* (LEE et al., 2006; SEZER et al., 2018).

A manutenção alcançou importância crítica para as indústrias devido ao crescimento da complexidade das interações entre as diferentes atividades de produção em ecossistemas de produção cada vez mais ampliados e automatizados (SEZER et al., 2018). Desta forma, outro conceito que pode ser útil para a indústria e está relacionado diretamente com os fundamentos da I4.0 é a IoT. Com o termo especializado *Industrial Internet of Things* (IIoT), utilizam-se de tecnologias IoT em um ambiente industrial, incorporando, principalmente, ML e Big Data para fortalecer a filosofia de que *smart machines* apresentam maior eficiência em comparação aos humanos em termos de precisão e consistência para gerenciamento de dados (SEZER et al., 2018).

Tabela 1 – Comparação da fábrica atual com a indústria 4.0

	Fonte de Dados	Fábricas atuais		Fábricas Indústria 4.0	
		Atributos Chave	Tecnologias Chave	Atributos Chave	Tecnologias Chave
<b>Componente</b>	Sensores	Precisão	Sensores inteligentes e detecção de falhas	Auto: Consciente Predição	Degradação Monitoramento Tempo restante de vida (RUL)
<b>Máquina</b>	Controlador	Produtividade e desempenho (qualidade e produtividade)	Monitoramento e diagnósticos baseados em condições(CBM)	Auto: Consciente Predição Comparação	Tempo de execução com monitoramento preditivo de integridade
<b>Sist. produção</b>	Sistemas de fabricação em rede	Produtividade e OEE	Operações Lean: redução de trabalho e resíduos	Auto: Configuração Manutenção Organização	Sem preocupação Produtividade

Fonte: Adaptado de Lee, Bagheri e Kao (2014)

Outro sistema que vem fazendo uso da IoT é o CPS, que se refere aos sistemas de engenharia da próxima geração (GUNES et al., 2014; LEE et al., 2015). O termo foi apresentado na *National Science Foundation* (NSF), nos Estados Unidos, por volta de 2006 (GUNES et al., 2014). Um aspecto chave da modelagem e do estudo do CPS é ter informações suficientes sobre a máquina e o processo físico a fim de criar uma representação abstrata para o objetivo pretendido (SAEZ et al., 2018). Sua arquitetura consiste em várias camadas, como conexão digital, conversão de dados para informações, infraestrutura de computação de alto desempenho, cognição e camadas de configuração (WU et al., 2017a).

Mesmo com estas tecnologias e com a preocupação para a melhoria do processo de manutenção, é importante ficar atento à possibilidade de integração que a I4.0 permite com o uso de dispositivos, sensorização e inteligência no uso dos dados gerados. O processo de fabricação pode ser descrito com muitos detalhes, mas, em sua grande maioria, envolve o processo de determinação, controle, fluxo e agendamento da produção, também conhecido como: *Manufacturing Execution Systems* (MES). Seguido da expedição e entrega com a possibilidade de propor melhoria no carregamento e roteirização das cargas, todo esse ciclo de informação integrada pode ser denominado como *Factory Information System* (FIS) (YAN et al., 2018).

Alguns autores destacam a integração das agendas de manutenção e produção, mas trazem a preocupação do estudo e aplicação em separado (FITOURI et al., 2016; LADJ; Benbouzid-Si Tayeb; VARNIER, 2016; NIKOLAKIS et al., 2018). As soluções apresentadas são focadas em determinados cenários e com testes muitas vezes realizados em laboratório. Conforme apontando por Nikolakis et al. (2018), uma falta de aplicabilidade e versatilidade nas abordagens é encontrada. Neste ponto é focado este trabalho, com estudos em uma aplicação que ganha força nos processos de I4.0: a possibilidade de prever uma manutenção.



## 2.2 Manutenção Preditiva

A PdM tem ganhado destaque em grupos de pesquisa multidisciplinares (RODRÍGUEZ-MAZAHUA et al., 2016; LAMONACA et al., 2018). A possibilidade de aplicar métodos envolvendo aquisição de dados, infraestrutura, armazenamento, segurança e inteligência proporcionou a criação de linhas integradas de pesquisa. Esta seção pretende destacar alguns dos conteúdos essenciais para o entendimento da PdM e que contribuíram para os resultados deste trabalho.

Os dados coletados a partir dos vários sensores em ambientes da indústria fornecem novas oportunidades para soluções de previsão de vida restante de um ativo (YAN et al., 2017). A ideia de que a PdM é capaz de gerar agendamento de ações com base no desempenho ou nas condições do equipamento torna-se primordial para o futuro da indústria (WU et al., 2016). Um dos principais requisitos para a efetiva realização de PdM é a quantidade suficiente de dados de todas as partes do processo de fabricação (KIANGALA; WANG, 2018). Como resultado, isso pode diminuir os custos de manutenção e o tempo de inatividade, além de melhorar a produtividade e a qualidade.

Um dos principais conceitos relacionados à PdM é o PHM que prevê o gerenciamento do ciclo de vida de sistemas industriais, apresentando técnicas de manutenção estudadas e utilizadas em aplicações de engenharia, empregando quatro tipos: corretiva, preventiva de intervalo fixo, detecção de falhas e manutenção baseada na condição (CBM) (KWON et al., 2016; ZERHOUNI et al., 2017). O monitoramento do ativo é realizado por sensores e utiliza estratégias de algoritmos que permitem a avaliação do RUL (KWON et al., 2016).

Na manutenção, há quatro categorias de ocorrência: corretivas: quando a falha ocorreu ou há sinais; preventiva: que usa cronogramas em horários específicos; preditiva: que utiliza informações e conhecimento baseados no tempo para indicar uma possível falha; e a manutenção prescritiva: que pode responder à pergunta: "Como podemos fazer isso acontecer?" ou, em outras palavras, "Como podemos controlar a ocorrência de um evento específico?". A resposta para essas perguntas pode ser: fornecendo conselhos úteis para tomar decisões, melhorando e otimizando os próximos processos de manutenção (MATYAS et al., 2017; NEMETH et al., 2018).

Outro conceito essencial relacionado à PdM são as três classificações da abordagem usada para predição (WU et al., 2017a; WANG et al., 2018; DEUTSCH; HE, 2018):

- **Baseado em modelo físico - (*Physical model-based*):** tem como principal característica a modelagem matemática com reflexos na condição de um componente, necessitando da precisão da condição e medição de uma falha e métodos estatísticos para limitar estes índices (WU et al., 2017a);
- **Baseada no conhecimento - (*Knowledge-based*):** estas abordagens reduzem a complexidade de um modelo físico. Por esta razão, são frequentemente usadas como

uma estratégia híbrida, por exemplo, sistemas especialistas ou lógica difusa (WU et al., 2016; AYAD; TERRISSA; ZERHOUNI, 2018);

- **Orientado a dados - (*Data-driven*):** estes modelos são os mais comumente encontrados na evolução atual das soluções de PdM, baseados em estatísticas, reconhecimento de padrões, IA e modelos baseados em algoritmos de ML.

Além destas classificações, foram encontradas outras definições híbridas:

- **Baseados em nuvem:** com monitoramento descentralizado com informações e alertas disponibilizados na nuvem (KIANGALA; WANG, 2018; WU et al., 2016; WU et al., 2017d; SILVA et al., 2016; SCHMIDT; WANG; GALAR, 2017);
- **Deep Learning-Based:** com abordagens baseadas em dados, com modelos DNN (DEUTSCH; HE, 2018; LEE; JIN; BAGHERI, 2017; HE; HE, 2017; LEE, 2017; YAN et al., 2018; LIU et al., 2018);
- **IoT-Based e Fleet-based:** ambos trazem a ideia do uso da similaridade de um conjunto de máquinas (WU et al., 2017a; KWON et al., 2016; JIN et al., 2017; LAMONACA et al., 2018);
- **Baseadas no tempo:** que buscam a vantagem da antecipação ao surgimento de falhas de equipamentos. Esta é a principal característica que identifica uma solução de PdM - a predição realizada no tempo (KAUR et al., 2018; WU et al., 2017c; JANTUNEN et al., 2016).

### 2.2.1 Problemas de qualidade de dados

Algo que deve ser observado em problemas de PdM são os dados históricos brutos que geralmente contém erros e ruídos, afetando a tomada de decisão final. Por exemplo: a telemetria pode não ser suficiente para cobrir as perspectivas críticas dos fenômenos do sistema ou conter informações redundantes (CHEN; ZHU; LEE, 2013).

Dentre as estratégias existentes, os dados sintéticos baseados em semelhanças permitem a identificação de um padrão de degradação em ciclos de telemetria. Pode ser destacada a importância da identificação das condições operacionais de operação e dos processos produtivos, o que, em alguns casos, não está disponível. Para isso, é necessário aplicar filtros digitais, matemáticos e estatísticos para suavização de dados (WANG et al., 2008; ZHENG et al., 2017; CAI et al., 2020). Por meio deste processo é possível prever uma possível metodologia de aplicação em indústrias que possuem dados mas realizam manutenção de forma corretiva ou preventiva.

## 2.2.2 Redes Neurais Profundas e Modelos de Regressão

O aumento da pesquisa relacionada à PdM reflete as novas necessidades da indústria. Desafios impostos pelos volumes de dados geraram discussões importantes, principalmente no período a partir de 2018. Abordagens ligadas à ML, modelos DNN ou RNN apresentaram bons resultados em aplicações com volumes de informação consideráveis (CARVALHO et al., 2019).

A estrutura básica de uma DNN é feita de células e camadas, como camadas de entrada, camadas ocultas e camadas de saída. Cada arquitetura tem suas características, mas são geralmente, diferentes nas camadas ocultas e dependem do formato de dados utilizados nas camadas de entrada (VEEN, 2017).

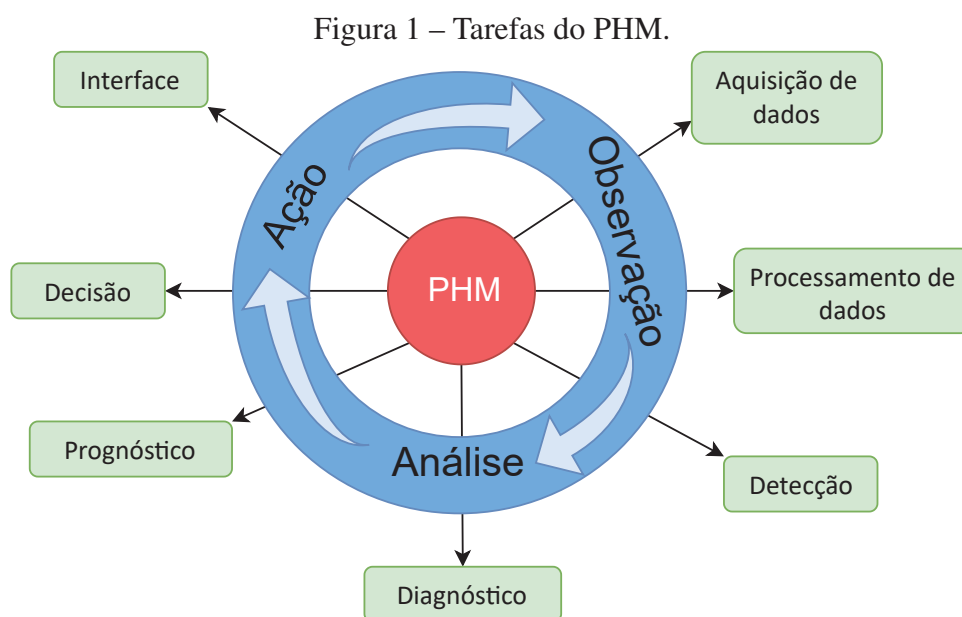
Modelos baseados em dados usam classificação e regressão para apontar características nos dados e, modelos físicos, contribuem para melhores resultados (ZHANG; YANG; WANG, 2019). A previsão de falha é, geralmente, modelada como um problema de regressão devido à sua característica de série temporal e à leitura periódica do sensor. Este trabalho descreve a comparação entre os modelos de regressão utilizando RRF, DNN e RNN para avaliar a ideia de que esses modelos podem se adaptar e trazer bons resultados para problemas de PdM.

## 2.3 *Prognostics and Health Management (PHM)*

Conforme destacado, o PHM tem grande influência na PdM. O termo prognóstico e gestão de saúde remete mais a um conteúdo da área da medicina do que estudos relacionados a verificação da saúde de ativos na indústria. Mas algo que chama atenção, no momento que as pesquisas relacionadas à previsão são realizadas, é que o termo se torna frequente com uma aplicação relacionada diretamente às Engenharias. Segundo Zerhouni et al. (2017), na literatura, o PHM tem sido estudado por pesquisadores de diferentes áreas de engenharia com o objetivo de aumentar a confiabilidade, disponibilidade, segurança e redução de custo de manutenção de ativos de engenharia. O assunto é considerado por autores como um ponto crítico para pesquisas que utilizam ferramentas avançadas de previsão (LEE et al., 2013). Por ser um termo comum em publicações de autores das engenharias, foi identificada sua ligação direta com a ideia da PdM, sendo possível, até, rotular como o conteúdo precursor e necessário para entender melhor a PdM. A Figura 1 traz a definição do fluxo da realização do método de prognóstico, chamado de tarefas do PHM, e nelas, fica clara a necessidade de um grupo multidisciplinar para atendê-los.

A descrição das tarefas do PHM, apresentadas na Figura 1, é realizada pelos processos macros:

- **Observação:** a observação é composta por três tarefas: aquisição, processamento e detecção. Importante destacar que o processo de aquisição não envolve somente o uso de sensores que coletam dados de emissão acústica, vibração, temperatura, pressão,

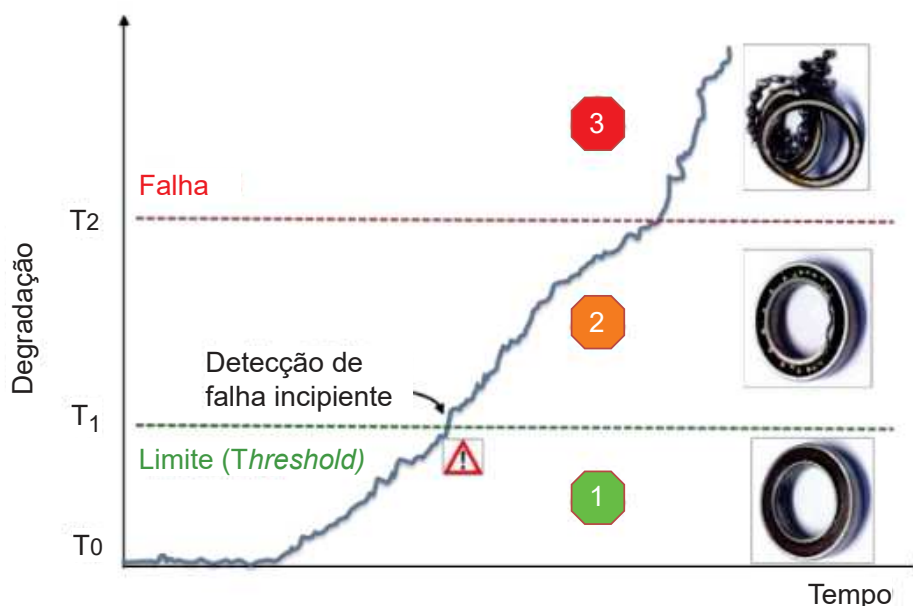


Fonte: Adaptado de Zerhouni et al. (2017)

umidade, resistência, medições eletroeletrônica e análise de imagens. Também são importantes os dados de ações já realizadas e ocorrências já identificadas, por isso a importância do pré-processamento dos dados. É neste momento que é realizada a extração dos melhores recursos necessários para a identificação de um desgaste ou possível falha. No processamento é importante o conhecimento físico do ativo que está sendo monitorado. Alguns exemplos de técnicas são: transformada de Fourier, transformação de Hilbert-Huang, filtro de Kalman, filtro Savitzky–Golay e distribuição Wigner-Ville. Importante lembrar que o processo de aquisição e processamento dos dados não é útil se não houver a detecção da propagação da degradação e falha do ativo conforme Figura 2.

- **Análise:** a análise é o segundo processo macro dentro do PHM, com as tarefas de diagnóstico e prognóstico. Após a detecção das informações da degradação, é necessário catalogar ou rotular cada característica da falha e informações necessárias para o diagnóstico esperado, sendo possível apontar à nível de qual componente está ocasionando a degradação do ativo. Com esta informação, é possível tomar uma decisão reativa ou proativa, baseada no prognóstico que é responsável pela identificação do tempo de vida útil do ativo e conhecido como RUL. A diferença entre as duas tarefas é que o prognóstico serve como prevenção do sistema contra possíveis falhas e previsão de estados futuros, enquanto o diagnóstico diz respeito ao isolamento destas falhas e ao processo de classificação (TERRISSA et al., 2016; ZERHOUNI et al., 2017).
- **Ação:** o processo final do PHM atende as tarefas da ação que envolvem a importância da escolha correta da realização da manutenção, fazendo uma relação com a solução desta tese. É neste momento que é feita a integração com o agendamento da produção. No

Figura 2 – Propagação da degradação e falha do componente.



Fonte: Adaptado de Zerhouni et al. (2017)

caso da publicação de Levrat, Thomas e Iung (2008), uma abordagem de agendamento de manutenção oportunista é apresentada, ou seja, são utilizadas informações do prognóstico para fazer "encaixes" de manutenção na agenda da produção, por isso a ideia de uma decisão oportunista. No caso deste trabalho, esse processo terá um previsão automática e integrada, verificando a possível modificação na agenda de produção. Além do momento da manutenção, a tarefa da decisão também está relacionada ao que realizar, ou seja, qual componente pode ser trocado. Em alguns casos, a abertura de um motor gera tanto trabalho que já seria importante trocar outros componentes (ZERHOUNI et al., 2017).

A dificuldade em encontrar uma pesquisa detalhada de cada um destes processos é algo que pode ser destacado. Os artigos focam, normalmente, na descrição física ou lógica da proposta. No caso das pesquisas com foco físico, estes estão diretamente relacionados à observação e, em como são realizados os processos de aquisição, processamento, armazenamento, distribuição e acesso dos dados gerados. Quando o artigo tem essa característica, são citadas abordagens utilizadas para a análise, porém, com detalhes apenas para o apontamento do que poderia ser utilizado (TERRISSA et al., 2016; WU et al., 2017d; YAN et al., 2017; SPENDLA et al., 2017; LAMONACA et al., 2018). Já no caso de pesquisas com foco lógico, são destacados os algoritmos e estratégias de tratamento e seleção dos dados, ou seja, as informações de como a aquisição é feita é menos detalhada (WU et al., 2017a; MAN; ZHOU, 2018; YAN et al., 2018). Essa diferença fica clara quando a especialidade do pesquisador é analisada. Pesquisadores da Engenharia relatam o processo de PHM e relacionam sua solução com ele. Pesquisadores da computação utilizam dados já extraídos realizando, basicamente, as tarefas de processamento, detecção e análise, chamando esse processo de PdM. Por isso, nossa afirmação de que essa linha

de pesquisa traz várias oportunidades multidisciplinares.

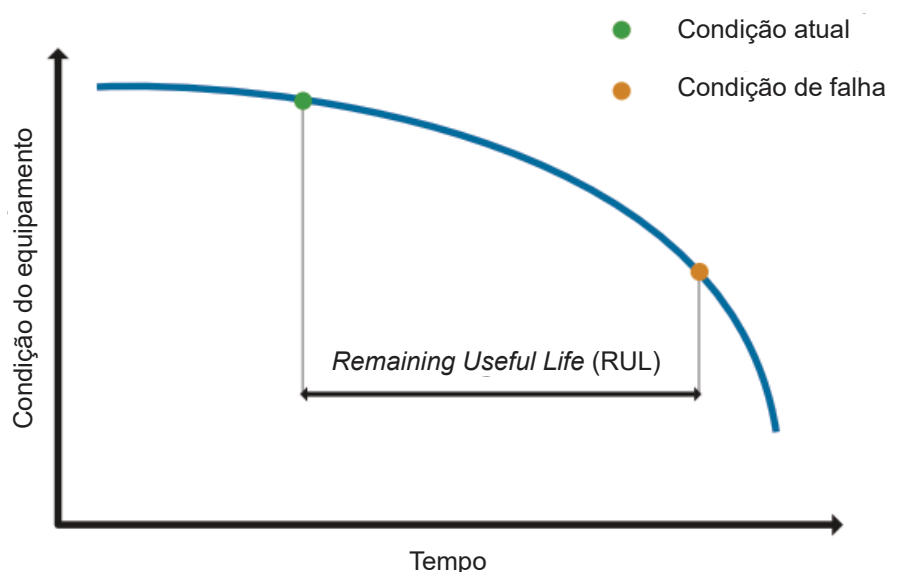
Um exemplo com uma abordagem de aplicação do PHM foi publicado por Kwon et al. (2016) em um artigo que, além da definição do PHM, traz dois termos comumente encontrados: RUL e Manutenção Baseada na Condição (CBM). O artigo destaca que o PHM consiste em quatro dimensões: detecção, diagnóstico, prognóstico e gestão e, também, atenção aos problemas em usar somente estratégias *data-driven*, devido à necessidade de dados históricos, sendo que os dados da falha são na maioria, simulados em laboratório e não levam em consideração novas máquinas - que podem possuir outro apontamento de falha. Para isso, o artigo apresenta a forma híbrida entre *physics-of-failure* (PoF) e *data-driven*, em que o conhecimento físico é importante tanto para análise como, também, para a ação a ser realizada.

### 2.3.1 Remaining Useful Life (RUL)

Um dos pilares da metodologia PHM é determinar corretamente o RUL. Como o próprio nome sugere, o RUL determina o tempo que o ativo consegue operar sem apresentar falha. Com ele, os engenheiros conseguem determinar o tempo para manutenção e otimizar a eficiência sem um possível *downtime*. Aí a prioridade de estimar o RUL corretamente também para processos de PdM (MATHWORKS, 2018).

A Figura 3 traz um exemplo da representação do RUL considerando o perfil de deterioração do ativo no tempo. Este período pode ter várias medidas: dias, milhas ou ciclos (MATHWORKS, 2018).

Figura 3 – Perfil de deterioração com período determinado para o RUL.



Fonte: Adaptado de MathWorks (2018)

A determinação do RUL faz parte das tarefas de detecção, diagnóstico e prognóstico e tem dependência das tarefas anteriores, principalmente do volume e determinação mais assertiva

dos dados e *features*, que serão utilizados para seu cálculo. Para isso, é possível destacar três formas para determinar o RUL: modelos de similaridade, degradação e sobrevivência. Segundo MathWorks (2018), o modelo é definido dependendo do quanto é conhecida a situação do ativo. Para o modelo de similaridade deve-se ter dados que identifiquem o estado saudável ao estado de falha. O modelo de degradação tem os dados, mas não a falha, e, sim, um limite de segurança. E, por fim, o modelo de sobrevivência, que tem somente os dados do momento da falha.

## 2.4 Sistemas Ciber-Físicos (CPS)

A integração de processos e comunicação entre máquinas vem de encontro ao CPS - área que refere aos sistemas projetados de próxima geração (GUNES et al., 2014; LEE et al., 2015). O termo apresentado na NSF, traz um aspecto chave da modelagem e do estudo baseado em informações suficientes sobre a máquina e o processo físico para criar uma representação abstrata para o objetivo pretendido (GUNES et al., 2014; SAEZ et al., 2018). Sua arquitetura consiste em várias camadas, como: conexão digital, conversão de dados para informações, infraestrutura de computação de alto desempenho, cognição e camadas de configuração (WU et al., 2017a). As operações são integradas, monitoradas ou controladas por um núcleo computacional e estão distribuída em rede. Na maioria, este núcleo é um sistema embarcado, com resposta em tempo real. O comportamento de CPS integra ações computacionais lógicas e físicas.

Uma das definições e conteúdos que contribuíram para este trabalho foi a modificação da pirâmide da automação, publicada por Lee, Jin e Bagheri (2017). A Figura 4 demonstra a arquitetura de um CPS, muito próximo da ideia do PHM:

- **Conexão:** foca no processo de aquisição com uma proposta padronizada para comunicação e segurança. Hoje, os protocolos dependem da tecnologia de cada fornecedor, o que prejudica a utilização de uma comunicação unificada. Por isso, a ideia é apresentar um protocolo sem características proprietárias, em que, os desenvolvedores podem se concentrar mais na aplicação do que no processo de tradução e adequação (LEE; JIN; BAGHERI, 2017).
- **Conversão:** processo de tratamento de dados brutos. Segundo Lee, Jin e Bagheri (2017), deve-se aplicar as técnicas de PHM para atingir o objetivo de conversão com melhor resultado. Chama-se atenção, também, para o uso de falhas induzidas e que experimentos de laboratório podem apresentar as principais causas, mas não é possível identificar todos os modos de falha, sendo essa a responsabilidade do nível cibernético.
- **Cyber:** a ideia do nível cibernético é que seja possível ter um gêmeo digital e que possa ser avaliada constantemente a situação do ativo. A ideia é comparar com diferentes históricos de tempo, possibilitando que algoritmos possam aprender novas

características de falhas deixando o resultado mais confiável (LEE; JIN; BAGHERI, 2017).

- **Conhecimento:** neste nível, o ativo identificará uma possível falha e preverá sua degradação utilizando avaliação do histórico para aprender. Neste nível, os algoritmos de predição seriam usados para estimar o RUL. Com essa informação, é possível otimizar a operação de produção, programação de manutenção e planejamento de logística para apoiar uma melhor tomada de decisão.
- **Configuração:** o topo da pirâmide utilizará as informações e previsões do níveis anteriores, a fim de contribuir para a tomada de decisão, permitindo uma "configuração" antecipada do processo produtivo no caso da I4.0. Segundo Lee, Jin e Bagheri (2017), a ideia principal é possibilitar que a própria máquina possa reduzir sua carga de trabalho e ajustar o cronograma de fabricação a fim de reduzir a possibilidade de mau funcionamento e alcançar o que chamou de um sistema resiliente.

Figura 4 – 5C - Arquitetura de CPS.



Fonte: Adaptado de Lee, Jin e Bagheri (2017)

A concepção da arquitetura 5C foi baseada, principalmente, na ideia da predição e na tomada de decisão levando em consideração a aquisição de dados dos processos e máquinas, permitindo a comparação entre vários ativos para prever, principalmente, falhas. Essas características são apontadas, basicamente, no PHM e na PdM, como já citado anteriormente. Desta forma, é possível identificar várias linhas de pesquisa com o objetivo de permitir à indústria se tornar mais autônoma e inteligente no que foi chamado de revolução 4.0.

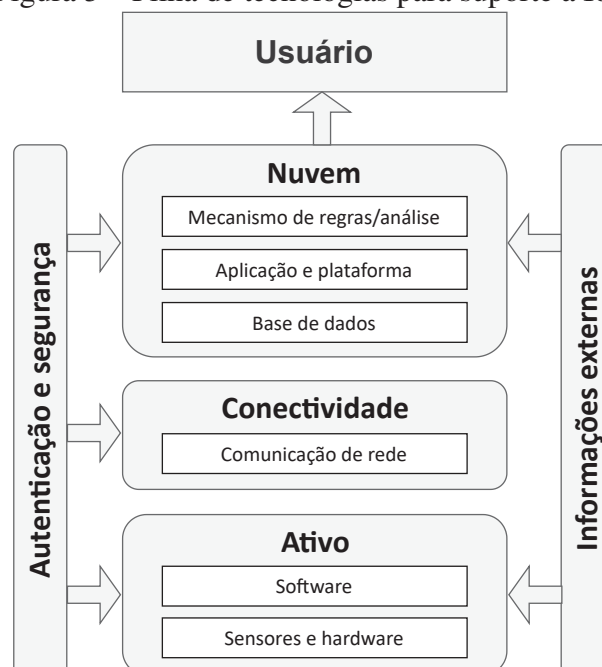


## 2.5 Internet das Coisas (IoT)

Um dos grandes desafios apresentados no PHM, PdM e CPS é a possibilidade de comunicação entre as máquinas, como se a indústria pudesse permitir troca de dados e informações entre gerentes e máquinas. Um dos conteúdos que apresentaram essa possibilidade ficou conhecido como Internet das Coisas (IoT), que traz em sua concepção a ideia de que um dispositivo, componente, ativo ou "coisa" que possa se conectar e enviar dados para rede se torne um gerador de dados que possam ser utilizados. Esse movimento vem crescendo devido, baixo custo e miniaturização, principalmente de sensores que permitem coletar dados já citados: temperatura, pressão, umidade e vibração.

Devido os sensores e dispositivos não terem alta capacidade de armazenamento, processamento e a necessidade de baixo consumo de energia. Na maioria das abordagens ligadas à IoT, estratégias de distribuição e armazenamento dos dados coletados são necessárias, por exemplo, *cloud computing* (TERRISSA et al., 2016; WU et al., 2017a; SCHMIDT; WANG; GALAR, 2017; SILVA et al., 2016). Em alguns casos até com abordagens mais atuais como a *fog computing* (WU et al., 2017d). Na Figura 5, é apresentada uma pilha de tecnologias para suporte a IoT (KWON et al., 2016).

Figura 5 – Pilha de tecnologias para suporte à IoT.



Fonte: Adaptado de Kwon et al. (2016)

Apresentados os conceitos, métodos e tecnologias que norteiam a I4.0, torna-se necessário entender como pode ser feita a integração dos processos de fabricação.

## 2.6 Problemas de escalonamento de produção

Com objetivo de propor uma integração entre os processos de fabricação. Faz-se necessário identificar os desafios existentes, e, em que momento é possível a realização do escalonamento da produção, com a necessidade de manutenção determinada de forma preditiva.

O escalonamento é um processo de tomada de decisão para alocação de um ou vários recursos limitados por um certo período para otimizar um ou mais objetivos (PINEDO, 2016). Segundo Pinedo (2016), estes recursos podem ser máquinas, pistas em aeroportos, equipes em um canteiro de obras entre outros. Já as tarefas podem ser realizadas na produção, decolagens de avião, estágios de construção e podem ter tempo determinado e prioridade de execução. Por ser considerado um problema *NP-HARD*, dentro da complexidade computacional, os objetivos de sua utilização podem ser minimizar ou maximizar algo. Esta categoria de problemas é conhecida pela complexidade computacional e por apresentar resultados considerados viáveis sem a certeza de uma solução exata.

A complexidade existente nos processos de fabricação vem de encontro à capacidade de gerenciar os recursos disponíveis com êxito. Os problemas de escalonamento de produção trazem este desafio, mas, muitas vezes, são realizados com a previsão de disponibilidade constante dos ativos envolvidos (HATAMI, 2016; FITOURI et al., 2016).

A descrição padrão para os problemas de escalonamento parte de um número finito de *jobs* e máquina(s). Um *job* pode exigir várias tarefas ou processamentos. Pode-se destacar as principais variáveis que fazem parte de uma tarefa: tempo de processamento em uma máquina, período determinado de entrada e conclusão do processamento e o peso que pode determinar a prioridade de execução. Outra característica que é importante destacar é a disponibilidade de máquinas que vão rotular o tipo de problema a ser modelado: única máquina (1) com menos complexidade, máquinas idênticas ( $P_m$ ), de diferentes velocidades ( $Q_m$ ) e sem relação ( $R_m$ ) em paralelo e várias máquinas com disposição de execução específica (HATAMI, 2016; PINEDO, 2016).

Conforme descrito por Pinedo (2016), os problemas de escalonamento são modelados por uma tripla  $\alpha | \beta | \gamma$  que descreve na sequência: o ambiente e disponibilidade de máquina com somente uma entrada, detalhes das características e restrições de processamento com nenhuma ou uma entrada e o objetivo a ser minimizado com entrada simples.

### 2.6.1 Classificação dos problemas de escalonamento

A quantidade de máquinas disponíveis, como já visto, é determinante para a classificação e modelagem do problema. É importante fazer uma leitura correta, principalmente em casos que apresentam múltiplas máquinas. As principais classificações referentes à problemas de escalonamento são abordadas a seguir:

- **Single Machine (1):** é uma classificação com solução mais trivial, até mesmo em sua

identificação, que apresenta a situação de um recurso a ser utilizado no escalonamento das tarefas. Importante destacar que as soluções para essa classificação consideram as regras de que o recurso está disponível, executa somente uma tarefa por vez e o tempo de utilização é conhecido previamente.

- **Parallel Machine (P|Q|Rm):** máquinas paralelas apresentam algumas possibilidades: máquinas idênticas (Pm), de diferentes velocidades (Qm) e sem relação (Rm). Segundo Hatami (2016), consiste em um único estágio de produção com múltiplas máquinas dispostas em paralelo. As tarefas precisam ser atribuídas e processadas por uma das máquinas paralelas sem a utilização de outra ao mesmo tempo, determinando que o processamento tem que começar e terminar em uma máquina. Uma máquina não pode processar mais de um trabalho ao mesmo tempo.
- **Flow-shop (Fm):** traz a ideia de máquinas em série. As tarefas, além de serem processados em uma das máquinas, devem obedecer uma sequência, todos utilizando um mesmo fluxo, ou seja,  $m1...mn$ , um formato que, segundo Pinedo (2016), lembra uma fila FIFO (*First In First Out*), sendo que nenhuma tarefa pode ser atendida por outro recurso enquanto espera em uma fila, conhecido também como Fm de permutação.

A classificação Fm apresenta uma generalização chamada de *Flexible flow shop* (FFc), que substitui os recursos por estágios em série e possui um número de máquinas idênticas em paralelo. Neste caso, a ordem do fluxo torna os estágios de 1..n. Segundo Pinedo (2016), FFc, por vezes, também são conhecidos como Fm híbrido e como Fm de multiprocessador.

- **Job-shop (Jm):** a característica do Jm traz que cada tarefa tem sua própria rota a seguir, mas obedece a regra de que cada máquina é utilizada uma vez, a não ser que a classificação seja de um processo conhecido como recirculação.

Segundo Hatami (2016), cada tarefa consiste em operações com uma ordem de visitação específica da máquina, determinada com tempos de processamento e levando em conta que, cada operação tem um único predecessor, a ordem de utilização para as máquinas no Jm difere do Fm na obrigatoriedade, dependendo de cada tarefa. Não há restrições de precedência entre operações de diferentes tarefas; a interrupção de operações não é permitida; cada máquina pode processar apenas um trabalho de cada vez e cada trabalho só pode ser executado em uma máquina por vez. Da mesma forma que o Fm, o Jm possui uma generalização flexível (*Flexible job shop* (FJc)). Segundo Pinedo (2016), em vez de máquinas em série existem centros de trabalho com um número de máquinas idênticas em paralelo. Cada tarefa tem seu próprio caminho e requer processamento em cada centro de trabalho em apenas uma máquina e qualquer máquina pode fazer isso.

O Jm tem, em suas características, a relação com a produção customizada e de baixa escala, por isso o *Job-shop* apresenta um relação com a diversidade de produtos, um dos

desafios das linhas de produção na I4.0.

- **Open-shop (Om):** várias máquinas e tarefas que podem reutilizá-las sem restrições em relação ao roteamento. Diferente do Jm, as sequências de trabalhos podem ser executadas obedecendo apenas a regra de uma tarefa por máquina. Novamente, no caso do Om, não há relações de precedência entre as operações de cada trabalho e não há restrição na ordem.

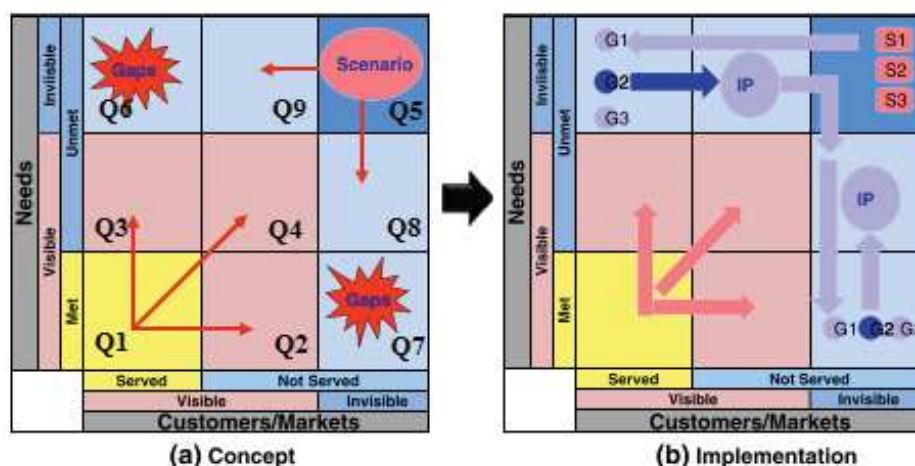
Além das classificações destacadas, existem algumas generalizações na literatura, como, esforços de diminuição de espaço de busca e previsão de múltiplos objetos ou distribuição de recursos em pontos e fábricas separadas (HATAMI, 2016; WANG; TANG, 2017).

Algumas informações serão explicadas no momento que for feita a modelagem do problema proposto, mas a principal variável objetivo de um problema de escalonamento é o *Makespan*, que é equivalente ao tempo de conclusão do último trabalho para sair do sistema. Sua minimização implica em um apontamento viável de utilização dos recursos (PINEDO, 2016).

## 2.7 Matriz de inovação sistemática

Com o objetivo de expressar a inovação pretendida, foi realizada uma pesquisa por um método que à exemplo do Produto Mínimo Viável (MVP), pudesse apresentar de forma diferenciada as decisões e necessidades em nível de negócio. A metodologia de criação de inovação sistemática proposta por Lee e Abuali (2011) e detalhada na Figura 6 permite o levantamento da aderência de um produto no mercado. A proposta é que o processo de inovação concilie necessidades do mercado e capacidades tecnológicas, ofertando novos produtos e serviços enquanto avança a tecnologia.

Figura 6 – Metodologia para criação de um inovação sistemática.



A explicação detalhada da metodologia proposta na Figura 6 é dividida em passos e utiliza os quadrantes de 1 a 9, identificados na matriz (LEE; ABUALI, 2011):

- **Passo 1:** definição da necessidade atual dos possíveis clientes do produto. Para este passo são necessários dois procedimentos: (i) identificar clientes atuais que estão sendo atendidos; e (ii) identificar as necessidades explícitas atuais que estão sendo "atendidas". Este passo é descrito no quadrante Q1, em amarelo;
- **Passo 2:** avaliação de necessidades não atendidas e clientes não identificados. Para este passo são necessários três procedimentos: (i) para os clientes identificados, determinar os mercados que "não estão sendo atendidos"; (ii) para as necessidades identificadas, determinar as necessidades que "não estão sendo atendidas"; (iii) correlacionar os dois primeiros procedimentos com "clientes identificados" e necessidades "explícitas" que não estão sendo atendidos. Este passo é descrito nos quadrantes Q2, Q3 e Q4, em vermelho;
- **Passo 3:** análise das lacunas em aberto (*Gaps*). Para este passo são necessários dois procedimentos: identificar lacunas de clientes - qual mercado não é identificado e não é atendido? Identificar lacunas nas necessidades - quais necessidades são latentes e não atendidas? Este passo é descrito nos quadrantes Q6 e Q7, em azul claro;
- **Passo 4:** exploração do espaço de aplicação. Para este passo são necessários dois procedimentos: identificar vários "cenários" capazes de direcionar as lacunas selecionadas e correlacionar o espaço do aplicativo com o tecnológico. Este passo é descrito no quadrante Q5, em azul escuro; **As ferramentas que podem ser utilizadas para atender os 4 primeiros passos são: *brainstorming*, ferramentas de controle de qualidade (7QC) (causa e efeito e princípio de pareto) e matriz de inovação;**
- **Passo 5:** geração e design de conceito de serviço dominante. Para este passo são necessários dois procedimentos: (i) avaliação quantitativa para selecionar o conceito de aplicativo, correlacionando-o com as necessidades do cliente e de gerenciamento; e (ii) documentar e gerenciar propriedade intelectual e iniciar um plano de negócios. A ferramenta indicada para este passo é a desdobramento da função qualidade (QFD) e matriz de inovação. Este passo é descrito nos quadrantes Q8 e Q9, em azul claro;

## 2.8 Considerações finais

Os conteúdos abordados neste capítulo tiveram o objetivo de nortear as necessidades apontadas para o desenvolvimento de uma proposta de integração em processos de "chão de fábrica". Para isso, os estudos iniciaram na descrição das características, desafios e oportunidades da I4.0.

Os apontamentos para esforços relacionados à PdM aparecem com frequência, primeiro pela disponibilidade de dados existentes, hoje motivada pela IoT e CPS, segundo, pelo custo

que um *downtime* acarreta para as indústrias. Durante os estudos da aplicação da PdM na I4.0, a frequência de alguns termos, como PHM, pouco comuns para computação chamaram a atenção, e, em uma pesquisa mais aprofundada, foi identificado que sua metodologia seria de suma importância para este trabalho.

Com um dos conteúdos principais relacionados ao objetivo do trabalho já fundamentado, foi necessário realizar estudos sobre os problemas de escalonamento, problemas estes, mais conservadores, com uma linha de pesquisa focada em soluções da Pesquisa Operacional com heurísticas e programação inteira, mas com novas oportunidades quando integrados com processos da I4.0.

Este levantamento inicial contribuiu para a visualização do problema, indicação do modelo apresentado e levantamento de tecnologias que vão ser utilizadas, sendo estas, abordadas com maior detalhe na descrição do método planejado. Os estudos realizados são relatados com detalhes no Capítulo dos trabalhos relacionados, dividido na apresentação da revisão sistemática realizada sobre a PdM no cenário da I4.0 e, com ela, a identificação dos desafios, entre eles, a integração dos agendamentos, escolhida como objetivo para esta tese.

### 3 TRABALHOS RELACIONADOS

Neste capítulo são apresentados os resultados de uma revisão sistemática que pesquisou os desafios da PdM na I4.0 (ZONTA et al., 2020). Neste processo, foram encontrados alguns artigos, a exemplo de um estudo de mapeamento sistemático relativo ao Big Data na manufatura, que avalia e faz uma classificação dos artigos, indicando crescimento de pesquisas ligadas ao Big Data e I4.0 (O'DONOVAN et al., 2015). Neste mapeamento, duas questões importantes foram analisadas: "Que tipo de análise está sendo usada na área de Big Data na fabricação?" e "Que tipo de pesquisa está sendo realizada na área de Big Data na manufatura?".

Como resultado da revisão, já citado na motivação, tem-se o mapeamento de alguns desafios, sendo um deles utilizado como tema desta tese.

#### 3.1 Manutenção Preditiva na I4.0: Uma Revisão Sistemática da Literatura

Para entender melhor os desafios e oportunidades relacionadas à PdM e I4.0, foram abordados os seguintes desafios científicos:

1. Propor uma taxonomia para PdM no contexto da I4.0;
2. Organizar os principais conceitos relacionados à área;
3. Apresentar os principais modelos preditivos e monitoramento aplicados à I4.0;
4. Identificar os principais desafios e futuros problemas relacionados à I4.0.

Com os desafios científicos definidos o método de População, Intervenção, Comparação, Resultado e Contexto (PICOC) (O'DONOVAN et al., 2015) demonstrou-se ideal para o objetivo da revisão devido sua definição trazer a necessidade da realização da comparação, contextualização, discussão e apresentação de desafios da PdM na I4.0.

##### 3.1.1 Questões de Pesquisa

A partir dos desafios científicos e as contribuições identificadas, foi criada a questão principal (MQ) e subquestões (SQ) da Tabela 2. A MQ foi formulada com o objetivo de relatar como a PdM é aplicada na I4.0. As SQs foram criadas para colaborar e detalhar as contribuições científicas. A questão SQ1 lista os principais meios de divulgação da pesquisa em consonância com a PdM e I4.0. A SQ2 identifica e relaciona quais métodos e modelos são usados nas pesquisas. A SQ3 analisa os termos mais encontrados para a criação e apresentação da proposta da taxonomia. A SQ4 discute as aplicações, levando em consideração os casos e tipos de dados coletados para as soluções propostas. A questão SQ5 traz os desafios e direções futuras percebidas no estudo e que contribuiriam diretamente para a escolha do tema desta tese.

Tabela 2 – Questões de Pesquisa

Identificador	Questão
MQ	Quais são os modelos, métodos ou arquiteturas relacionados à previsão ou monitoramento que estão sendo usados na Indústria 4.0
SQ1	Quais são os principais meios de divulgação de pesquisas alinhadas ao PdM na Indústria 4.0?
SQ2	Quais são os modelos mais comuns de previsão encontrados no Indústria 4.0?
SQ3	É possível criar uma taxonomia usando os termos encontrados para aplicação preditiva ou monitoramento?
SQ4	Como são os resultados das pesquisas que apresentam modelos, métodos ou arquitetura?
SQ5	Quais são os desafios e questões abertas identificadas?

Fonte: O Autor

### 3.1.2 Estratégia de pesquisa

Para realização das buscas foi necessário a criação de uma *string* e selecionar as bases de pesquisa. Inicialmente a pesquisa foi realizada no Google Acadêmico, devido sua busca livre no título e textos das publicações. A ideia foi obter um maior volume de resultados para identificar possíveis desafios relacionados à PdM durante a catalogação.

A *string* de pesquisa foi focada na PdM aplicada na I4.0 e pode ser visualizada na Figura 7. Com base em leituras anteriores, foi identificada a necessidade de realizar uma revisão e apontar os desafios e as direções futuras nesta linha de pesquisa (LEE et al., 2013; HAARMAN; MULDER; VASSILIADIS, 2017). A *string* foi montada considerando algumas características, por exemplo, que a maioria dos dados de abordagens de PdM envolvem variáveis mecânicas e elétricas.

Figura 7 – String de pesquisa.

((("industry 4.0" or "intelligent factory" or "smart factory" or "smart manufacturing") and ("internet of things" or "iot") and (monitor\* or predict\*) and ("model" or "method" or "architecture") and (mechanic\* or electric\*))

Fonte: O Autor

### 3.1.3 Seleção dos Artigos

A *string* apresentada na Figura 7 foi aplicada em 27/10/2018 no Google Acadêmico, foi realizado filtro considerando 10 anos (2008-2018) removendo patentes e citações. Em seguida, os artigos foram exportados para o software Mendeley, resultando em 1143 ocorrências. A intenção desta triagem foi receber um volume maior de resultados para catalogar e o mesmo tempo avaliar o contexto da cadeia de caracteres e as perguntas de MQ e SQ. Para a catalogação, foram utilizados os seguintes critérios de exclusão listados na Tabela 3.



Tabela 3: Critérios de avaliação

Critério	Descrição
Critérios 1	Filtro com período de 10 anos, 2008 a 2018;
Critérios 2	Remover livros, relatórios técnicos, dissertações e teses;
Critérios 3	Remover documentos repetidos, com menos de 4 páginas e que não estão em inglês;
Critérios 4	Remover todas as publicações que não usam os termos de pesquisa <i>industry 4.0</i> , <i>smart factory</i> , <i>intelligent factory</i> , <i>smart manufacturing</i> or <i>internet of things</i> no título, resumo ou palavras-chave.
Criteria 5	Remova todas as publicações que não abordam a previsão ou o monitoramento aplicado a <i>Industry 4.0</i> , <i>smart factory</i> , or <i>IoT</i> como modelo, método ou arquitetura.

Fonte: O Autor

Após a catalogação realizada no Google Acadêmico, a *string* foi adequada para que pudesse realizar a busca nas bases da ACM, IEEE, ScienceDirect, Scopus e Web of Science. Após, foi repetido o processo removendo os artigos duplicados. O resultado da estratégia de busca está na Figura 8.

Com a realização da análise de cerca de 100 artigos, foi identificado que alguns termos traziam conteúdos que não atendiam ao critério 5, como: *smart grids*, *logistics*, *supply chain*, and *cybersecurity*. A linha de pesquisa destes artigos foca em informações, estratégias e estruturas dentro da I4.0, mas não aplica à PdM.

Ao final da primeira seleção apresentada na Figura 8, foram selecionados 118 artigos, baseados no resumo, palavras-chave, verificação do conteúdo das seções e conclusão. No caso dos 118 artigos, foi realizada a leitura completa e o critério primário aplicado foi o 5, foi validado se o artigo contribuiu para a aplicação da PdM levando em consideração o monitoramento baseado no tempo e não apenas a realização de um alerta.

Depois de finalizar a aplicação dos critérios, alguns artigos com conteúdo relevante à PdM ou exemplos de aplicações na I4.0 foram adicionados. Os artigos selecionados são listados no Apêndice A com tipos de publicações, editores e nomes de conferências ou periódicos do corpus resultante.

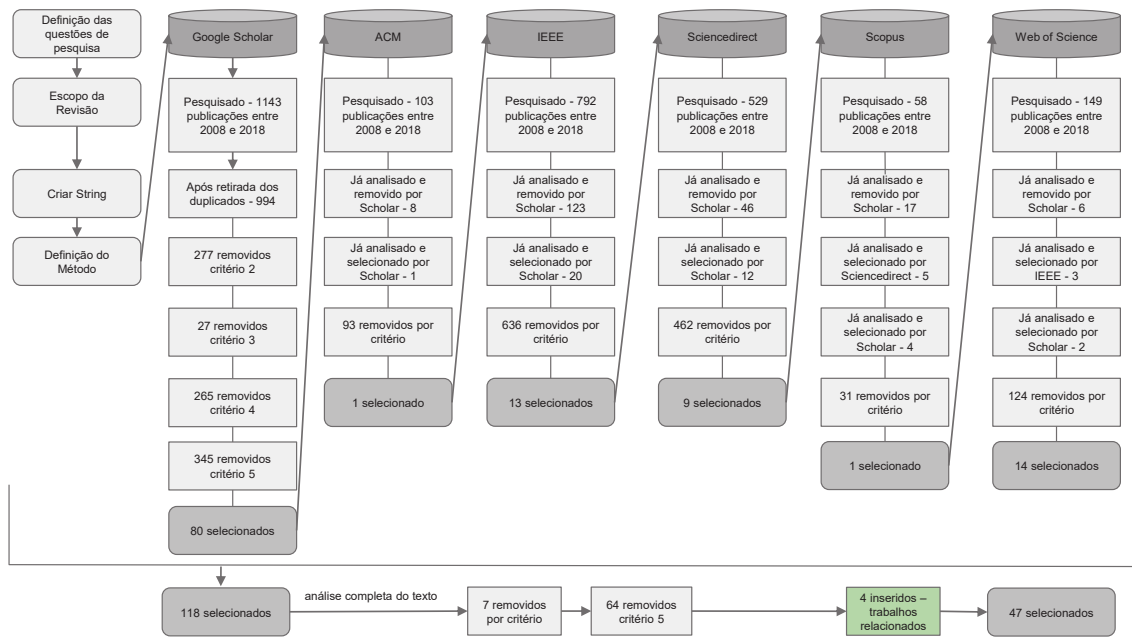
### 3.1.4 Resultados e Discussão

Após a leitura dos artigos, são apresentados os resultados e discussões com base nas questões previamente elaboradas com o objetivo de responder ao MQ.

#### **SQ1 - Quais são os principais meios de divulgação de pesquisas alinhadas à PdM na I4.0?**

Para responder a esta questão, é criada a Figura 9 que apresenta a distribuição dos artigos por editora e tipo de publicação. O gráfico de setores mostra os resultados para jornais e conferências, no gráfico de barras pode-se destacar IEEE e Elsevier como editores com o número mais significativo de publicações. A análise da distribuição dos artigos utilizando

Figura 8 – Triagem de pesquisa.

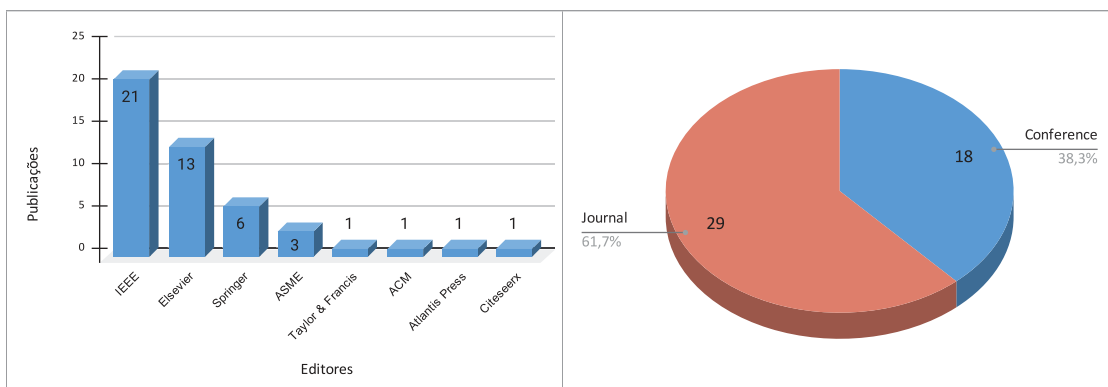


Fonte: O Autor

meios de publicação reforça a observação de que as aplicações da PdM apresentam uma característica multidisciplinar envolvendo diversas áreas do conhecimento, no caso da ACM, a Computação ainda não apresenta um volume de publicações vinculadas à PdM. Precisamente porque a computação é uma das tecnologias utilizadas e a PdM requer conhecimento alinhado à automação, mecânica e elétrica gerando mais conteúdo em outros meios de divulgação.

Os periódicos e conferências que apresentaram mais de uma ocorrência foram: dois artigos na *IEEE Conference on Automation Science and Engineering (CASE)*, *Journal of Manufacturing Science and Engineering* e *CIRP Annals - Manufacturing Technology*, três no *Journal of Manufacturing Systems* e *IEEE Access*.

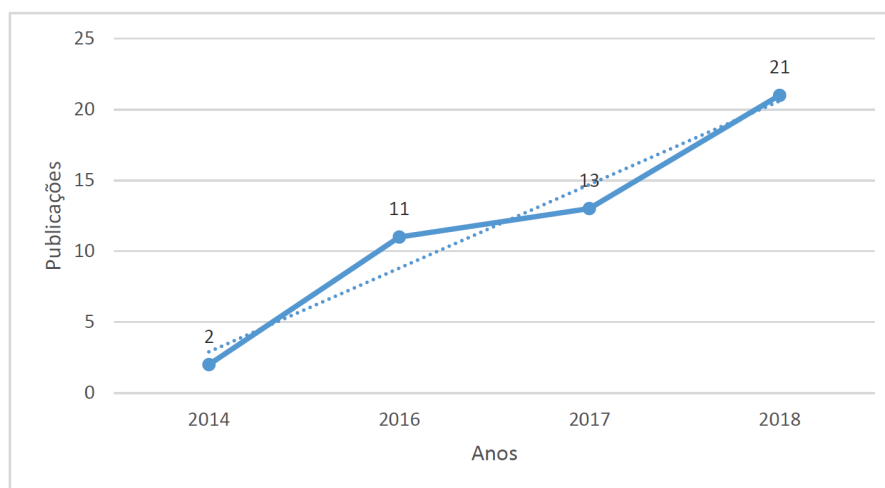
Figura 9 – Distribuição das publicações por editor e tipo.



Fonte: O Autor

Na Figura 10 é possível visualizar a tendência da linha pontilhada referente ao crescimento anual das publicações, com ênfase a partir de 2014. Fator que pode ser destacado devido o crescimento da disseminação da IoT na I4.0.

Figura 10 – Distribuição das publicações por ano.



Fonte: O Autor

## SQ2 - Quais são os modelos preditivos mais comumente encontrados no Industry 4.0?

Está questão foi respondida em diferentes contextos utilizados para avaliar os artigos: primeiro, foram as informações relacionadas aos três métodos de classificação da predição já descritos: baseado em modelo físico, conhecimento e orientado a dados. Em segundo lugar, uma discussão sobre as abordagens que aplicam Redes Neurais Artificiais (RNAs), ML e algoritmos. Em terceiro lugar, é discutida a maturidade dos artigos que abordam conteúdos e metodologias comumente encontradas nas Engenharia: PHM, CBM e RUL.

A discussão é iniciada pelo contexto dos três métodos de classificação de predição, foram listados os artigos na Tabela 4, e é feito uma breve descrição destes artigos.

Tabela 4: Classificações da predição.

Classificação	Artigos
Baseados em modelo físico ( <i>Physical model-based</i> )	(LIU et al., 2018; KWON et al., 2016; ROY et al., 2016)
Baseado em conhecimento ( <i>knowledge-based</i> )	(KIANGALA; WANG, 2018; NEMETH et al., 2018)
Baseado em dados ( <i>Data-driven</i> )	(KIANGALA; WANG, 2018; WU et al., 2017a; NEMETH et al., 2018; WANG et al., 2018; WU et al., 2016; WU et al., 2017d; LEE; JIN; BAGHERI, 2017; KWON et al., 2016; KAUR et al., 2018; WU et al., 2017c; JANTUNEN et al., 2016; ROY et al., 2016; WU et al., 2017b; XIA et al., 2017; MAN; ZHOU, 2018; CHO et al., 2018a; REN et al., 2018; CIPOLLINI et al., 2018)
Híbridos	(SAEZ et al., 2018; DEUTSCH; HE, 2018; AYAD; TERRISSA; ZERHOUNI, 2018; KWON et al., 2016; YANG; ZHANG, 2016; HE; GUO; ZHENG, 2018)

Fonte: O Autor

As soluções usando o método *Physical Model Based* tipicamente trazem abordagens híbridas. Pode-se destacar um modelo dinâmico de *Deep Learning* (DL) baseado na compensação incremental para o diagnóstico de falhas em equipamentos com rolamentos (LIU et al., 2018) e uma solução denominada manutenção contínua realizou um estudo sobre *Self-healing* usando IoT e computação em nuvem (ROY et al., 2016). Em Kwon et al. (2016) apresentam o PHM baseado em IoT e criou um serviço de garantia preditiva e destacou os melhores resultados usando uma abordagem híbrida.

As abordagens baseadas no conhecimento são comuns em alertas de monitoramento e também em soluções híbridas. São destacados dois artigos: um subdivide duas classes de predição, um modelo baseado em estatísticas e outro monitoramento de condições de componentes. A solução de monitoramento é baseada em conhecimento e está relacionada ao exame dos processos de desgaste em componentes mecânicos. O modelo estatístico é responsável pela previsão, usa dados orientados para a evolução da solução vinculada à previsão e ao monitoramento e nomeia a solução como uma condição baseada na nuvem (KIANGALA; WANG, 2018). O segundo artigo traz a manutenção prescritiva com revisão discutindo modelos evolutivos usando dados orientados (NEMETH et al., 2018).

Dos três métodos, é destacado as abordagens baseadas em dados, devido ao aumento na aquisição de dados e à utilização de teorias relacionadas à IA, especialmente as RNAs. Foi analisado cinco trabalhos de um grupo que cita o crescimento da inteligência baseada em dados, com soluções preditivas usando *Random Forest* (RF) afirmam que em alguns casos, técnicas de aprendizado de máquina não são computacionalmente eficientes para o PHM (WU et al., 2017a; WU et al., 2016; WU et al., 2017d; WU et al., 2017c; WU et al., 2017b)). Outro exemplo são as soluções de detecção de anomalias que exigem volumes de informações históricas, em Wang et al. (2018) é comparada a detecção de anomalias em um e em vários sensores.

Com relação à predição do RUL usando dados orientados, em Man e Zhou (2018) são apresentadas duas categorias de falhas mecânicas: uma denominada *soft failure* que informa que o componente falhará e a outra *hard failure* que é quando o componente para. Em Kaur et al. (2018) é discutido a união do CBM com à PdM e apresenta um *framework* chamando-o de manutenção preditiva Baseada em condições (CBPdM). Uma estrutura para prever o RUL usando *autoencoder* e *Deep Neural Networks* (DNN) é abordado em Ren et al. (2018) e reforça o crescimento de dados orientados com uso promissor para suportar a predição do RUL. Com colaborações essenciais, Jantunen et al. (2016) trazem princípios de monitoramento de desgaste (tempo, carga e desgaste) e formas de medição, análise de sinais, diagnóstico e prognóstico.

Como já mencionado, o uso da IA traz diferenciais para as soluções baseada em dados, e é possível destacar algumas aplicações: uma estrutura CPS usando dados orientados com DL e *Restricted Boltzmann Machine* (RBM) (LEE; JIN; BAGHERI, 2017). Um modelo estatístico baseado em dados aplicado a sistemas de propulsão naval usando os métodos ML

supervisionados e não supervisionados (CIPOLLINI et al., 2018). Uma previsão e diagnóstico de falhas com base no *Stacked Denoising Autoencoder* (SDA) e DNN (XIA et al., 2017). Uma solução híbrida de ML, não e semi-supervisionada para PdM em fábricas inteligentes (CHO et al., 2018a)).

Algumas estratégias híbridas já foram citadas, mas alguns artigos têm uma descrição da solução focada nessa característica, por exemplo, o caso que estimou o estado operacional do ativo com base na funcionalidade dinâmica, e suas interações no que foi chamado de "*data-based classification model based on supervised learning*" (SAEZ et al., 2018). A solução que usou o *Deep Learning-Based* com RBM para PdM em componentes rotativos e comparou os métodos existentes no PHM (DEUTSCH; HE, 2018). Uma proposta de Modelo Inteligente Híbrido de classificação e regressão para o diagnóstico de múltiplas falhas e previsão do RUL que foi denominada *Network of Extreme Learning Machines* (N-ELM) (YANG; ZHANG, 2016). Um modelo híbrido usando abordagem física e baseada em dados para determinar a situação atual do equipamento e executar a previsão do RUL (AYAD; TERRISSA; ZERHOUNI, 2018). Uma discussão dos recentes desafios e avanços, introduzindo um caso chamado *Pavatar*, o sistema de IoT industrial do mundo real que permite vigilância abrangente e diagnósticos remotos para *Ultrahigh-voltage Converter Station* (UHVCS) (HE; GUO; ZHENG, 2018). No entanto, grande parte das aplicações, se analisadas com cuidado, encontrarão o uso de métodos híbridos ou alguma informação necessária que não tenha sido rotulada com uma classificação de previsão. Em muitas das soluções de monitoramento, mesmo quando usadas abordagens baseadas em dados, serão encontrados recursos baseados em conhecimento para realização dos alertas.

Respondendo ao contexto das classificações, foi identificado que em propostas envolvendo casos de PdM com previsão baseada no tempo, é necessário usar dados orientados, primeiro devido à necessidade de dados históricos e, em alguns casos, a validação e verificação de dados heterogêneos. No entanto, alguns trabalhos contrastam deficiências no uso de dados tradicionais. Os recursos extraídos são robustos e requerem especialistas de domínio, e eventos históricos que muitas vezes são simulados em laboratório não consideram as diferentes características, com isso, a importância de ter um mínimo de conhecimento físico dos componentes que serão avaliados (CHO et al., 2018a; KWON et al., 2016; MAN; ZHOU, 2018; HE; GUO; ZHENG, 2018). Outro problema é a dificuldade de extrair dados rotulados para uso em soluções usando técnicas de ML supervisionadas que requerem dados classificados (XIA et al., 2017).

O segundo contexto para responder ao SQ2 está relacionado a soluções que utilizam IA com RNAs, ML e soluções algorítmicas. Para esse contexto, os artigos foram divididos em três blocos principais, métodos que aplicam RF, DL e outras estratégias utilizando RNAs e ML. Nesse contexto, alguns artigos que já foram descritos anteriormente não serão repetidos e outros serão complementados. Os artigos estão listados na Tabela 5.

Tabela 5: Aplicações com RNAs, ML e soluções algorítmicas.

Solução	Artigo
<i>Random Forest</i>	(WU et al., 2017a; WU et al., 2016; WU et al., 2017d; WU et al., 2017c; YANG; ZHANG, 2016; WU et al., 2017b; MULRENNAN et al., 2018; AMIHAI et al., 2018)
<i>Deep Learning</i>	(DEUTSCH; HE, 2018; LEE; JIN; BAGHERI, 2017; HE; HE, 2017; LEE, 2017; YAN et al., 2018; LIU et al., 2018; XIA et al., 2017; REN et al., 2018; AMIHAI et al., 2018)
Outras estratégias ligadas às RNAs e ML	(SEZER et al., 2018; WU et al., 2017a; AYAD; TERRISSA; ZERHOUNI, 2018; LAMONACA et al., 2018; XIA et al., 2017; QIN; LIU; GROSVENOR, 2018; MAN; ZHOU, 2018; CIPOLLINI et al., 2018)

Fonte: O Autor

Neste contexto, é iniciado com um grupo de pesquisas que utilizaram RF, pois devido às suas características, seus modelos colaboram na identificação e visualização de problemas relacionados ao ML, principalmente na detecção de anomalias. Um algoritmo de ML baseado em nuvem foi aplicado RF em paralelo com *MapReduce*, resultando no que foi denominado como *MapReduce-Based Parallel Random Forests* (PRFs) (WU et al., 2017a; WU et al., 2016). Toda a estrutura é montada em um sistema de computação em nuvem escalável, e os testes foram realizados usando dados de monitoramento de condições coletados de experimentos em ativos de fresamento. Também foram realizadas análises comparativas de três RNAs, *Support Vector Regression* (SVR) e RF para desgaste de ferramentas em fresamento foram realizadas (WU et al., 2017c; WU et al., 2017b). Outra proposta, apresenta o método de *Fog Computing* para aquisição de dados de força, velocidade de rotação, temperatura, vibração, emissão acústica e sensores de torque (WU et al., 2017d). Os dispositivos executam a aquisição de dados e executam o trabalho de "limpeza", enquanto a nuvem realiza as atividades "avançadas" de previsão e análise de dados. Os testes foram realizados em torno de 50 sensores instalados em 16 bombas selecionadas e máquinas CNC para coletar dados em tempo real relacionados a vibrações e consumo de energia.

É destacado também uma propostas com RF aplicada em polímeros, é chamada de *soft sensor* que mede a pressão e a temperatura para a previsão das propriedades de tração do *Poly lactide* (PLA) (MULRENNAN et al., 2018). Foram quatro abordagens utilizadas: *Bagging*, RF, Análise de Componentes Principais (PCA) com *Bagging* e PCA com RF. Os testes usaram R para gerar e randomizar os dados, e o artigo relata que a meta foi alcançada, mas a ideia é criar um sistema de verificação de qualidade online que reduza a necessidade de teste *offline*, custo e desperdício. Outra proposta, utilizando os dados de vibração, foram coletados de 30 bombas industriais em uma fábrica química durante dois anos e meio, os algoritmos de RF e a técnica de persistência foram utilizados e os *Key Condition Indices* (KCI) foram utilizados como CBM para monitoramento (AMIHAI et al., 2018).

O segundo grupo significativo de soluções foram as relacionadas a DL. Uma abordagem de

predição do RUL usa a Deep Belief Network (DBN) como uma versão empilhada de uma RBM que também descreve a rede neural DBN-Feedforward (FNN) (DEUTSCH; HE, 2018). Dois testes foram realizados, um usando arquivos disponíveis da NASA relacionados a dados de engrenagens cônicas em espiral - indicadores de condição de vibração (CIs) e outro com a massa de detritos de óleo (ODM) para detectar *pitting damage*. O segundo teste foi realizado em laboratório usando o Rolamento Cerâmico Híbrido. Um exemplo de um algoritmo dinâmico baseado em compensação incremental com DL usa *Support Vector Machine* (SVM) para classificar os modos ponderados de maneira supervisionada, e o algoritmo *Backpropagation* (BP) usado para ajustar o modelo, para completar o ajuste dinâmico e compensatório de DL foi publicado por Liu et al. (2018).

Soluções usando DL introduzem uma característica de aplicação e dados um pouco diferentes de outros métodos, por exemplo, geração de Emissões Acústicas (AE) e imagens são mais comuns em DL. Um exemplo é a proposta de um "*framework of cyber-physical ball screw prognostics systems*" com aquisição de dados usando acelerômetros, termômetros e sensores de AE com diagnóstico preditivo de diferentes modos de falha do componente com algoritmo RBM (LEE; JIN; BAGHERI, 2017). Outro exemplo de método com AE usando DL realiza diagnósticos de falhas em mancais, aproximando os pré-processos dos sinais do sensor usando a transformada de Fourier de curta duração (STFT) (HE; HE, 2017). Uma matriz de espectro simples obtida pelo STFT, e uma estrutura de DL otimizada para recuperação de armazenamento de memória grande denominado (LAMSTAR), foi construída para diagnosticar falhas.

Uma pesquisa que chamou a atenção pela analogia apresentada foi um conceito de *Device Electrocardiogram* (DECG), utiliza um algoritmo baseado em *autoencoder* e operação de regressão para a predição do RUL de equipamentos industriais com testes em CNC (YAN et al., 2018). Com importante documentação referente a PHM e RUL baseado em DL, o artigo traz o pseudocódigo do Algoritmo de *Deep Denoising Autoencoder* e relata que "uma das vantagens mais óbvias do DL é sua capacidade de extrair os recursos automaticamente como uma Rede Neural Convolucional (CNN) e Rede Neural Recorrente (RNN)". Outro ponto a ser destacado é que, além do PHM, o artigo discute FIS e faz uma relação entre os dois.

Outras propostas diferenciadas foram relacionadas, como um interessante estudo de *frameworks* para uso em CPS para múltiplas empresas e multiprodutos (LEE, 2017). Uma estrutura usando sensores de torque mede o campo magnético e seus graus em um mecanismo de compressão, as alterações são enviadas para a nuvem usando um dispositivo conhecido como *beacon*. O artigo faz uma comparação com SVR, *Radial Basis Function* e *Deep Belief Learning* baseado em DL para identificar dois tipos de falhas: circuito curto e soldagem insuficiente entre o cabo e um conector. Outro caso apresenta uma nova estrutura de predição baseada em DNN denominada "*A novel eigenvector based on time-frequency-wavelet joint features is proposed to effectively represent bearing degradation process*" (REN et al., 2018).

O último bloco de soluções encontradas no corpus foi dividido em um conjunto de

estratégias que aplicaram RNAs e métodos de ML. Pode-se iniciar com uma arquitetura de CPS de baixo custo para pequenas empresas que medem as variáveis de temperatura e vibração de um CNC com *Recursive Partitioning and Regression Tree* (RPaRT) em R (SEZER et al., 2018). Outra solução uma Rede Neural (NN) e Redes Neuro-Difusas com uma solução híbrida usando modelo de base orientada a dados para determinar a situação atual do equipamento e prever o RUL é apresentada em Ayad, Terrissa e Zerhouni (2018). No entanto, o estudo descreve detalhadamente a parte física da proposta. Diferentemente de Man e Zhou (2018) que explicam detalhadamente as técnicas matemáticas usadas como variações validadas por sinais de degradação estocástica, processo de Wiener, definição de parâmetros usando o método de *Maximum Likelihood Estimation* (MLE) e previsão de Vida Residual Média (MRL). O artigo realiza comparação com Back-propagation Neural Network (BPNN) e NN usando R e os testes foram baseados no processo de partida de motores automotivos com 13 baterias de chumbo-ácido.

Outro caso realiza métodos de análise de dados para facilitar a compreensão e a previsão do consumo de energia dos processos de produção digital sob uma estrutura de IoT (QIN; LIU; GROSVENOR, 2018). O estudo é realizado em um Sistema Seletivo denominado *Laser Sintering System* (LSS) em manufatura aditiva, utilizando três técnicas de análise de dados: Regressão Linear, Árvore de Decisão e BPNN. Nos resultados comparativos, as soluções utilizando DT e BPNN apresentaram melhores resultados que Regressão Linear.

Um caso diferenciado propõe a predição do estado de "decaimento" dos componentes principais em um *Naval Propulsion Sys* (NPS) para CBM, formulando o modelo estatístico baseado em dados (CIPOLLINI et al., 2018). Vários componentes são listados para a degradação da Turbina a Gás, Compressor a Gás, Casco e Hélice. Para cada degradação, utilizou-se um algoritmo, e a documentação relatada como estratégias supervisionadas: métodos de Kernel, Bayesianos e "preguiçosos", para os casos não supervisionados foi utilizado SVM e *k-Nearest Neighbors* (KNN).

Para finalizar este contexto de SQ2, um Monitoramento de Saúde Estrutural baseado no paradigma da IoT, usado com sucesso em edifícios históricos, pontes, estruturas civis e solos. Após a coleta de dados as predições são executadas a partir de NN e Algoritmos Genéticos (AGs), o artigo não indica especificamente quais NNs foram utilizados, mas o problema de predição é diferente dos demais selecionados e traz uma proposta que pode ser utilizada em plantas industriais (LAMONACA et al., 2018).

Para responder ao contexto relacionado ao uso de RNAs, ML e soluções algorítmicas, pode-se dizer que o intervalo de abordagens utilizadas não é muito grande e existem padrões específicos para cada tipo de necessidade. O que está claro é que, nas soluções que envolvem um volume matemático maior, é necessário conhecimento físico para normalizar recursos e parametrização de funções de previsão. Como já mencionado, o RF é frequentemente usado em problemas relacionados à anomalia, e também fornece uma visualização da estrutura do problema. Também pode-se destacar o crescimento do uso de DL em estudos mais recentes.



De qualquer forma, os artigos que trazem um método, *framework* ou arquitetura focam na explicação da estrutura física e na aquisição de dados, os artigos apresentados são aqueles que apresentaram um mínimo de informações relacionadas ao processo lógico de predição, com alguns casos com contribuições significativas (DEUTSCH; HE, 2018; MAN; ZHOU, 2018; MULRENNAN et al., 2018; REN et al., 2018).

Como resposta ao terceiro e último contexto do QS2, foi destacado os artigos que utilizam os conceitos de prognóstico PHM, RUL e CBM em sua proposta, modelo, *framework* ou arquitetura. Foi identificado que é essencial destacar trabalhos que utilizam essas abordagens em suas soluções, pois apresentam resultados diferenciados. Além destes, foram encontradas algumas derivações, por exemplo, manutenção predeterminada em Cipollini et al. (2018) e manutenção preditiva baseada em condições (CBPdM) em Kaur et al. (2018). Os artigos que abordaram as estratégias de prognóstico para a realização da PdM estão listados na Tabela 6.

Tabela 6: Termos importantes para o prognóstico.

Termos para prognóstico	Artigos
<i>Prognostics and Health Management</i> (PHM)	(LEE; BAGHERI; KAO, 2014; KIANGALA; WANG, 2018; LEE et al., 2015; WU et al., 2017a; ROY et al., 2016; WU et al., 2016; JIN et al., 2017; WANG et al., 2018; DEUTSCH; HE, 2018; AYAD; TERRISSA; ZERHOUNI, 2018; LEE; JIN; BAGHERI, 2017; YAN et al., 2018; KWON et al., 2016; KAUR et al., 2018; WU et al., 2017c; TERRISSA et al., 2016; WU et al., 2017b; MAN; ZHOU, 2018; REN et al., 2018)
<i>Condition-Based Maintenance</i> (CBM)	(SEZER et al., 2018; LEE et al., 2015; WANG et al., 2018; SILVA et al., 2016; SCHMIDT; WANG; GALAR, 2017; KWON et al., 2016; KAUR et al., 2018; JANTUNEN et al., 2016; MAN; ZHOU, 2018; CIPOLLINI et al., 2018)
<i>Remaining Useful Life</i> (RUL)	(WU et al., 2017a; ROY et al., 2016; JIN et al., 2017; NEMETH et al., 2018; WANG et al., 2018; DEUTSCH; HE, 2018; AYAD; TERRISSA; ZERHOUNI, 2018; WU et al., 2017d; LEE; JIN; BAGHERI, 2017; YAN et al., 2018; KWON et al., 2016; WU et al., 2017c; TERRISSA et al., 2016; YANG; ZHANG, 2016; WU et al., 2017b; MAN; ZHOU, 2018; REN et al., 2018; AMIHAI et al., 2018)
<i>Predetermined Maintenance</i> (PRM)	(CIPOLLINI et al., 2018)
<i>State of Health</i> (SoH)	(LEE; BAGHERI; KAO, 2014; WANG et al., 2018; AYAD; TERRISSA; ZERHOUNI, 2018)

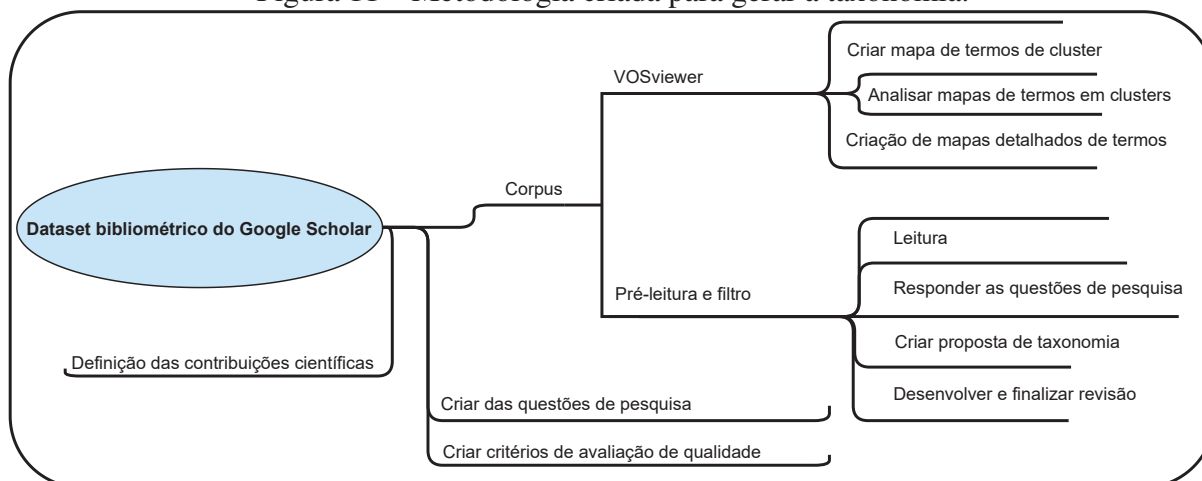
Fonte: O Autor

### **SQ3 - É possível criar uma taxonomia usando os termos encontrados para aplicação preditiva ou monitoramento?**

Para responder a esta pergunta, foram abordados os desafios científicos da revisão, foi realizado a separação de termos e criada uma taxonomia. A Figura 11, demonstra a sequencia da metodologia utilizada, com a realização da pesquisa e definição dos artigos foi iniciada a separação e discussão dos resultados. Para isso, a ferramenta VOSviewer foi utilizada para

contribuir principalmente na visualização dos principais termos encontrados. O resultado apresentado foi mais expressivo, pois foi possível criar uma taxonomia mais abrangente do que a inicialmente planejada.

Figura 11 – Metodologia criada para gerar a taxonomia.



Fonte: O Autor

Para estabelecer razões lógicas para o processo de definição taxonômica, foram adotados três critérios para criar a taxonomia da I4.0 com foco em PdM:

- **Primeiro critério:** Gerar mapeamento e o *clustering* usando o VOSviewer, ferramenta que implementa algoritmos e métodos de otimização do *Smart Local Moving* (SLM) criado pelo Centro de Estudos de Ciência e Tecnologia (CWTS) (KLAVANS; BOYACK, 2017). O primeiro processo foi a geração de um arquivo com as informações vitais para criar os mapas, neste caso, autores, termos e citações. Para isso, foi utilizado o Scopus e realizada uma busca individual do corpus selecionado. Após este processo, foi importado o arquivo pelo VOSviewer de acordo com o manual (ECK, 2016) e aplicado métodos de dados bibliométricos, filtragem e relacionamento por co-ocorrências de palavras-chave. A análise de co-ocorrência consiste em analisar os links entre as palavras usando algoritmo de linguagem natural (ECK, 2016). Para evitar a redundância, foram aplicados filtros para termos semelhantes de acordo com a Tabela 7. Esta técnica é aplicada para evitar que palavras sinônimas, escrita diferente ou mesmo significado sejam plotadas no mapa separadamente.

Fonte: O Autor

- **Segundo critério:** Verificar todos os termos que estão relacionados hierarquicamente com relação direta ao termo I4.0 com foco em PdM, assim, usando o mapa de relação e calor do VOSviewer obtendo os mapas da Figura 12a um mapa de relacionamento e 12b de calor. Com os mapas, é possível visualizar que os principais termos utilizados na *string* foram contemplados nos resultados dos artigos selecionados.

Tabela 7 – Arquivo de configuração de termos de co-ocorrência

<b>Termo</b>	<b>Substituir por</b>
<i>learning algorithms</i>	<i>machine learning</i>
<i>learning systems</i>	<i>machine learning</i>
<i>internet of thing</i>	<i>internet of things</i>
<i>internet of thing (iot)</i>	<i>internet of things</i>
<i>internet of things (iot)</i>	<i>internet of things</i>
<i>cyber physical systems</i>	<i>cyber physical system</i>
<i>cyber-physical systems</i>	<i>cyber physical system</i>
<i>cyber physical system (cpss)</i>	<i>cyber physical system</i>
<i>cyber physical systems (cpss)</i>	<i>cyber physical system</i>
<i>cyber-physical systems (cps)</i>	<i>cyber physical system</i>

A partir deste critério pode-se destacar a definição dos principais termos encontrados para I4.0 com foco em PdM na Tabela 8.

Tabela 8 – Termos-chave para gerar uma raiz para o Indústria 4.0 com foco em PdM

<b>Termos-chave</b>
Big Data
<i>Cyber-physical systems (CPS)</i>
<i>Smart Manufacturing/Manufacture</i>
<i>Internet of Things (IoT)/Industrial Internet of Things (IIoT) - Figura 14</i>
<i>Machine Learning/Artificial Intelligence</i>
<i>Predictive Maintenance/Maintenance/Fault prognosis</i> Figura - 13

Fonte: O Autor

- **Terceiro critério:** Para cada termo significativo identificado na Tabela 8 foi realizada uma representação do próximo nível da árvore taxonômica, verificando sua relação direta, selecionando os termos que pertencem ao mesmo *cluster* de acordo com a Figura 13 e Figura 14. Os termos que não mantiveram a conexão direta foram excluídos e outros conectados, se necessário. O mapeamento foi executado com todos os termos-chave e os resultados de cada *cluster* são demonstrados na Tabela 9.

A Figura 13 apresenta as principais ligações com os seguintes termos: manutenção, manufatura inteligente, Big Data, sistemas de suporte à decisão, manipulação de dados e sistema de produção.

Tabela 9: Termos-chave e *clusters* relacionados mapeados

<b>Termos-chave</b>	<b>Clusters</b>
Big Data	<i>maintenance, PdM, data handling, decision support systems, production system</i>
CPS	<i>computer architecture, multi-agent systems, decision making, manufacturing industries, predictive maintenance, manufacture, IoT, RUL</i>

continua na próxima página

Tabela 9 – continuação da página anterior

Termos-chave	Clusters
Smart Manufacturing	<i>industry 4.0, CPS, computer architecture, multi-agent systems, decision making, life-cycle, manufacture, embedded systems</i>
IoT - Figura 14	<i>monitoring, conditions monitoring, big data, cloud computing, machine learning, intelligent manufacturing, industrial research, industrial environment, fault detection, RUL, deep learning</i>
AI	<i>metadata, PHM, systems engineering, decision trees, failure, forecasting</i>
PdM Figura 13	<i>maintenance, smart manufacturing, Big Data, decision support systems, data handling and production system</i>

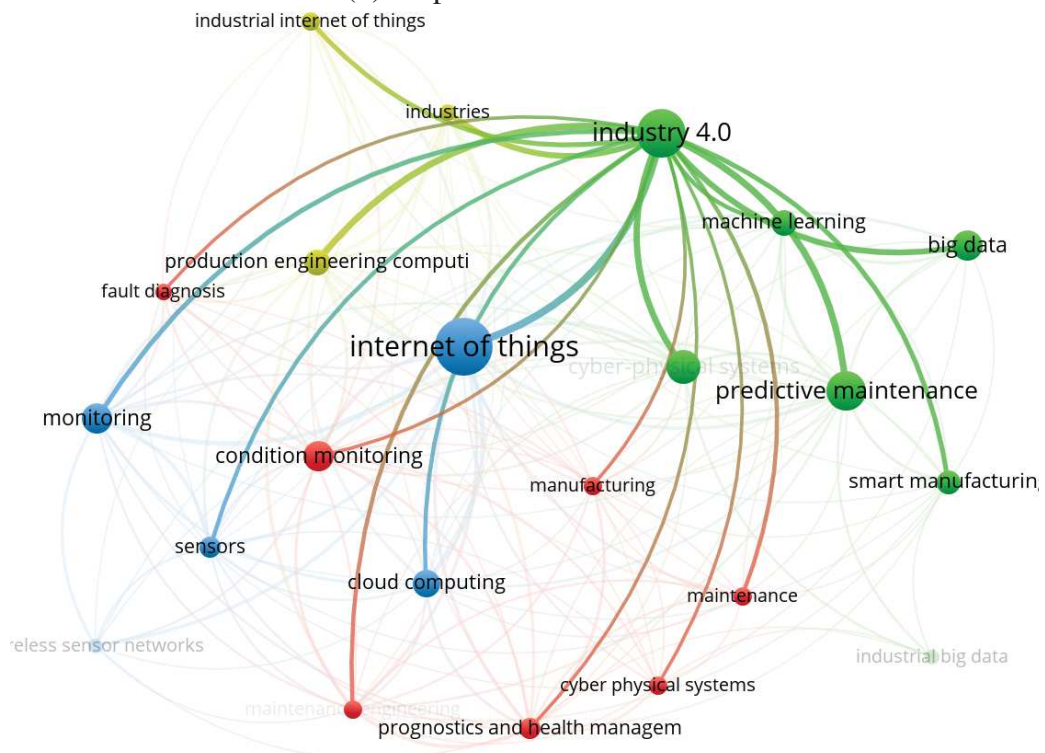
Fonte: O Autor

O *cluster* IoT na Figura 14, mapeou o mesmo processo e apresenta os seguintes termos: monitoramento, monitoramento de condições, Big Data, computação em nuvem, aprendizado de máquina, manufatura inteligente, pesquisa industrial, ambiente industrial, detecção de falhas, RUL, e *Deep Learning*.


Depois de cumprir todos os três critérios, foi possível criar a taxonomia da Figura 15. Com base nos artigos selecionados e discussões realizadas nos SQs, os ambientes CPS podem ser considerados como os precursores do *Smart Factoring*, por serem os primeiros trabalhos a trazerem a provocação do uso dados além da possibilidade de uma aplicação *Machine to Machine* (M2M). O mesmo ocorre com o prognóstico, o PHM utilizou uma ideia de monitoramento inteligente antes do surgimento da PdM. O uso de IoT também é algo real, mas ainda é encontrado em aplicações em soluções legadas ou protótipos para aquisição de dados e estudos de ML e PdM.

Como principal contribuição na revisão, a proposta taxonômica da Figura 15 pode ser detalhada da seguinte maneira: iniciada com o item **monitoramento no contexto da I4.0**, termo identificado como a melhor representação do cenário de discussão com o objetivo de criar uma referência para manutenção. Em sequência, o item **tipos de manutenção**, se estende para o **análise baseado no histórico** e **análise baseada no instantâneo**. Análise baseado no histórico, refere-se à manutenção em previsões que podem gerar históricos com características temporais. A partir disso, é apresentado quatro categorias de manutenção: corretiva, preventiva, preditiva e prescritiva (NEMETH et al., 2018). Análise com base no instantâneo são vinculados como ações imediatas, por exemplo, monitoramento de alerta. **Princípios** lista colaborações importantes sobre princípios de monitoramento (JANTUNEN et al., 2016). **Domínios de aplicações** aponta o progresso e aplicabilidade relacionada ao PdM na indústria 4.0 (LEE et al., 2006; LEE et al., 2013; ZERHOUNI et al., 2017)). Em **manutenção preditiva (PdM) no contexto da I4.0** é o núcleo da proposta de taxonomia e, portanto, envolve mais detalhes. **Interações** aborda a manufatura baseada no sistema cibernético e da inovação de

Figura 12 – Mapas gerados com termos relacionados diretamente a I4.0 com foco em PdM. (a) Mapa de conceitos relacionados. (b) Mapa de calor.



(a)

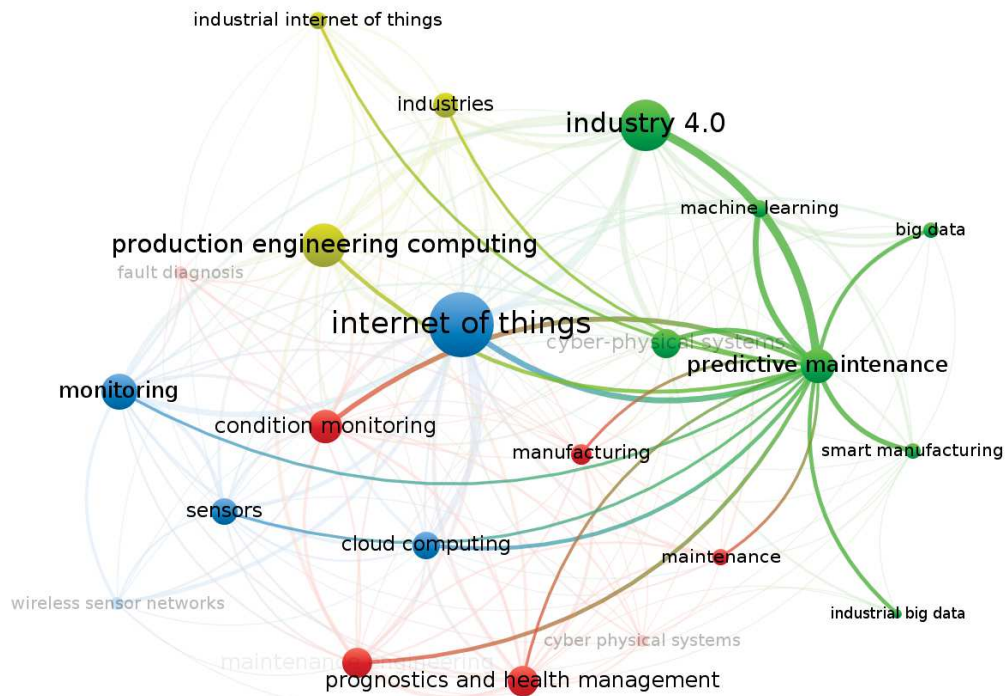


(b)

Fonte: O Autor

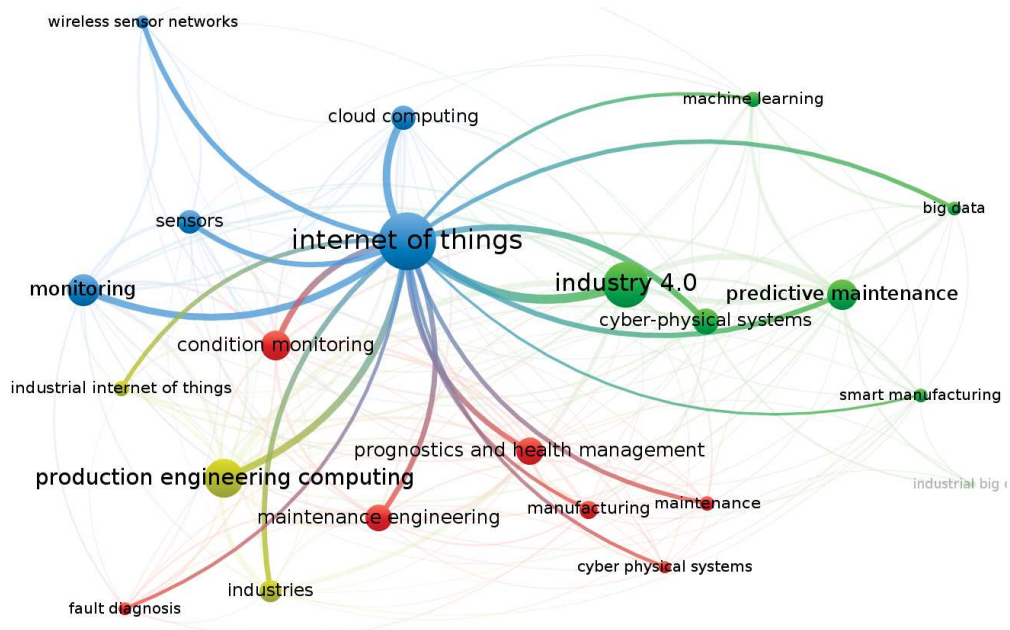
serviços, para que haja interação com produtos e serviços industriais (LEE; BAGHERI; KAO, 2014). Entre todos os itens, **métodos** merece atenção, pois é possível encontrar a abordagem de classificação da PdM utilizada para contextualizar com as respostas do SQ2, por exemplo, **data-driven** com sua importância e aplicação de métodos e modelos relacionados a IA.

Figura 13 – Mapeamento no VOSviewer do *cluster* de PdM.



Fonte: O Autor

Figura 14 – Mapeamento no VOSviewer do *cluster* da IoT.



Fonte: O Autor

**Modelos** enfatiza que a chave para a PdM está relacionada ao PHM. A gestão de saúde de um ativo usa quatro tipos de estratégias. Em **foco de monitoramento**, de acordo com o modelo para a predição do RUL (MAN; ZHOU, 2018), enfatiza-se a importância do conhecimento físico mínimo dos componentes que serão avaliados para verificar se a falha pode ser identificada ou não. Por fim, **objetivos** representa os possíveis resultados obtidos de acordo com essa representação da taxonomia de monitoramento no contexto da I4.0, reduzindo os custos de manutenção e o tempo de inatividade, além de melhorar a manutenção e a qualidade relacionada à manutenção.

#### **SQ4 - Como são os resultados das pesquisas que apresentam modelos, métodos ou arquitetura?**

As discussões relacionadas às aplicações partem do Apêndice B, que apresenta um resumo com as informações primárias sobre os modelos, métodos, *frameworks* e arquiteturas, destaca-se o nome ou descrição dada pela pesquisa, caso aplicado e dados adquiridos para realizar a previsão. Os artigos selecionados que possuem características de pesquisas de revisões ou mapeamentos não foram listados, porque apresentam diferentes desafios e conceitos.

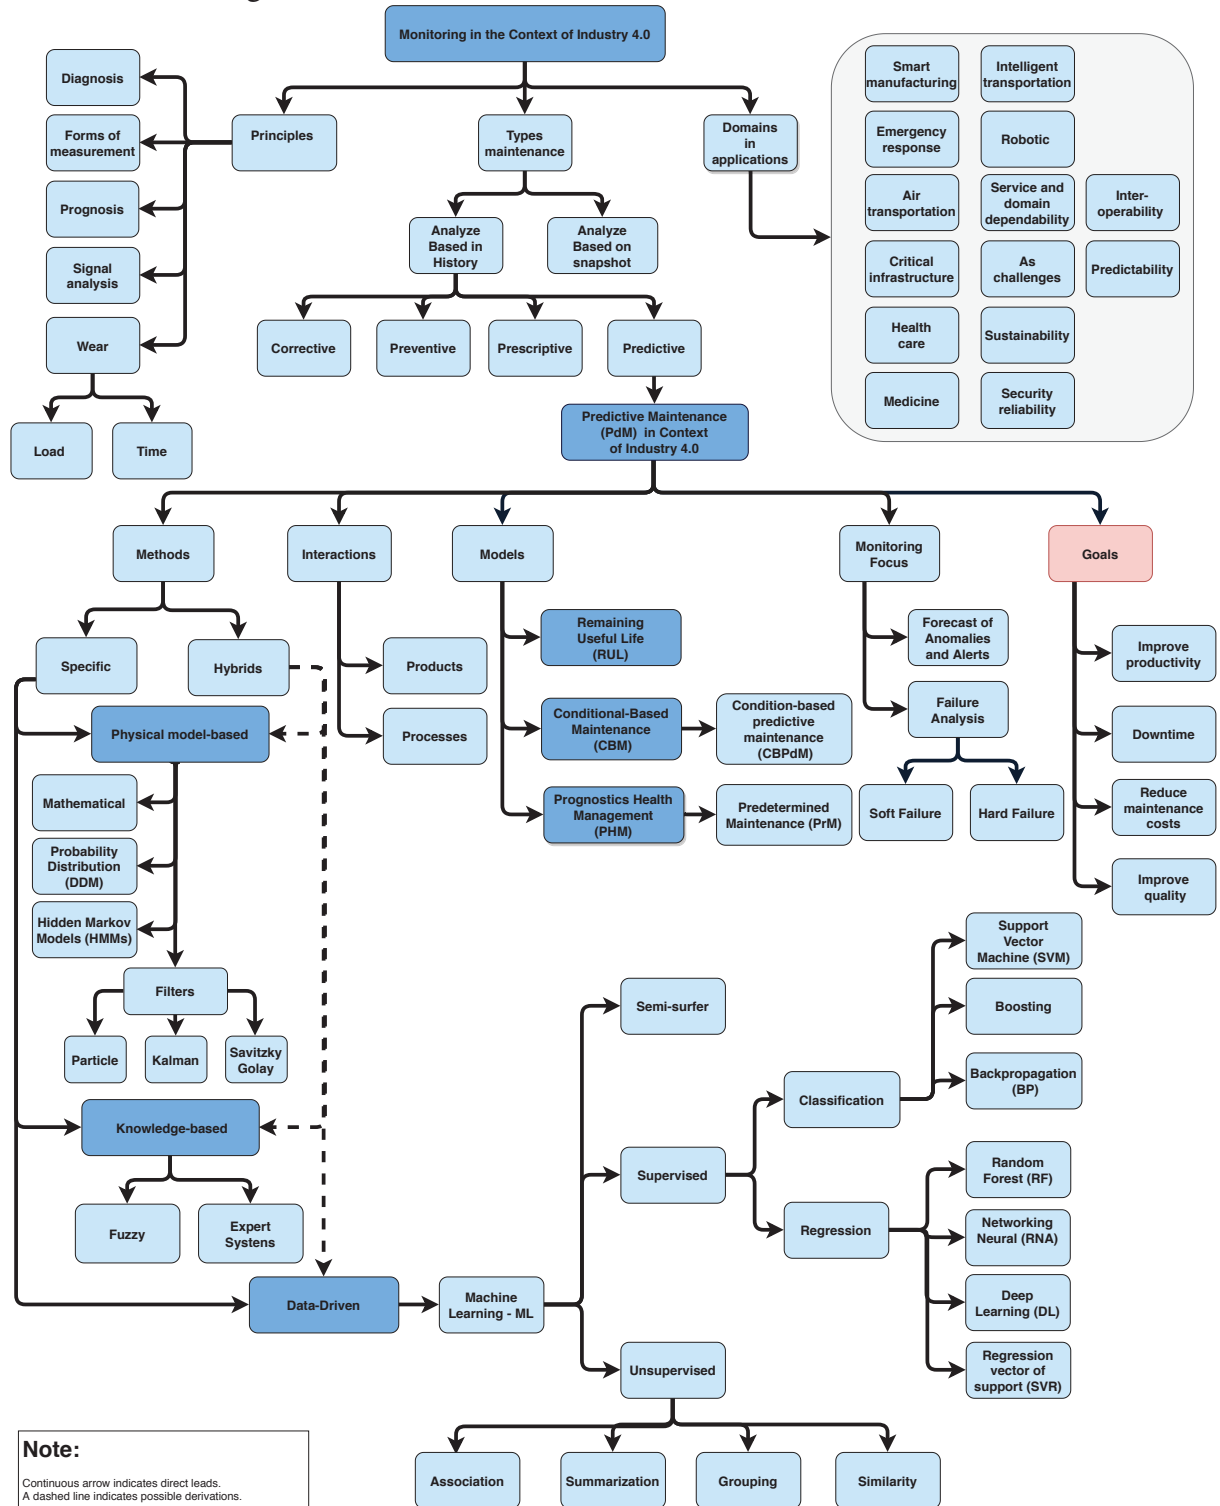
Pode ser observado no Apêndice B que as soluções para avaliação de vibração, temperatura e desgaste em componentes rotacionais foram as mais comuns. Alguns casos com importante documentação trouxeram aplicações usando AE (LEE; JIN; BAGHERI, 2017; HE; HE, 2017), imagens (YAN et al., 2017) e polímeros (MULRENNAN et al., 2018). Também pode-se destacar dois exemplos: um traz um conceito de Eletrocardiograma de Dispositivos (DECG) (YAN et al., 2018) outro uma proposta de I4.0 de baixo custo para Pequenas e Médias Empresas (PME) (SEZER et al., 2018).

A padronização vinculada à aquisição de dados, comunicação, segurança e escalabilidade também é algo necessário para o crescimento e adoção de CPS e IoT, alguns exemplos aplicados foram: *Android Things* (Google), *Predix [General Electric (GE)]*, *Azure IoT Suite* (Microsoft) (HE; GUO; ZHENG, 2018; JIN et al., 2017; LEE et al., 2015; SAEZ et al., 2018; WU et al., 2017d; LEE; JIN; BAGHERI, 2017).

Cada artigo tem sua particularidade, seja o uso do sensor, aquisição, comunicação, forma de retorno, mas em sua maioria as aplicações seguem uma linha de preocupação com o legado, um dos maiores desafios para fábricas que desejam adotar a I4.0 sem a possibilidade de investimento significativo em novos ativos. O objetivo da SQ4 foi encontrar soluções com uma estrutura que pudesse apresentar um fluxo de implantação padrão, mas com aplicabilidade prática diferente.

Antes de apresentar o resultado dos desafios identificados na revisão sistemática e a resposta do SQ5 é feita uma discussão sobre os trabalhos relacionados para avaliar as oportunidades existentes na integração da PdM com o problemas de escalonamento.

Figura 15 – Taxonomia - Monitoramento no contexto da I4.0.



**Note:**  
 Continuous arrow indicates direct leads.  
 A dashed line indicates possible derivations.

Fonte: O Autor



### 3.2 Trabalhos relacionados a integração da PdM com problemas de escalonamento

Como segunda parte dos trabalhos relacionados, o foco foi na busca por aplicações que propõem integração de processos dentro da I4.0, a pesquisa foi baseada em uma *string* básica aplicada no Google Scholar sobre "*maintenance scheduling with scheduling problems*". Após esta primeira busca, foi encontrada a denominação do problema na literatura conhecido como "*joint maintenance and production scheduling problem*" ou "*scheduling problem with availability constraints*" (VARNIER; ZERHOUNI, 2012). A partir dos primeiros artigos encontrados, foi iniciada uma avaliação de citações e trabalhos relacionados nos próprios artigos retornados.

Durante o processo de avaliação das publicações algo que chamou a atenção e que se repetiu em várias pesquisas relacionadas foi o problema sendo abordado em separado ou considerando um índice de desgaste para cada *job* monitorado por um limite mínimo ou máximo (FITOURI et al., 2016; CUI et al., 2018). Em outros casos, a parte ligada à PdM é considerada como resolvida e que já existe a informação disponível do período em que a máquina vai apresentar problemas, seria o caso de uma *constraint* já identificada (VARNIER; ZERHOUNI, 2012; NIKOLAKIS et al., 2018). A principal descrição está na comparação e na tentativa de solução do rearranjo do agendamento de produção com informações de manutenção. O motivo pode estar no fato de ser um problema *NP-HARD* alinhado a aplicação da pesquisa operacional na indústria, trazendo maior ênfase no problema de agendamento do que na solução da PdM.

Em Varnier e Zerhouni (2012), os autores trazem que a manutenção pode ser controlada com dois modos: um nominal que a máquina trabalha sem alterações e um modo degradado, em que são inseridas algumas restrições prevendo a possibilidade de um tempo maior para o RUL, permitindo a previsão de uma manutenção preventiva. Essa estratégia seria considerada como predição. Mesmo que o artigo traga conteúdos relacionados à manutenção e agendamento de produção, o autor considera que os dois modos propostos para sua solução já estão determinados, e não apresenta detalhes de como foi realizado o processo de predição. De qualquer forma, a solução apresentada pelo artigo permite encontrar o melhor horário de operação de produção para cada máquina e, se necessário, é gerado um plano de manutenção preventiva.

Outro trabalho considerado estado da arte, apresenta uma solução para agendamento de produção definindo que as máquinas não estão continuamente disponíveis e apresenta comparações e avaliações de complexidade na ideia de rearranjo ou prevê intervalos de tempos para que as máquinas estejam disponíveis (SCHMIDT, 2000) apud (VARNIER; ZERHOUNI, 2012).

O trabalho de Levrat, Thomas e Iung (2008) traz uma nova categoria de manutenção em que denomina de manutenção oportunista. A ideia é realizar encaixes da manutenção em espaços existentes na agenda de produção, ou seja, não haveria propriamente um rearranjo. Na conclusão do artigo, é reforçada a ideia de que a abordagem proposta tem comprovação

numérica, mas propõem, também estender o algoritmo para suportar a tomada de decisão nas variáveis ligadas à manutenção e não somente na produção.

Em Ladj, Benbouzid-Si Tayeb e Varnier (2016), as abordagens utilizadas já possuem uma linha mais heurística, saindo um pouco das soluções baseadas na programação inteira, mas pode ser destacado, novamente, a colocação do autor de que "primeiro fluxo se concentra em considerar as ações de manutenção separadamente e o segundo enfoca a integração de produção e PdM". Como solução, é proposto um algoritmo híbrido utilizando algoritmos genéticos e um sistema artificial imune, chamado IPro-HGIA que, baseado no PHM, realiza o planejamento de intervenções de produção e PdM com o objetivo de minimizar o custo total. O método proposto utiliza da informação do RUL mas não descreve como ele é obtido, tanto que, no momento que a manutenção é realizada, o algoritmo retorna a identificação do RUL para zero. O artigo pode dar base para a ideia de integração, mas a desta tese ainda prevê a conexão direta entre os dois processos de forma automática.

Com uma característica mais ligada à tomada de decisão, Fitouri et al. (2016) apresentam uma abordagem com a integração das duas agendas e reforça a ideia de *constraints* citando duas linhas: uma levando em consideração a sequência de produção e outra aos recursos. Interessante que os autores apontam o aumento de trabalhos sobre novos métodos de predição de falhas, e este fator pode motivar pesquisas como a que está sendo proposta justamente pela manutenção ser uma função primordial no processo produtivo. Em sua conclusão, é destacada a busca por uma combinação de regras de decisão e a ideia do processo ser *on-line*, além da realização de um estudo comparativo.

Também pode ser destacado o *survey* realizado por Ma, Chu e Zuo (2010) sobre programação determinística com restrições de disponibilidade motivadas pela manutenção preventiva. O artigo traz um importante resultado de catalogação do que foi publicado, mas, novamente, os resultados ficam focados ao problema de agendamento com a previsão de manutenção já solucionado.

Dois artigos mais recentes já confirmam esforços no alinhamentos de ideias de integração dos problemas de agendamento de manutenção e produção. Em Cui et al. (2018) tratam da integração com o objetivo de qualidade e robustez da solução para *flow shops* com incerteza de falha. É proposto um modelo proativo modelado matematicamente resultando em um algoritmo para otimizar a sequência de tarefas e as posições de manutenções preventivas juntamente com os tempos de ociosidade. A exemplo de Fitouri et al. (2016) o algoritmo atribui um nível de desgaste para cada tarefa e estabelece medidas de alerta para determinar a manutenção de forma preventiva e não preditiva.

Por fim, Nikolakis et al. (2018), relatam resultados e dois estudos de caso e fala que os sistemas de manufatura estão mudando para o CPS, e destaca o custo de manutenção e que as atividades de manutenção não seguem mais uma linha corretiva e preventiva e, sim, cronogramas pré-definidos. Também fala que, com o crescimento do CPS, novas soluções escaláveis e distribuídas são necessárias para gerenciar o processo de produção com eficiência,

sendo esta a principal motivação desta tese. Os apontamentos e estudos desta publicação foram as únicas com uma relação de ação contrária, ou seja, o ajuste é realizado no agendamento de manutenção baseado nas informações de um cronograma de produção já existente. O artigo faz parte de um projeto de pesquisa europeu chamado SERENA e que tem o objetivo de realizar pesquisas para produção conectada.

Baseado na publicação de Nikolakis et al. (2018), foi identificado um possível desafio relacionado a realização de uma revisão mais aprofundada de soluções mais atuais. Para entender o cenário dos trabalhos relacionados apresentados, foi criado o comparativo visto no Apêndice C com o objetivo de visualizar de forma macro como as abordagens integram os dois agendamentos. Como resultado pode-se destacar que o foco maior está na solução do problema da produção por ser considerado um NP, mas, com as tecnologias atuais e possibilidade principalmente da aplicação da IA, o processo de manutenção também começa a ganhar destaque e deixa de ser apenas uma *constraint* de entrada, isso contribuí com a ideia de integração e abordagem dos dois problemas.

### 3.3 Oportunidades de pesquisa

As oportunidade de pesquisa discute o resultado da revisão sistemática e resposta à SQ5 que aborda - "Quais são os desafios e questões abertas identificadas?" As percepções sobre este questionamento são:

- **Aplicação PdM baseada em tempo real:** o primeiro desafio e o foco principal da pesquisa foi a aplicação da PdM baseada no tempo (KAUR et al., 2018; WU et al., 2017c; JANTUNEN et al., 2016). Foi possível perceber que há um conjunto de resultados em que é apontada a predição, mas, apenas, o monitoramento de alertas é realizado. Poucas soluções deixam claro que a manutenção pode ser feita levando em consideração o tempo específico de uma determinada condição. Mesmo os artigos selecionados, que atendem a esse critério, não deixam claro que farão a previsão de fato. Um único caso previu um intervalo de 7 dias para falha usando RF (AMIHAI et al., 2018). Outros casos trazem situações como: forma reativa, manutenção de cronograma, operações preventivas programadas e monitoramento de condições de cronograma entre outras denominações (LEE; BAGHERI; KAO, 2014; SEZER et al., 2018; GUNES et al., 2014; LEE et al., 2015; SAEZ et al., 2018; ROY et al., 2016; YAN et al., 2017; WU et al., 2016; SILVA et al., 2016; LEE; JIN; BAGHERI, 2017; LEE, 2017; YAN et al., 2018; KWON et al., 2016; WU et al., 2017c; TERRISSA et al., 2016; YANG; ZHANG, 2016; LI, 2016; WU et al., 2017b; CHO et al., 2018a; CIPOLLINI et al., 2018; HE; GUO; ZHENG, 2018; ARDOLINO et al., 2018)). Há também os casos de manutenção prescritiva que, por sua característica, podem contribuir para esse desafio (MATYAS et al., 2017; NEMETH et al., 2018).

- **Dados heterogêneos, testes de bancada:** parte dos testes aplicados em PdM utiliza bancos de simulação. A explicação para este cenário é a complexidade da necessidade de parada de uma máquina para avaliação ou deixar ocorrer a falha. Mesmo tendo todos os dados coletados, é possível avaliar apenas uma máquina por vez, portanto, o desafio de analisar dados heterogêneos. Alguns artigos já citaram essa complexidade para avaliar a situação de uma máquina e depois disso colocar em produção (DEUTSCH; HE, 2018; CHO et al., 2018a; AMIHAI et al., 2018), este desafio mostra a necessidade do conhecimento físico aplicado à predição (KWON et al., 2016; MAN; ZHOU, 2018; HE; GUO; ZHENG, 2018).
- **Criando uma nova classificação de manutenção:** as classificações de manutenção normalmente encontradas são corretivas, preventivas e preditivas. A denominação prescritiva (MATYAS et al., 2017; NEMETH et al., 2018), chama atenção e pode ser a solução para o fator de ser preditivo ou não, criando uma prescrição apontando para uma situação específica, como já mencionado, a descrição feita por (NEMETH et al., 2018) "Como podemos fazer acontecer?" ou "Como podemos controlar a ocorrência de um evento específico?". Um dos desafios pode ser a criação de uma nova designação chamada manutenção baseada em monitoramento ou alerta autônomo, porque, se a máquina está apresentando um alerta, ainda não seria uma previsão. Os alertas já apontam a atenção, de modo que, seria algo como prevenção autônoma. Esse monitoramento pode ser considerado algo prescritivo, mas é mantida a ideia de que a previsão deve envolver o tempo.
- **PdM baseado em imagem:** o uso de imagens para fazer uma previsão pode ser considerado um desafio, foi encontrado alguns artigos que levaram em consideração imagens e termografia, mas apenas (YAN et al., 2017) está entre os selecionados. Assim, algumas estratégias baseadas em imagens podem ser destacadas como sendo desafiadoras para a realização de PdM, especialmente ao realizar pesquisas e estudos de problemas relacionados a soluções usando imagens termográficas.
- **Integrar o PdM ao processo de produção:** a integração entre os processos da indústria e a automação inteligente é um dos pilares da I4.0, portanto uma forma de usar PdM baseado no tempo seria a integração do processo de manutenção com a produção já sugerida por alguns artigos (JIN et al., 2017; KIANGALA; WANG, 2018; WU et al., 2016; NEMETH et al., 2018; LEE, 2017; JANTUNEN et al., 2016; QIN; LIU; GROSVENOR, 2018)). O caso de Lee, Jin e Bagheri (2017) com a arquitetura 5C do CPS, previsão de qualidade de produção (SPENDLA et al., 2017), fluxo de energia de integração e logística (LI, 2016). O artigo Kwon et al. (2016) apresentam argumentos e desafios para a indústria: ativos móveis, geração de energia, transporte e logística, ativos de infraestrutura, automóveis, produtos médicos, serviços de garantia e robótica. O artigo também apresenta uma visão dos desafios que fazem a análise de trabalho de

PHM baseada em IoT: aprendizado de máquina e mineração de dados, segurança, coleta de energia, novos modelos de negócios para PHM baseado em IoT, licenciamento e gerenciamento de direitos. As principais formas de integração encontradas foram o cronograma de produção baseado na previsão de manutenção, logística e consumo de energia de forma sustentável. Algo que pode ser destacado é o FIS relacionado ao PHM que é um modelo de informação conceitual que pode ser o padrão para tal integração, a ideia seria exatamente um sistema de inteligência de fábrica (YAN et al., 2018).

Durante a pesquisa, várias variáveis foram surgindo e trazendo novas oportunidades. Da mesma forma que foi possível destacar alguns desafios depois da realização da revisão sobre PdM, os estudos necessários para criação do modelo também trouxeram novos apontamentos que podem ser listadas a seguir:

- Aplicação de métodos de ML para contribuir com a complexidade de problemas NP, algumas pesquisas já apontam para o uso de soluções de *clustering* para a diminuição do espaço de busca (WANG; TANG, 2017). Outro exemplo é Mirshekarian e Šormaz (2016), que utilizaram ML para predizer o *Makespan* adequado para uma determinada configuração de escalonamento, utilizando como métrica de qualidade de sua solução.
- Criação de um estudo focado em cada dado resultante de um tipo de sensor pode ser um oportunidade identificada neste trabalho, por exemplo, quais informações adicionais a medição devem ser levadas em consideração para detecção de uma anomalia ou falha. Qual é o índice e período a ser utilizado para determinar o tempo de falha a partir da identificação de uma anomalia?
- Conforme já mencionado a integração proposta neste trabalho, é uma das possíveis em um ambiente de FIS, o processo de fabricação pode abranger facilmente a expedição e a entrega da produção, trazendo outras oportunidades de pesquisa aplicada ligadas a I4.0.

### 3.4 Considerações finais

A atividade de manutenção requer estratégias e planejamento para atender às necessidades de qualidade, segurança e produtividade. O crescimento dos conceitos da I4.0 traz novas oportunidades e desafios. Dentre eles, a manutenção de forma preditiva foi o foco deste estudo no qual foi buscado entender as abordagens utilizadas e as aplicações existentes. Deste modo, a revisão apresentada neste capítulo teve o objetivo de fornecer uma visão geral do PdM no contexto da I4.0.

A partir desta revisão, foram apresentadas as contribuições científicas guiadas pela questão principal e cinco subquestões discutidas em profundidade na análise do estado da arte. A questão principal do estudo abrange a identificação de padrões, principais meios de publicação, aplicações e os termos mais comuns sobre PdM e I4.0. Como principal

contribuição, foi criada a taxonomia do PdM no contexto da I4.0, a taxonomia apresentou os tipos de aplicação, princípios, seguindo modelos de aplicação, métodos, enfoque e delimitação de objetivos. O que chamou atenção foi que no período da realização da revisão foram encontrados artigos sobre manutenção com modelos de monitoramento, mas sem a ideia principal de prever a possibilidade de falhas com base no tempo. Os conteúdos vinculados ao prognóstico de falhas também podem ser considerados uma limitação por serem dominantes nos estudos de engenharia e incomuns na computação.

Em relação aos próximos passos, primeiramente, foi visualizado alguns apontamentos como O'Donovan et al. (2015), Zerhouni et al. (2017), Muhuri, Shukla e Abraham (2019) que existem oportunidades para pesquisas na I4.0, especificamente no processo de manutenção inteligente. Com o foco, no PdM, foi apresentado sete direções futuras, desafios que foram importantes para delimitação deste trabalho. Houve a preocupação de conceito, sugerindo a criação de uma classificação de monitoramento autônomo com alertas, deixando a previsão para uma característica baseada no tempo. Foi chamada a atenção para a multidisciplinaridade envolvida nos novos desafios da I4.0 e a necessidade de integração. Em relação ao volume de dados e a realização dos testes, o grande desafio de permitir a falha de um ativo para verificar o ponto de manutenção correto.

#### 4 MODELO PdMS

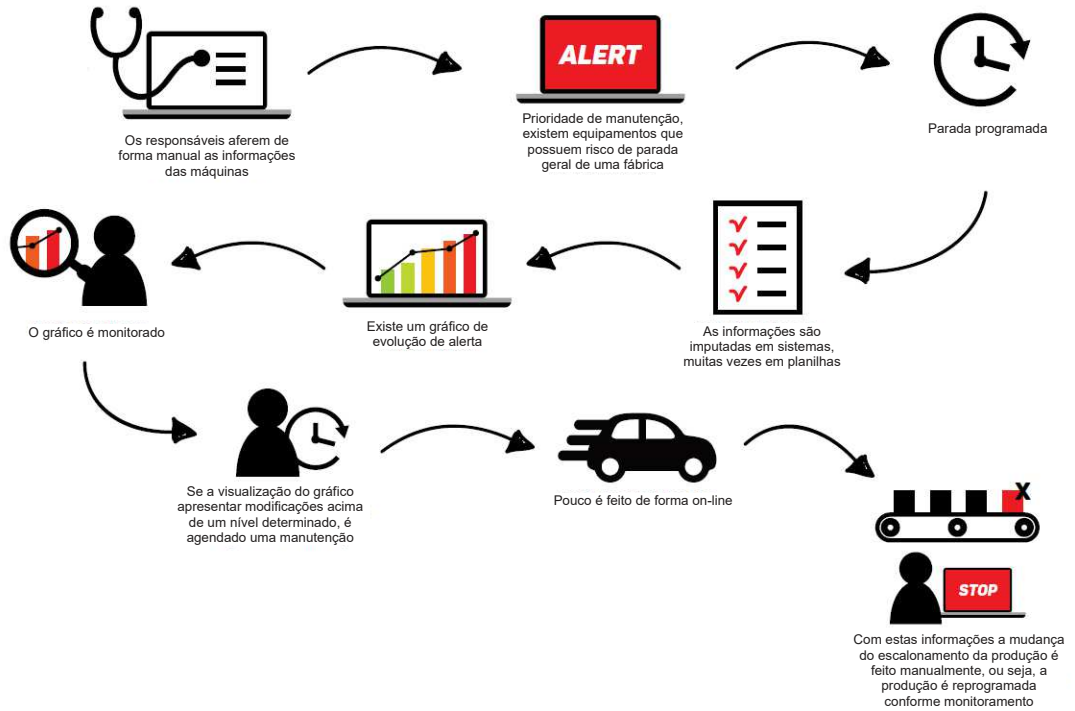
Neste capítulo é apresentada a abordagem utilizada para criação do *Predictive Maintenance & Schedule* (PdMS). Para propor um modelo para o PdMS foram analisados cenários com fluxos desde a aquisição dos dados das máquinas até a tomada de decisão considerando o agendamento da manutenção e produção. Foi necessário entender melhor as necessidades e, para isso, o cenário apresentado na Figura 16a foi analisado. Este cenário é normalmente encontrado em indústrias que possuem processo de manutenção corretiva ou preventiva e é realizado da seguinte maneira:

1. Os responsáveis aferem, de forma manual, as informações dos ativos como vibração, temperatura e ruído. Este é um sinal da necessidade de adequação para a I4.0;
2. É utilizada uma prioridade de manutenção. Há equipamentos que possuem risco de parada geral de uma fábrica;
3. As programações de manutenção são baseadas em manuais de fornecedores (preventiva), o que não garante que o ativo esteja em situação de desgaste. Esse fator é apontado no relatório da PwC como um dos maiores motivos de gastos com manutenção avaliados como desnecessários (HAARMAN; MULDER; VASSILIADIS, 2017);
4. As informações dos ativos são inseridas em sistemas ou planilhas para geração de gráficos e indicadores de manutenção;
5. São criados gráficos de evolução de alerta. O gráfico é monitorado e, se apresentar alterações acima de determinado limite, é agendada uma manutenção. Este procedimento é um risco de ocorrência de manutenção corretiva e parada da produção;
6. Falta de integração dos processos, procedimentos realizados *offline*, informações perdidas ou incorretas;
7. A mudança do agendamento da produção é realizada manualmente ou baseada no monitoramento de alerta, gerando possível atrito entre os setores de manutenção e produção.

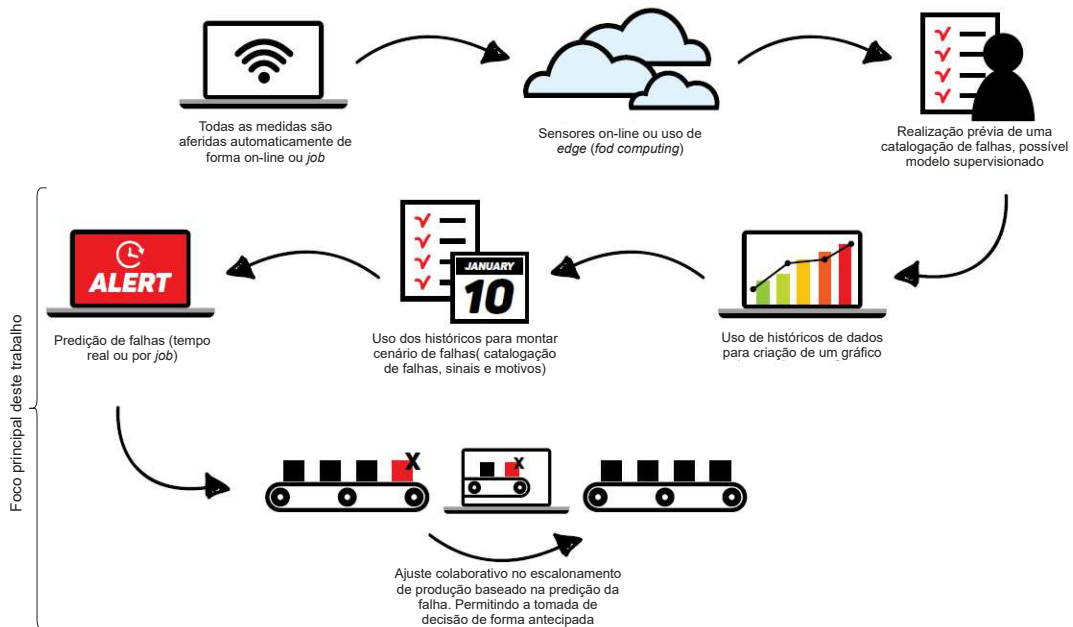
Para apresentar um modelo que possa melhorar o cenário da Figura 16a, foram utilizados os estudos realizados nos trabalhos relacionados. A inserção de tecnologias do domínio da Computação contribuíram nesta visualização e, como resultado, é apresentado o cenário da Figura 16b, uma visão geral do fluxo dos desafios do modelo proposto e descrito a seguir:

1. As medidas são aferidas automaticamente de forma *on-line* ou *job* (hora marcada). Neste ponto são utilizadas as tecnologias de IoT e CPS;

Figura 16 – Cenários analisados para criação do PdMS.



a) Cenário tradicional, sem PdM e escalonamento da produção manual.



b) Cenário proposto, PdM e integração dos agendamentos com a produção.

Fonte: O Autor



2. São utilizados sensores *on-line* ou uso de *edge - fog computing* para pré-processamento e armazenamento dos dados;
3. É realizada uma catalogação prévia de falhas baseadas nos manuais dos ativos e no conhecimento prévio dos engenheiros;
4. É mantida uma visualização gráfica do monitoramento de falhas, para possível apontamento de novas situações e teste do modelo;
5. O histórico de dados é utilizado para montar cenários de falhas e identificação de similaridades (catalogação de falhas e motivos);
6. É realizada a predição de falhas, apontando o tempo estimado do RUL;
7. O resultado é um indicador de ajuste na produção baseado na predição da falha, permitindo a melhora na tomada de decisão dos setores responsáveis.

O foco inicial da integração do cenário proposto está na manutenção e produção, porém pode ser estendido para expedição e logística prevendo problemas de empacotamento, carregamento e roteirização (FRANK; DALENOGARE; AYALA, 2019). Este é um dos principais objetivos da I4.0, permitir que o processo industrial forneça informações de toda a situação - do chamado "chão de fábrica" até o rastreamento do produto.

#### **4.1 Aplicação da metodologia da matriz de inovação sistemática**

A aplicação da metodologia da matriz de inovação da Figura 6 foi baseada na revisão sistemática e em relatórios de pesquisas realizadas nas indústrias. Um exemplo, é o estudo da PwC, com mais de 2 mil empresas em 26 países, entre eles o Brasil, que fez o levantamento sobre a 4ª Revolução Industrial e mostra que o setor pretende investir 5% da sua receita digital anual nessa transformação, o que corresponde a um total de US\$ 907 bi até 2020 (GEISBAUER; VEDSO; SCHRAUF, 2016). Como resultado, foi construída a matriz do domínio da inovação do PdMS apresentada na Tabela 10:

- Quadrante Q1: foi identificado o que está sendo atendido, tanto a nível de necessidades quanto a nível de tecnologias. Com as pesquisas realizadas, foram apontados esforços para solução de problemas de PdM e de agendamento de produção. Este foi o ponto de partida;
- Quadrante Q2: os mercados não atendidos para os cliente são de soluções de PdM, ações automatizadas, alto custo de tomada de decisão, necessitando avaliação de relatórios e falta de integração entre processos produtivos, como a diminuição de ocorrências de *downtime*;

Tabela 10 – Matriz para identificar o domínio da inovação.

Necessidades	Invisível	Atendidas	Q6 -Integração -Automatização -Preditivo -Flexível	Q9	Q5 PdMS: integração das agendas da manutenção e produção de forma preditiva, adaptativa e autônoma
	Visível		Não atendidas	Q3 -Integração de processos: manutenção e agendamento de produção.	Q4 - <i>Worry-free Industry</i> -Confiabilidade -Disponibilidade
				Q1 -Manutenção Preditiva (PdM)/ Problema de escalonamento	Q2 -Monitoramento preditivo. -Ação automática -Diminuição do custo de decisão -Integração e diminuição do <i>Downtime</i>
			Atendidos	Não atendidos	
			Visível		Invisível
			Clientes / Mercados		

Fonte: Adaptado de Lee e Abuali (2011)

- Quadrante Q3: as necessidades não atendidas estão relacionadas à integração dos processos, neste caso, os agendamentos;
- Quadrante Q4: o cenário possível de atender estas lacunas está relacionado à indústria desprovida de preocupações, confiável e que possibilite integração de processos de forma mais inteligente e autônoma;
- Quadrante Q6: são listados os *gaps* de necessidades que não são atendidas. Estes serão os diferenciais a nível de tecnologia porque deverão funcionar de forma invisível, sua implantação vai contribuir para atender as demandas do quadrante Q7 dos clientes;
- Quadrante Q7: os mercados não atendidos são a maior preocupação. São ativos legados com a utilização de novas abordagens, por exemplo: IA e a integração dos processos de operação e tecnologia de informação. Neste ponto, atuam as empresas chamadas de integradoras, que trazem soluções de adequação dos processos e máquinas defasadas, mas deixam a lacuna ligada ao uso da IA, oportunidades tecnológicas e de serviços;
- Quadrante Q5: une, em um cenário, uma solução que pode se tornar um produto diferenciado que atenda às necessidades, espaço tecnológico e o mercado. Aqui surge a proposta do PdMS;
- Os quadrantes Q8 e Q9 só serão identificados no momento que for validada a proposta, pois dependem de dados quantitativos e a comprovação da inovação, finalizando, até

mesmo, com dados para uma patente. Estes quadrantes serão atendidos quando surgir a oportunidade de aplicação real do modelo em uma indústria.

O uso do método chamado de *Dominant innovation*, proposto por Lee e Abuali (2011), teve o objetivo de apresentar uma forma visual de identificar e levar até a indústria a adoção das inovações existentes na I4.0, buscando atender o desafio de - "**Como fazer diversos setores discutirem sobre como é possível modificar o seu processo de fabricação?**". O método traz suas contribuições científicas para outros exemplos que fazem um levantamento de *insights* para abordar problemas e apontar soluções, por exemplo, *canvas*, *brainstorms* e *design thinking*. O uso de soluções da Computação trazem desafios que devem ser entendidos pelos "clientes" (neste caso a indústria), antes de serem aplicados.

## 4.2 Decisões do projeto

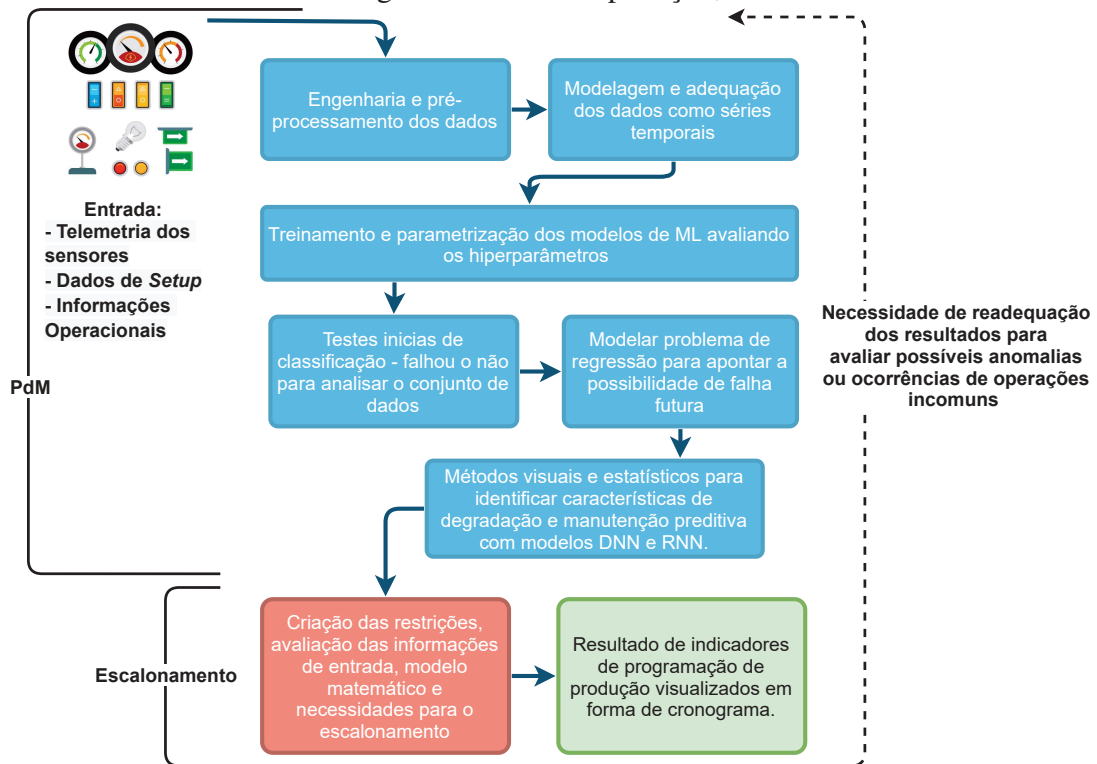
Após delimitar o cenário do problema na Figura 16b, foi criada uma sequência de objetivos menores para identificar os conceitos e requisitos apresentados na Figura 17. A figura visa traçar uma estratégia para o estudo e busca de hipóteses que atendam às especificidades do PdMS. Por isso, foi criada uma visão macro do modelo para entender: (i) processo de pré-processamento e avaliação dos dados; (ii) modelagem do problema de série temporal e separação dos dados em treinamento, teste e validação; (iii) estudos, treinamento e avaliação de hiperparâmetros; (iv) verificação da possibilidade de testes de classificação para realização de estudos mais detalhados sobre os dados; (v) modelagem do problema de regressão comumente aplicado em problemas de PdM; (vi) análise visual dos resultados e aplicação de modelos de ML para PdM, avaliação e possível criação de informações de degradação; (vii) criação de restrições para o problema de escalonamento e cenário de aplicação; (viii) geração de resultados visuais para controle de produção. Conforme destacado na Figura 16b, o foco foi delimitado no momento após a aquisição dos dados. No entanto, foram estudadas propostas de sistemas de aquisição de dados para entender melhor as tecnologias necessárias para trabalhos futuros (MOURTZIS; ANGELOPOULOS; PANOPOULOS, 2020).

O fluxo foi delimitado levando em consideração trabalhos relacionados de aplicação de DNN e RNN para a PdM e predição do RUL (HEIMES, 2008; CUI; CHEN; CHEN, 2016; ZHENG et al., 2017; DONG; LI; SUN, 2017; BRUNEO; De Vita, 2019; MODE; CALYAM; HOQUE, 2019; XIA et al., 2020).

### 4.2.1 Pré-processamento dos dados

A entrada dos dados é formada pela telemetria dos sensores aliada às informações operacionais e *setup* das máquinas. Normalmente, a telemetria dos sensores é realizada com pequenos espaços de tempo. Estes podem apresentar a incidência de picos que confundem os modelos de aprendizado de máquina. Outra característica é a variação da escala de valores dos

Figura 17 – Modelo PdMS. Visão geral do fluxo da aplicação, demonstrado de forma conceitual.



Fonte: O Autor

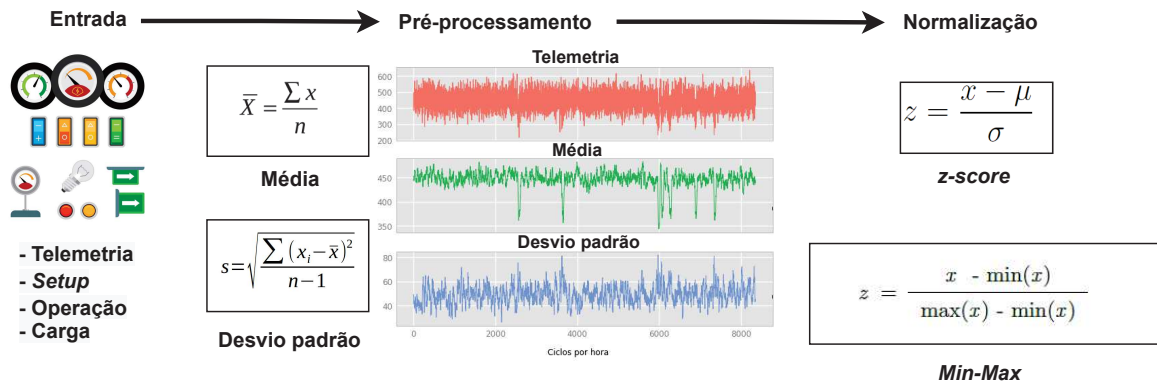
sensores, que precisam ser normalizados antes do treinamento e teste.

Neste trabalho, o objetivo é usar conjuntos de dados alinhados às características heterogêneas: diferentes máquinas e situações de falha. Nos estudos realizados, foi identificado que, em alguns casos, as informações operacionais não estão disponíveis, o que pode afetar os resultados da predição, exigindo novas abordagens. Isso reforça a necessidade de pré-processar e normalizar os dados, conforme Figura 18. É essencial avaliar métodos matemáticos e estatísticos para ajustar as características usadas nos modelos de ML. Há várias maneiras diferentes de normalizar os dados do sensor e o objetivo é ajustar a variação e dimensionar os dados brutos dentro do intervalo  $[0,1]$  usando, por exemplo, *z-score* ou *Min-Max* (ZHENG et al., 2017).

#### 4.2.2 Análise e modelagem das séries temporais

O próximo passo do fluxo é analisar a melhor forma de modelar os dados dos sensores. A telemetria realizada ao longo do tempo indica o uso de séries temporais. Na era do *Big Data*, há uma necessidade crescente de extrair conhecimento de séries temporais e é crucial modelar dados sensíveis ao tempo de forma correta (CUI; CHEN; CHEN, 2016). Considerando isso, foram analisadas estratégias como os recursos de atraso (*lag features*), apresentados na Figura 19. Neste caso, a aprendizagem é determinada a partir da ideia de tempo com atraso, por exemplo, prevendo o RUL do dia atual mas tendo em consideração um atraso de dados de

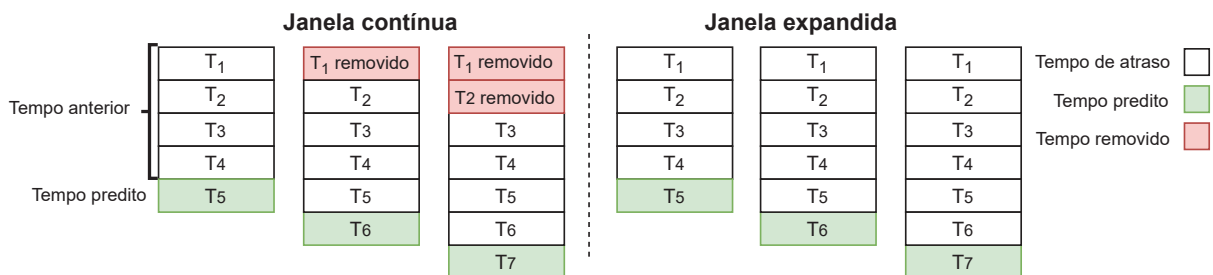
Figura 18 – Entrada, pré-processamento e normalização dos dados.



Fonte: O Autor

10 dias. São estudadas duas técnicas de retardo de dados: (i) janela contínua em que os dados têm uma característica deslizante ou rolante, na qual o tamanho do conjunto é mantido para a previsão de  $T + 1$  e o aprendizado é feito sempre usando os dados mais próximos; (ii) a janela expandida, na qual a duração do atraso aumenta a cada previsão e mantém as informações mais antigas.

Figura 19 – Uso de janelas de atraso para modelar séries temporais e realizar a previsão.



Fonte: O Autor

#### 4.2.3 Estratégia para estudo dos dados, parametrização e avaliação de modelos ML


Normalmente, os resultados são esperados apenas com processos básicos de normalização e verificação da importância dos recursos selecionados do conjunto de dados. No caso da PdM, a telemetria quase sempre apresenta sinais ruidosos que devem ser estudados, o que significa que o conhecimento do *setup*, as diferentes cargas de trabalho das máquinas e as informações de manutenção dos fornecedores fazem a diferença.

Uma estratégia para analisar e estudar as características do conjunto de dados é verificar se eles contêm informações rotuladas, possibilitando a aplicação de modelos de aprendizagem supervisionada, classificando as entradas e verificando se houve uma falha em determinado momento da telemetria. Diferente da classificação, a PdM tem a necessidade de prever o tempo de funcionamento da máquina até a falha, resultando na saída de informações contínuas o que

é característico de problemas de regressão.

Como resultado, é apresentada a Figura 20, uma arquitetura que, inicialmente, propõem a realização da classificação para verificar se houve falha para, posteriormente, realizar a modelagem de um problema de regressão e prever o RUL. O objetivo é estudar modelos DNN ou RNN em camadas ocultas, seguidos por camadas de DFF para saída. Os trabalhos relacionados demonstram que a complexidade da arquitetura aplicada à classificação supervisionada pode não ser necessária. Portanto, é possível comparar os resultados com modelos clássicos de classificação, como: RF, KNN e *Gradient Boosted Trees* (XGBoost).

Figura 20 – Visão geral da arquitetura para conhecimento do domínio.



Fonte: O Autor adaptado de Xia et al. (2020)

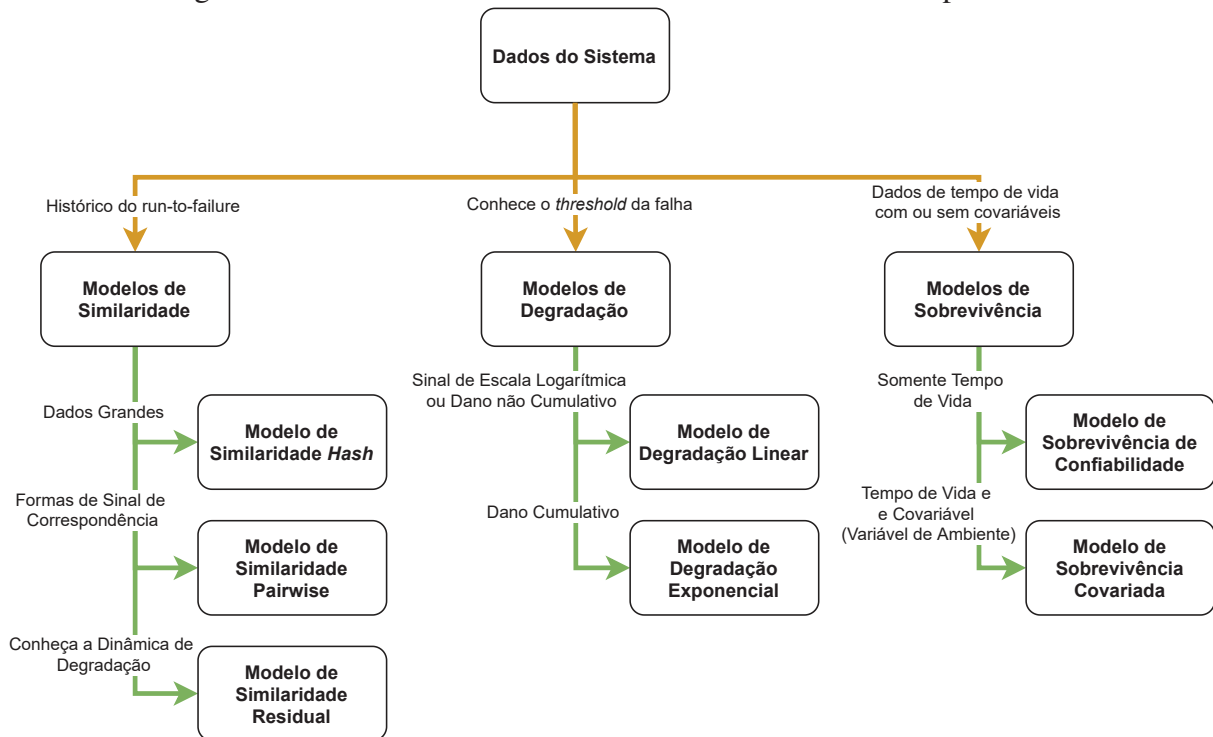
#### 4.2.4 Avaliação da predição, integração com o escalonamento e saída desejada

Um dos pilares da PdM é determinar o RUL corretamente. Ao fazer isso, os engenheiros podem avaliar o tempo de manutenção e otimizar a eficiência com menos tempo de inatividade possível (MATHWORKS, 2018). Para isso, é necessário saber o resultado desejado e como será modelado, por exemplo: "Como será definido o RUL de uma máquina?" e "É possível identificar com os dados de entrada quanto tempo a máquina ficará em operação antes de falhar?". Segundo MathWorks (2018), é possível mapear algumas características para se estimar o RUL mostrado na Figura 21, destacando-se três:

1. Modelo de similaridade: quando as informações são completas, do estado de integridade até a falha.
2. Modelo de degradação: quando tem-se as informações do limiar da falha, dados sobre o momento de integridade da máquina e a identificação do estado da falha;
3. Modelos de Sobrevivência: quando são conhecidos apenas dados do tempo de falha;

A escolha correta de um modelo para o RUL é um dos motivos da busca por informações heterogêneas. Na revisão, é chamada atenção para o uso de dados de bancadas devido à dificuldade de encontrar dados reais de máquinas que tenham funcionado até o ponto de falha. Outro fator é que, mesmo máquinas do mesmo modelo podem ter diferentes momentos de falha, conforme já mencionado. Tudo depende do regime de operação e carga de trabalho de

Figura 21 – Formas de estimar o RUL baseado nos dados disponíveis.



Fonte: O Autor - tradução do autor de MathWorks (2018)


sua utilização. Com diferentes situações de funcionamento, os modelos de aprendizado de máquina podem apresentar melhores resultados quando aplicados em ambiente real de produção.

Depois de pré-processar, normalizar, estudar os dados, testar os modelos DNN e RNN e arquiteturas para prever o RUL, é possível extrair as informações necessárias para aplicar o problema de escalonamento. Nesta fase, é necessário escolher como executar o cronograma de produção, considerando o tempo e com que antecedência foi possível prever a falha. O resultado é o escalonamento visual das máquinas, seguindo o padrão da Figura 22. São determinadas as tarefas de cada máquina e é indicado o período de parada para manutenção. Na Figura 22, por exemplo, a máquina 1 está em período de manutenção de 0 a 30 e estará disponível a partir deste ponto. A saída é alterada conforme previsão realizada pela PdM, executando automaticamente o rearranjo na programação da produção. O resultado por meio de gráficos com o cronograma de atendimento às tarefas e a disponibilidade das máquinas colabora no processo de decisão dos setores envolvidos.

### 4.3 Considerações finais

Neste capítulo, foi apresentado o processo seguido para a contextualização e o entendimento do modelo pretendido para o PdMS. Foram visualizados dois cenários: (i) baseado em indústrias que realizam manutenção corretiva, preventiva ou monitoramento de

Figura 22 – Exemplo de saída com previsão de manutenção.



Fonte: O autor

falha e, (ii) com um cenário proposto levando em consideração a predição da falha e a integração automática dos agendamentos de manutenção e produção. Na sequência, para avaliar as necessidades considerando negócio, produto e serviço, foi aplicada a ideia da metodologia de inovação sistemática de Lee e Abuali (2011). Todo este processo contribuiu para a delimitação das contribuições científicas da aplicação. Como resultado, foi criado um fluxo lógico do modelo PdMS focado em duas fases, a PdM e o escalonamento. Portanto, nos próximos capítulos, serão apresentadas, em detalhes, as decisões, técnicas, experimentos e resultados de sua aplicação.



## 5 MATERIAIS E MÉTODOS

Este capítulo descreve o processo de construção da metodologia baseado no modelo PdMS. De acordo com o fluxo lógico, é necessário determinar abordagens e estratégias para ciência de dados, metodologia para prever as condições das máquinas e utilizar os resultados da PdM para descrever a modelagem e os detalhes do problema do escalonamento.

### 5.1 Busca e descrição do conjunto de dados

Um dos desafios já mencionados é a dificuldade de encontrar dados reais de falhas de máquinas e que estes dados sejam heterogêneos. Normalmente, os experimentos são feitos com dados de bancada nos quais o ativo é estressado para identificar as situações de falha em produção. Estes pontos foram levados em consideração na escolha do conjunto de dados utilizado neste trabalho.

Após a avaliação de diversos conjuntos de dados de referência, por exemplo, o *Commercial Modular Aero-Propulsion System Simulation (C-MAPSS)* fornecido pelo *Prognostics Center of Excellence (PCoE)* da NASA (DATASETS, 2018; XIA et al., 2020) e desafios do *The Prognostics and Health Management Society (PHM Society)* (SOCIETY, 2018; WANG et al., 2008), foi encontrado um conjunto de dados usado na plataforma de PdM da Microsoft Azure AI (AZURE, 2020). Os motivos da sua escolha são detalhados abaixo:

1. O conjunto de dados é preparado para simular um problema de classificação supervisionada porque identifica o momento da falha;
2. Dados de várias máquinas, idades, modelos e diversas falhas durante o período de aquisição. A decisão de manter várias situações de falha é diferente da literatura, principalmente quando se utiliza dados C-MAPSS (DATASETS, 2018), que separam os arquivos de dados do registro de uma falha cada (BRUNEO; De Vita, 2019; MODE; CALYAM; HOQUE, 2019; XIA et al., 2020). A metodologia proposta considera várias falhas por máquina, contribuindo para uma melhor generalização dos modelos de ML, pois uma máquina pode falhar por diferentes motivos e tempos;
3. A ausência de informação sobre o tipo de máquina e a informação operacional permite verificar se a aplicação da metodologia é útil para empresas que possuem telemetria e pretendem iniciar um processo de PdM;
4. A possibilidade de criar uma simulação para testar a integração com a produção. Com base em cenários e estudos de problemas de escalonamento, foi buscado um conjunto de dados que tivesse a telemetria de mais de um modelo de máquina, o que permitiu simular um cenário de produção para serialização e customização de produtos. Neste caso, a produção considera que nenhuma máquina executa simultaneamente mais de uma tarefa

e seguem uma sequência de produção. Realizar testes de integração sem usar dados reais é, de certa forma, uma limitação. Normalmente, os dados de simulação trazem os dados relacionados à manutenção e os dados do planejamento da produção como informações separadas.

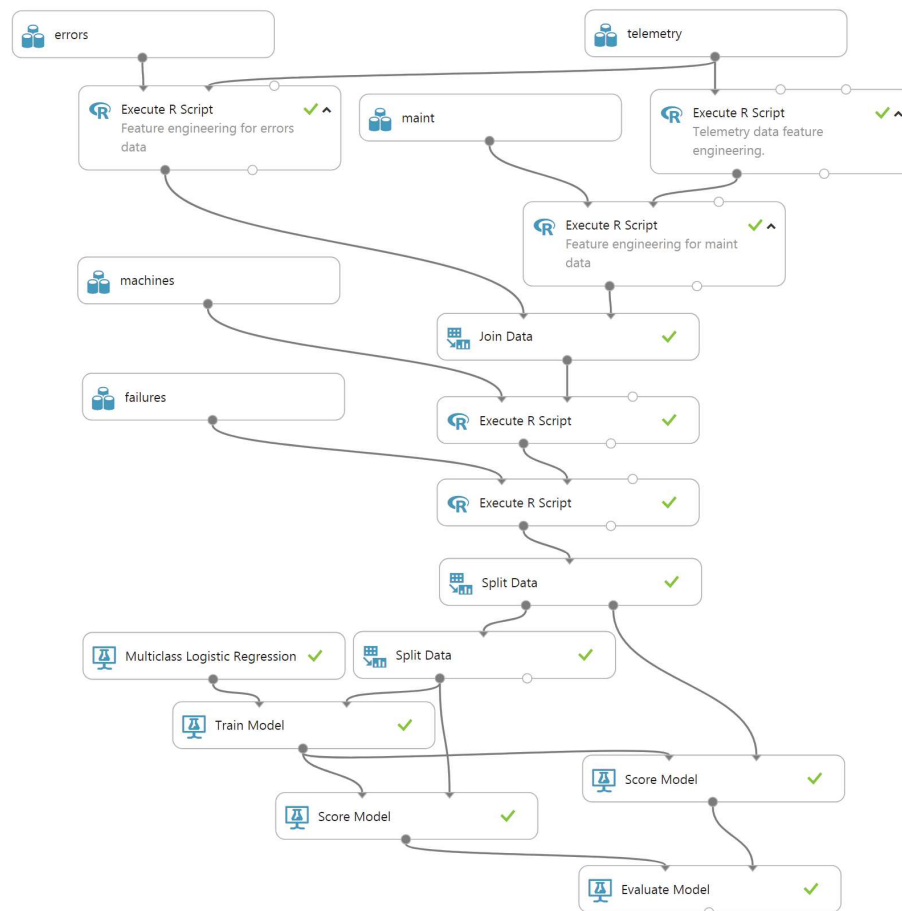
Portanto, consideramos essas características para avaliar o modelo inicial proposto e testar hipóteses que pudessem apresentar resultados satisfatórios. O conjunto de dados tem vinte e quatro leituras dos sensores (ciclos de telemetria) por dia e por máquina, durante um ano, e estão divididos em cinco arquivos descritos a seguir:

- **Máquinas:** dados de 100 máquinas, contendo suas idades e identificação de quatro modelos. No entanto, não fornece informações sobre o tipo de máquinas;
- **Telemetria:** leituras feitas a cada hora em sensores de tensão, rotação, pressão e vibração. Os dados não carregam informações sobre as condições operacionais, como configuração das máquinas, capacidade e velocidade de produção, esforço e ambiente operacional. O que é importante para a correlação entre os sensores. Por exemplo, se a tensão aumenta e a rotação e a vibração também aumentam, isso pode estar relacionado a uma capacidade de produção ou regime de operação da máquina;
- **Erros:** informação de erro de operação por hora sem identificação específica, incluindo apenas uma nota de erro binária;
- **Manutenção:** informações de manutenção, identificando o modelo dos componentes (modelos enumerados variando de um a quatro) que foram submetidos à manutenção, podendo significar uma falha ou não;
- **Falhas:** informações sobre falhas durante a manutenção. Identifica o número do componente que falhou e se precisou ser substituído.

## 5.2 Modelagem dos dados e testes de aprendizado de classificação supervisionada

Definido o conjunto de dados, foi avaliada a possibilidade de testar métodos de aprendizado de classificação supervisionada. Esta estratégia foi utilizada para entender melhor sobre os dados e avaliar o nível de ruído existente. No conjunto de dados em questão, a própria plataforma Azure traz exemplos de aplicação que verifica se determinado conjunto de informações daquele horário gerou uma falha. Os exemplos da Azure são realizados na ferramenta chamada *Microsoft Azure Machine Learning Studio*, que possui um ambiente visual onde são realizadas as parametrizações do modelo, utilizando estratégias de "arrastar e soltar". A Figura 23 demonstra um destes exemplos. Nele é feito o carregamento dos arquivos de dados, seguido pelos métodos de divisão dos dados em treino, validação e teste. Feito isso,

Figura 23 – Exemplo de classificação supervisionada realizada no *Azure Machine Learning Studio*.



Fonte: O autor

é possível selecionar alguns métodos como regressão logística para realização da classificação. Após, é realizado o treinamento e feita a validação dos resultados.

Após o estudo do experimento do exemplo da Azure, optou-se pela implementação utilizando a linguagem Python para estudo das bibliotecas *scikit-learn* e *Keras*, ambas usadas em soluções de aprendizado de máquina e DL (SCIKIT-LEARN, 2007; KERAS, 2020). Neste processo, foram correlacionadas informações multimodais, não limitando apenas às condições dos sensores. Foram utilizadas ferramentas de normalização e entendido melhor como aplicar a ideia do uso da janela de atraso, visto no modelo proposto. No caso da janela expandida, é gerada entradas de tamanhos variáveis, o que limita o uso de modelos de DL. Com isso foi optado pela janela contínua com atrasos de 24, 35, 60, 90 e 100 ciclos, o que se refere, respectivamente, em 1, 1.45, 2.5, 3.75 e 4.1 dias para prever  $T + 1$ . O fluxo do modelo de classificação seguiu, basicamente, o apresentado na Figura 23, só que, neste caso, foi feita toda a implementação de forma manual.

Cumprida a ideia da utilização da classificação e realização do estudo detalhado dos dados, inicia-se a fase de modelagem do problema de predição utilizando regressão, sendo que o objetivo é prever, a cada horário, se a máquina apresenta características que permita definir se ela está degradando, determinando o tempo de funcionamento que ela ainda tem, comumente chamado de *run-to-failure*.

### 5.3 Escolha da forma de estimar o RUL e divisão do conjunto de dados

Para uma generalização adequada, as técnicas de ML precisam de um conjunto de dados bem preparado. Assim, dadas as características do conjunto de dados, foi analisada a necessidade da escolha do método de geração do RUL, que é uma informação primordial para os processos de PdM (MATHWORKS, 2018).

Conforme descrição dos dados, não são conhecidas as informações do RUL. Ainda assim, foi encontrada a possibilidade de identificar o ciclo em formato numérico decrescente, desde o momento da integridade da máquina até a falha. Com essas informações, foi utilizada a estratégia de estimar o RUL em ciclos usando o modelo de sobrevivência detalhado na Subseção 4.2.4. Foi considerada a possível utilização da estimativa por similaridade, mas, a princípio, não foi possível, porque o conjunto de dados não possui as informações da condição operacional.

Determinado o modelo de sobrevivência como forma de estimar o RUL, os dados podem ser divididos em treinamento, teste e validação de várias maneiras: por máquina, data e falhas. A opção, foi utilizar a divisão por falhas, porque o conjunto de dados tem mais de uma falha por máquina no intervalo de tempo o que atende o objetivo de avaliar a característica heterogênea. A divisão resultou em 75% das informações para treinamento, destas, 5% para validação e 25% para testes. Neste formato de divisão, os dados de testes vão ter, pelo menos, uma falha por máquina, o que é importante para avaliar o aprendizado dos modelos. Para realização da divisão dos dados, foi optado pela criação de um algoritmo de divisão próprio, buscando evitar

a separação de informações, ou seja, não foi separado um ciclo completo do RUL que traz informações do estado saudável até o nível degradado da máquina.

#### 5.4 Critérios de avaliação das características de degradação dos dados

Definido como os dados serão divididos e o objetivo de realizar a predição comparando vários modelos de DNN, RNN e RRF, é necessário verificar quais serão os critérios de avaliação. Baseado nos trabalhos relacionados, foi identificado que, o comparativo dos resultados em problemas de regressão, utilizam a visualização dos dados verdadeiros e resultantes, o coeficiente de determinação  $R^2$  e avaliação dos critérios de erros e MAPE. No caso do  $R^2$ , é medido o ajuste de um modelo estatístico linear aos valores observados de uma variável, neste caso o RUL, podendo explicar mais sobre os dados coletados (HEIMES, 2008; CUI; CHEN; CHEN, 2016; ZHENG et al., 2017; DONG; LI; SUN, 2017; BRUNEO; De Vita, 2019; MODE; CALYAM; HOQUE, 2019; XIA et al., 2020). Com isso, foi optado pela utilização da métrica da funcionalidade  $r2\_score$  da biblioteca *sklearn*. Segundo Scikit-learn (2007), a função fornece uma indicação da qualidade do ajuste e, portanto, uma medida de quão bem as amostras podem ser previstas pelo modelo, por meio da proporção da variância. A Equação 5.1 traz como entrada os dados utilizados no treinamento ( $y$ ) juntamente com os resultados da predição ( $\hat{y}$ ) onde  $\bar{y}$  é conhecido na Equação 5.2.

$$R^2(y, \hat{y}) = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (5.1)$$

$$\text{onde } \bar{y} = \frac{1}{n} \sum_{i=1}^n y_i \text{ e } \sum_{i=1}^n (y_i - \hat{y}_i) = \sum_{i=1}^n \epsilon_i^2 \quad (5.2)$$

No caso da acurácia ela será calculada com a Equação 5.4 usando o *Mean Absolute Percentage Error* (MAPE) da Equação 5.3. Optou-se por esta equação porque ela apresenta um melhor ajuste se comparado às funções do *scikit-learn*. Também serão avaliados os erros *Root Mean Square Error* (RMSE), *Mean Absolute Error* (MAE) e *Mean Squared Error* (MSE). Conforme já mencionado, estes critérios foram os mais encontrados nos comparativos realizados nos trabalhos relacionados e, por se tratar de um problema de regressão com predição de informações contínuas, não foi possível utilizar critérios como: *F1-Score*, matriz de confusão e *Receiver Operating Characteristic Curve* (ROC), comumente utilizados em problemas de classificação.

$$\text{MAPE} = \frac{1}{n} \sum_{t=1}^n \left| \frac{\text{Atual}_t - \text{Previsto}_t}{\text{Atual}_t} \right| \quad (5.3)$$

$$\text{Acurácia} = 100 * (1 - \text{MAPE}) \quad (5.4)$$

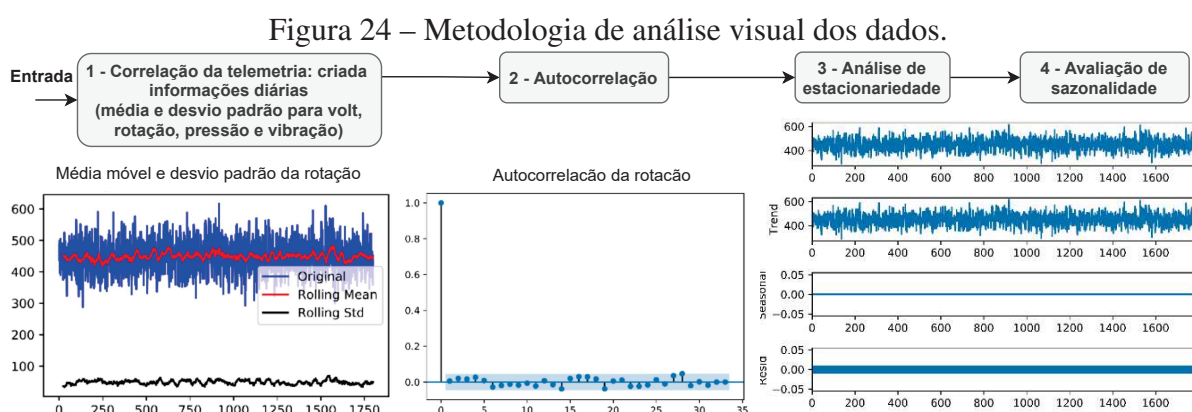
Com a delimitação da estratégia inicial, foram realizados os primeiros experimentos para

nova avaliação do comportamento dos dados agora focado na predição do RUL e verificação das características de degradação. Foi realizado o processo básico de ciência de dados com padronização, limpeza, pré-processamento e normalização. Com isso, foi possível aplicar a arquitetura inicial proposta para as redes, com uma camada de entrada, duas camadas ocultas DNN ou RNN e camadas de saída DFF. A ideia inicial foi realizar avaliações sem alterações nos hiperparâmetros padrão do *Keras* e para o RRF o padrão proposto pelo *sklearn.ensemble*.

A primeira análise realizada nos dados foram as características com maior importância na predição do RUL, para isso, foi utilizado o RRF para analisar a importância das *features* selecionadas. Após, foi realizado os primeiros treinamentos dos modelos DNN e RNN. Neste momento, já foi possível identificar a necessidade de aumentar as características de degradação devido à falta de informações de configuração e operação das máquinas. Segundo Chen, Zhu e Lee (2013), um sinal de telemetria geralmente carrega distúrbios aleatórios e ruídos e reforça que o conhecimento dos princípios físicos é importante para a realização da predição. Além disso, durante o armazenamento e comunicação dos dados podem ocorrer erros ou aumento do ruído.

#### 5.4.1 Estratégias para avaliação dos dados e séries temporais

Com a necessidade de melhoria dos resultados foi realizada uma avaliação mais detalhada dos dados. A estratégia utilizada está relacionada à análise gráfica apresentada na Figura 24, onde é feita a visualização da distribuição dos dados, função de autocorrelação, estacionariedade e sazonalidade (CHEN; ZHU; LEE, 2013).



Fonte: O Autor

No passo 1 e 2 da Figura 24, foram gerados os gráficos de correlação, que servem para verificar possíveis comportamentos dos dados no tempo, por exemplo, se é apresentada uma tendência de ciclo, sazonalidade ou aleatoriedade. A análise da correlação foi focada na telemetria para avaliação da necessidade de se criar características diárias, sendo que, a telemetria constante em pequenas faixas de tempo não permitem uma avaliação visual. Segundo Falcão (2012), a correlação entre duas variáveis num contexto de séries temporais

mede o grau de concordância relativamente assumidos pelos valores de cada variável ao longo do tempo. Segundo Cui, Chen e Chen (2016), pode-se criar algumas características incluindo estatísticas simples, como média e variância, bem como recursos complexos de análise de flutuação de tendência e análise espectral. Isso pode convergir para estratégias de transformação que penaliza mais os valores mais altos do que os valores mais baixos, com o objetivo de reduzir a tendência. Com isso, atendendo a primeira observação, foram criadas características diárias de média e desvio padrão da telemetria.

Como segundo passo, foi realizada a visualização da estacionaridade e sazonalidade itens 3 e 4 da Figura 24. Além do gráfico, foram utilizadas as ferramentas disponibilizadas pelas bibliotecas do Python, como a *statsmodels*, com a funcionalidade do teste de *Augmented Dickey-Fuller* que verifica se um modelo autorregressivo tem ou não raiz unitária (STATSMODELS, 2010). Conforme documentação da biblioteca, quanto mais negativo for o resultado estatístico, maior será a probabilidade da hipótese nula ser rejeitada, isso aponta para um conjunto de dados estacionário. Outro gráfico, é o histograma, que pode ser gerado a partir dos dados da telemetria. Neste caso, deve-se analisar se os gráficos do histograma demonstram uma distribuição gaussiana normal que é considerada benéfica para os modelos.

## 5.5 Proposta de metodologia para adequação do conjunto de dados

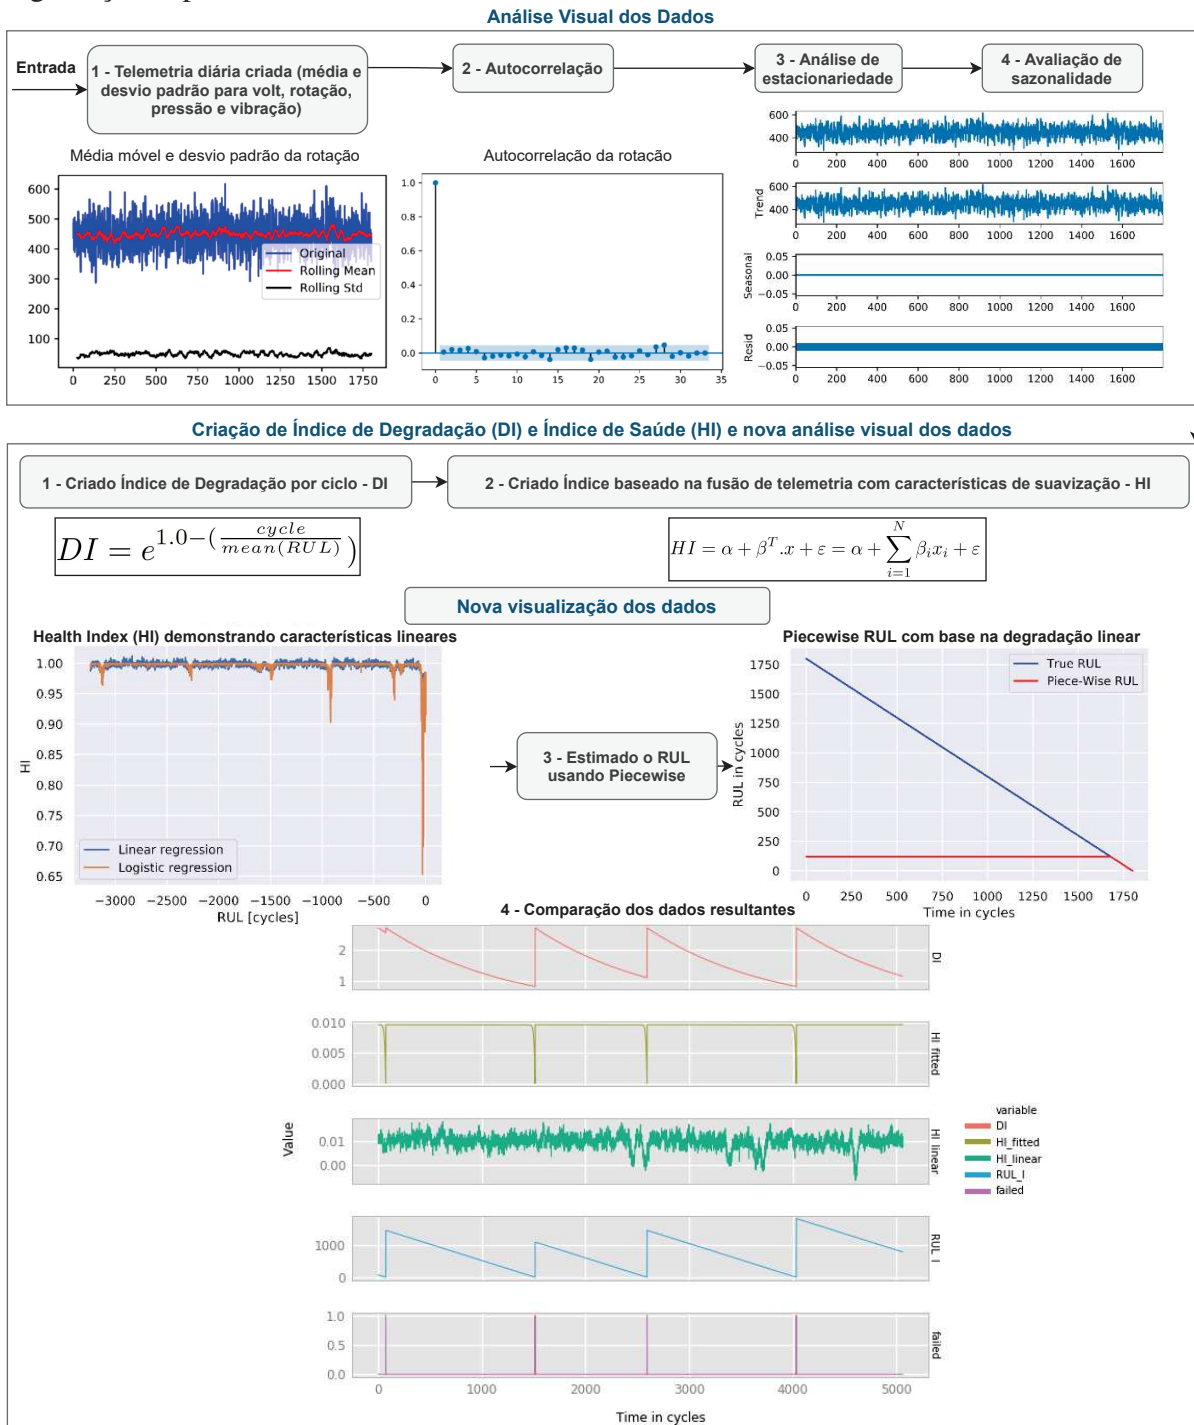
Com a aplicação das estratégias visuais e estatísticas, foi possível entender a dificuldade para os modelos identificarem características de degradação. Uma das hipóteses é que ruídos aliados a ausência de informações operacionais, podem estar contribuindo para uma dificuldade de aprendizado do modelo. Para isso foi criada uma metodologia apresentada na Figura 25, que demonstra uma visão macro do processo seguido. São dois blocos (caixas): a primeira, já detalhada, e a segunda, que apresenta às abordagens de criação dos índices de degradação que permitiriam prever o RUL utilizando dados ruidosos e sem informação sobre a condição de operação.

A metodologia proposta surgiu no momento dos estudos de alguns conjuntos de dados de competições. Foi encontrada uma solução para estimar o RUL que traz um esboço para o cálculo de um Indicador de Saúde (HI), que contribuí na identificação da característica de degradação Wang et al. (2008). Com isso, foi optado, inicialmente, pela criação de um Índice de Degradação próprio, conforme visto na Equação DI 5.5, baseada em uma função exponencial natural ( $e$ ). O uso de uma função com características exponenciais é motivado pelo comportamento desejado ao ajustar o modelo de regressão. O objetivo é penalizar pequenas variações na relação entre a leitura e o RUL esperado. Desta forma, pode-se garantir um melhor ajuste dos pesos do modelo.

$$DI = e^{1.0 - \left(\frac{\text{ciclo}}{\text{mean}(RUL)}\right)} \quad (5.5)$$

Após a criação do DI, foram realizadas novas avaliações, e mesmo com o DI, ainda foram identificadas características de degradação não previstas para uso em modelos de predição.

Figura 25 – Metodologia para gerar o RUL, DI e HI em um conjunto de dados ruidoso sem degradação expressiva.



Fonte: O Autor



Diante disso, foi utilizada a estratégia de criar a Equação HI 5.6 realizando a regressão Linear e Logística proposta por Wang et al. (2008). Neste processo, foram usados apenas dados de telemetria originais, tensão, rotação, pressão e vibração com ciclos por hora representados por  $x$  na equação.

$$HI = \alpha + \beta^T .x + \varepsilon = \alpha + \sum_{i=1}^N \beta_i x_i + \varepsilon \quad (5.6)$$

A equação proposta em Wang et al. (2008) tem  $x$  como o vetor de característica dimensional  $N$ ,  $HI$  é o indicador de saúde,  $(\alpha, \beta)$  é  $N + 1$  parâmetros do modelo, e  $\varepsilon$  é o termo de ruído. O processo realiza uma fusão de telemetria e usa regressão logística. É relatada uma distorção de padrão exponencial normal de degradação. Por esse motivo, também foi optado pelo uso de regressão linear na metodologia proposta. Ao contrário do método usado por Wang et al. (2008), os dados utilizados neste trabalho apresentam mais de uma falha, então foram incluídas informações sobre os ciclos de falha médios, prevendo uma mudança nos resultados.

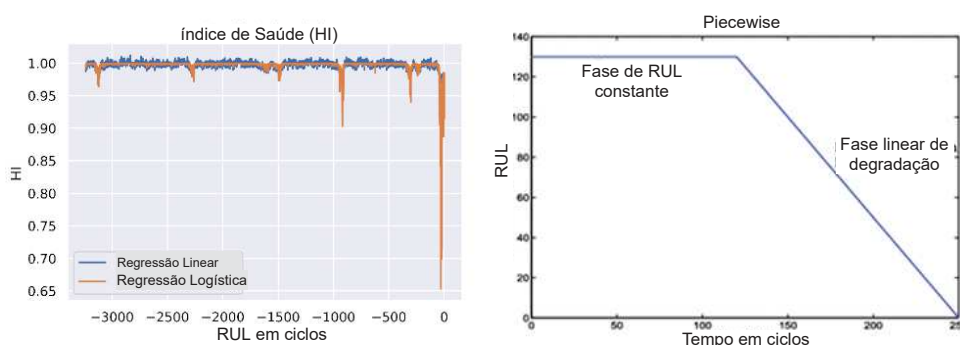
Todo o processo descrito está esboçado na Figura 25. Foi conectada a parte responsável pela análise visual com a estratégia de criação dos índices de degradação. Analisando o gráfico de regressão do HI da Figura, é possível visualizar que a escolha da regressão linear segue a estratégia de baixa penalidade para o ajuste dos modelos.

Outra observação é que a característica da degradação, vista na Figura 26, é similar à degradação linear por partes, que limita o valor máximo do RUL. Segundo Heimes (2008), pode-se delimitar um valor máximo com base nas observações dos dados e seu valor pode ser diferente para cada conjunto de dados. Por este motivo, foi utilizada a função *Piecewise* para estimar o RUL, levando em consideração que a degradação começa após um certo grau de uso do ativo (LIM et al., 2014; ZHENG et al., 2017; MODE; CALYAM; HOQUE, 2019; JAYASINGHE et al., 2019).

No caso do conjunto de dados em questão, foi percebida uma característica de falha em uma média de setenta e cinco dias, equivalente a mil e oitocentos ciclos de telemetria, o que trouxe um limite de análise para aplicação do *Piecewise* e a pretensão de antecipação da falha. Todos os testes vão avaliar o início da apresentação da falha, mas, inicialmente, o foco foi no limite de cento e vinte ciclos o que permitiria uma previsão de falha com cinco dias de antecedência.

A metodologia proposta também prevê a estratégia de verificação do RUL de forma contínua a cada leitura de telemetria diária com novos vinte e quatro ciclos. A ideia é refazer os cálculos dos índices de degradação e verificar, novamente, a situação da máquina estimando um novo RUL. Conforme previsto no modelo, a partir do resultado da predição é possível criar as *constraints* necessárias para a realização do agendamento de produção, levando em consideração o momento em que a máquina não estará disponível devido à necessidade de manutenção.

Figura 26 – Gráfico da regressão linear e logística utilizada para criar o HI. Característica similar a ideia da aplicação do *Piecewise* de (HEIMES, 2008).



Fonte: O Autor

## 5.6 Processo de integração das agendas de manutenção e produção

Conforme a sequência no fluxo do modelo, esta seção descreve os passos para a criação do escalonamento da produção baseado nos resultados da predição. Com isso, é apresentada a modelagem e as necessidades do experimento final.

A modelagem matemática do problema descreve que existem  $M = M_1, M_2, \dots, M_m$ , 1 ou  $m$  máquinas para realizar  $J = J_1, J_2, \dots, J_n$ , 1 ou  $n$  tarefas. No caso deste trabalho, por se tratar de I4.0, que tem, como uma de suas prerrogativas apresentar a possibilidade de uma produção personalizada, o problema do *Job Shop Scheduling Problem* (JSSP) foi identificado como o mais indicado. Se simulada a situação de  $M = A, B$  e  $J = A, B, C$  a execução da produção deve seguir para a máquina  $A$ , executando os trabalhos  $A, B$  e  $C$ . Para a máquina  $B$ , deve-se obedecer à restrição do JSSP de que nenhum trabalho pode ser iniciado numa máquina que esteja ocupada, tendo que executar os trabalhos  $B, C$  e  $A$  (FITOURI et al., 2016).

Na implementação clássica, o JSSP, considera-se que as máquinas estão sempre 100% disponíveis, isso deve ser modificado, porque para a realização da integração com a manutenção será utilizada a definição de sistema de máquinas com disponibilidade limitada (SCHMIDT, 2000). Além do tempo considerado de uso da máquina  $M$  para execução do trabalho  $J$ , é inserido um tempo de intervalo de disponibilidade  $D = [I_1, F_1]$ , que significa o início e o fim do período de disponibilidade da máquina 1. Estas restrições tem as entradas da PdM identificadas como *constraints*. A notação matemática foi baseada em Fitouri et al. (2016) e o resultado das adaptações destacadas, em negrito, podem ser visualizadas na Tabela 11.

Devido os experimentos utilizarem um conjunto de dados já preparado, foram criados cenários baseados na telemetria e informações de coleta de dados de um ano com aquisição a cada hora. Para a realização de um experimento, o problema foi modelado com a seguinte situação:

- **1** - Divisão dos períodos de agendamento da produção de forma semanal;

Tabela 11 – Notações no JSSP de produção e manutenção preditiva

Símbolos	Designação
$J = J_1, J_2, \dots, J_i$	Conjunto de $i$ trabalhos
$M = M_1, M_2, \dots, M_k$	Conjunto de $k$ máquinas(recursos)
$O_{ijk}$	A $j^{th}$ operação do trabalho $J_i$ a ser processada na máquina $M_k$
$p_{ijk}$	Tempo de processamento da operação $O_{ijk}$
$s_{ijk}$	Hora de início da operação $O_{ijk}$
$D = I_{M_k}, F_{M_k}$	<b>Período de disponibilidade da <math>M_k</math>. Início <math>I_{M_k}</math> - Fim <math>F_{M_k}</math></b>
$p_{M_k}$	<b>Duração de uma tarefa de manutenção proposta na máquina <math>M_k</math></b>

Fonte: Adaptado de Fitouri et al. (2016)

- **2** - A divisão da jornada diária da fabricação é de 3 turnos de 6 horas totalizando 126 horas de tarefas semanais;
- **3** - Baseado nos 4 modelos de máquinas, foi montada uma necessidade de escalonamento, considerando que cada modelo está disponível em um determinado período de atividade, por exemplo, modelo 1 - uma hora até o modelo 4 - quatro horas;
- **4** - É verificado o dia apontado na PdM e a máquina é alocada para manutenção durante a semana identificada  $D = I_{M_{semana_k}}, F_{M_{semana_k}}$ , essa será a *constraint*;
- **5** - Diariamente, com a realização de 24 ciclos de telemetria, é realizada a verificação contínua da PdM e, se houver indícios de falha, é gerado novamente o escalonamento;
- **6** - A simulação foi realizada utilizando o problema JSSP;
- **7** - Com o escalonamento realizado, é gerado um gráfico de Gantt, assim o resultado é utilizado como um indicador pelos setores de manutenção e decisão de produção.

Com o cenário criado, foram realizados estudos dos algoritmos e a aplicação das notações da Tabela 11. Após a avaliação dos objetivos deste trabalho, foi decidido pela utilização de uma solução *open source* chamada *OR-Tools* iniciativa da *Google Developers* criada para a resolução de problemas de otimização combinatória (DEVELOPERS, 2020). Para utilizar o recurso do *Job Shop* do *OR-Tools* é necessário ter as informações de como o modelo deve ser parametrizado. O resultado é o agendamento que determina as tarefas em cada máquina e aponta o período da parada da manutenção  $P = [I_{M_1}, F_{M_1}]$  e modifica a disponibilidade  $D = [I_{M_1}, F_{M_1}]$  da máquina, que significa o início e o fim deste período na máquina 1.

## 5.7 Incremento do fluxo lógico do modelo PdMS

Após as definições relacionadas aos requisitos da metodologia a ser aplicada, foi identificado que o fluxo lógico proposto no modelo pode ser modificado, adicionando mais detalhes para atender aos desafios visualizados em conjuntos de dados ruidosos e sem informações de operações das máquinas. O PdMS ainda mantém a divisão em duas fases, mas

algumas hipóteses devem ser mais detalhadas e, com isso, é apresentada a nova descrição do fluxo da Figura 27:

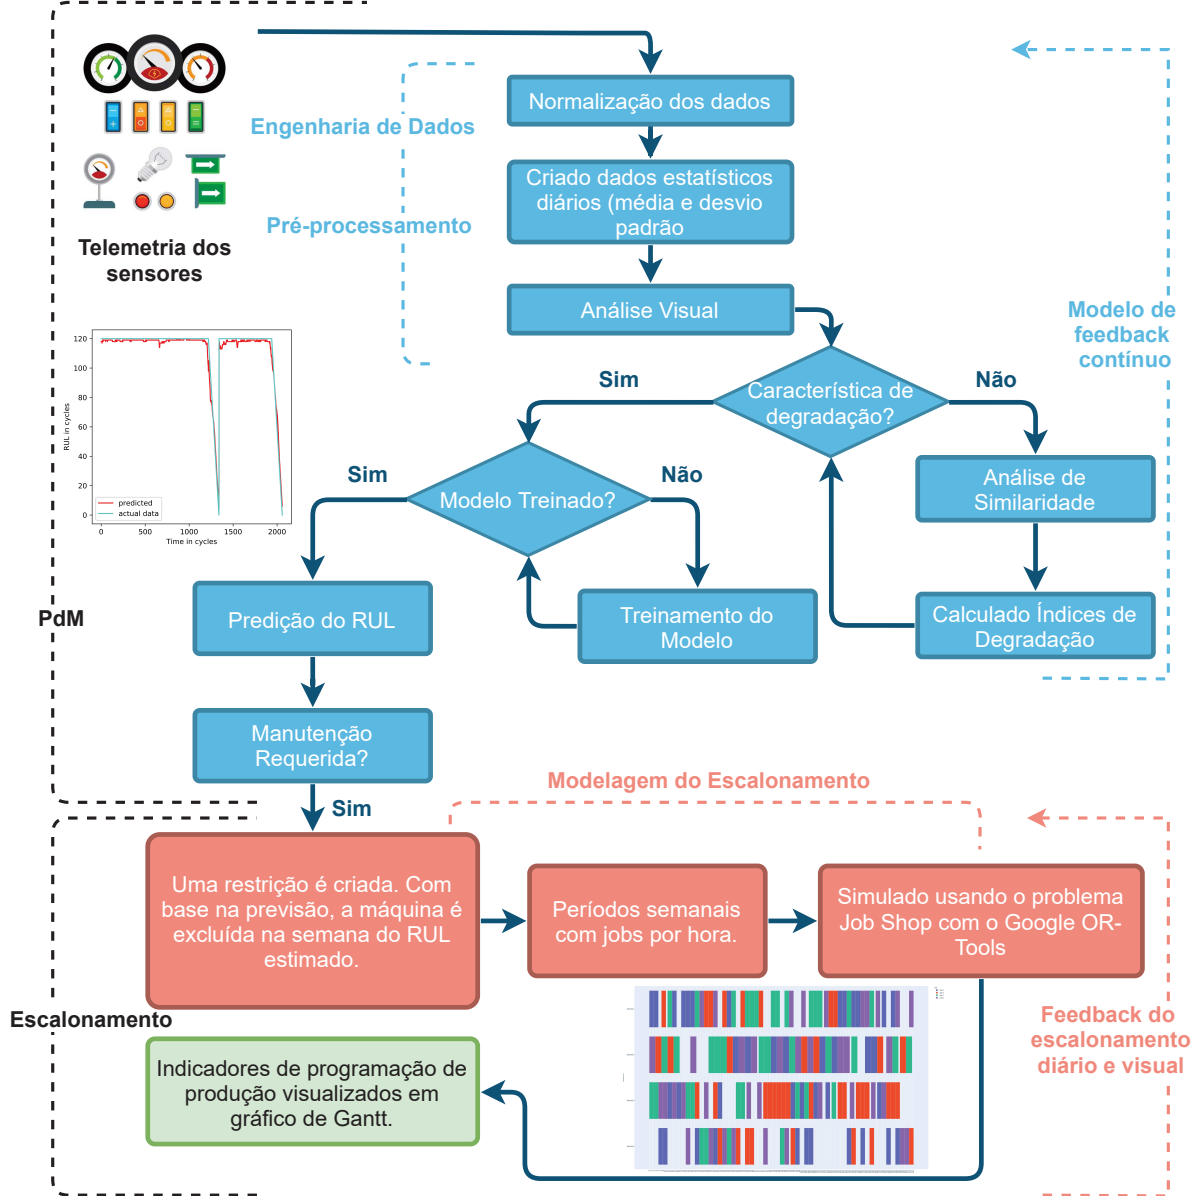
- O processo da PdM realizará a ciência de dados, não apenas a padronização e limpeza inadequadas de dados, mas também um estudo com uma avaliação incremental de cada estratégia a ser utilizada para possibilitar que dados com ruídos possam apresentar resultados satisfatórios. A PdM é iniciada com a avaliação visual das características de degradação do ativo. Se o processo visual demonstrar baixo índice de degradação, dados sintéticos baseados na telemetria e similaridade dos dados históricos devem ser avaliados. Como o modelo prevê novas entradas de telemetria de forma diária, o modelo deverá refazer o processo, gerando um *feedback* contínuo. Após o processo visual e a adequação das *features* com o uso do RRF, é realizada a predição com modelos baseados de DNN, RNN e RRF;
- Com a predição do RUL, a segunda fase poderá ser atendida, criando as *constraints* para o problema do escalonamento e apresentando uma abordagem que é modificada diariamente. O resultado deve ser através da geração de gráficos visuais, demonstrando o cronograma da produção levando em consideração a possibilidade de um ativo estar em manutenção no período. A cada nova etapa da hipótese, os resultados serão avaliados.

## 5.8 Considerações finais

A metodologia proposta apresenta a necessidade de avaliação das características de degradação. No caso do conjunto de dados utilizado, foi percebido que não era possível utilizar as informações da telemetria esperando resultados somente com a padronização, limpeza, pré-processamento e normalização dos dados como visto nos exemplos de aprendizado de classificação supervisionada. Esse entendimento surgiu quando foram analisados os conjuntos de dados do PCoE, que disponibiliza exemplos de dados originais e dados já preparados para simulação. Isso foi percebido quando comparadas as estratégias de Wang et al. (2008), que buscam extrair resultados de dados ruidosos e sem características de degradação, e Mode, Calyam e Hoque (2019) que utilizam os dados de simulação para testar modelos de aprendizado de máquina e simular ataques em ambientes de IoT. Nesta observação, foi percebido que as estratégias de Wang et al. (2008) estavam ligadas à um processo de melhoria dos dados através da similaridade, ou seja, o objetivo era melhorar os resultados mesmo com dados com poucas informações de degradação. Já no caso de Mode, Calyam e Hoque (2019), o objetivo foi criar possíveis ambientes de ruídos criados por ataques externos aos dados já adequados.

Relacionado ao problema do escalonamento os desafios ficaram para a modelagem dos dados da simulação de uma situação real. Foi necessário também, entender como o *OR-Tools* deve ser parametrizado e como são gerados os resultados para criação dos cronogramas em

Figura 27 – Modelo PdMS. Adequação do fluxo da Figura 17, demonstrado de forma conceitual o aumento das hipóteses metodológicas.



Fonte: O Autor

formato de gráficos. A escolha do *OR-Tools* e a característica de produção personalizada e serializada motivou a escolha do problema com o JSSP. Este capítulo utilizou-se do modelo inicial criado e evoluiu para uma metodologia de aplicação com criação de hipóteses e requisitos, que serão aplicados a seguir.

## 6 RESULTADOS E DISCUSSÃO

Neste capítulo, são apresentados maiores detalhes referente as avaliações realizadas no processo incremental da metodologia, cada passo, é descrito juntamente com os resultados, discussões e percepções em comparação aos trabalhos relacionados. Para a realização do treinamento, validação e teste, foi utilizado um computador com processador Intel Core i7-9700K de 32 GB de RAM e um NVIDIA Titan XP com 12 GB de memória.

### 6.1 Avaliações iniciais e análise visual dos resultados

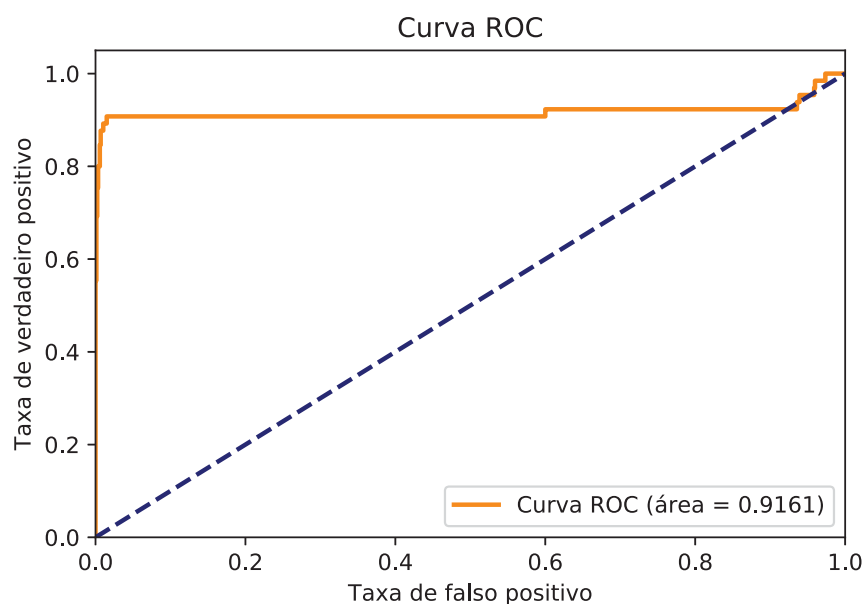
O primeiro passo a ser descrito é a avaliação da possibilidade de aplicação do aprendizado de classificação supervisionada. A proposta deste passo veio a partir da identificação de que, a cada novo conjunto de dados utilizado, é importante conhecer as informações e características das máquinas além da descrição dos manuais e conhecimento dos Engenheiros. Como o objetivo deste trabalho não é somente apontar se houve a falha, não foi realizado um detalhamento de critérios de comparação de resultados. O objetivo foi realizar estudos estatísticos e testar as modelagens das janelas de atraso e como os modelos se comportavam com o conjunto de dados escolhido.

As comparações foram feitas com os resultados disponibilizados pela Azure (2020) e a Figura 28 apresenta o resultado da curva ROC utilizada para ilustrar o desempenho de um sistema de classificação binária. A curva em questão é da aplicação do LSTM seguindo a arquitetura de hiperparâmetros padrões do *Keras*, com uma camada de entrada, duas camadas ocultas de LSTM e camadas de saída DFF. Os resultados foram comparados com as soluções clássicas citadas e não trouxe grandes diferenças, sendo que, o *XGBoost*, por exemplo, chegou a apresentar 94% de ROC. Nas avaliações realizadas, foi possível observar que as informações de erro, manutenção e falhas tem importância elevada no apontamento da falha, já a telemetria não traz contribuições expressivas no aprendizado dos modelos no caso da classificação.

Após o primeiro passo, o próximo estudo realizado está relacionado à modelagem do problema de regressão, com o objetivo de prever o RUL. Conforme metodologia, é utilizada a análise visual das características dos dados para aumentar o entendimento referente ao seu comportamento. Para isso, foram realizados as primeiras avaliações dos modelos DNN e RNN utilizando a parametrização descrita como básica: janela contínua de 100 ciclos de atraso, modelos com uma camada de entrada, duas camadas ocultas DNN ou RNN e camadas de saída DFF sem alterações nos hiperparâmetros padrões do *Keras*.

Os resultados iniciais não foram satisfatórios: abaixo de 30% de  $R^2$  e MAPE, embora o RMSE tenha registrado uma média de 60 a 90 ciclos (horas) de diferença, mas em qualquer caso de PdM, o erro de previsão de falha pode ser prejudicial. A Figura 29 traz o resultado da máquina 75, com previsão de duas falhas no período. O gráfico é baseado na previsão utilizando CNN. No gráfico é possível observar uma relação entre a detecção de forma precoce de falhas,

Figura 28 – Curva ROC do aprendizado de classificação supervisionada utilizando LSTM.



Fonte: O autor

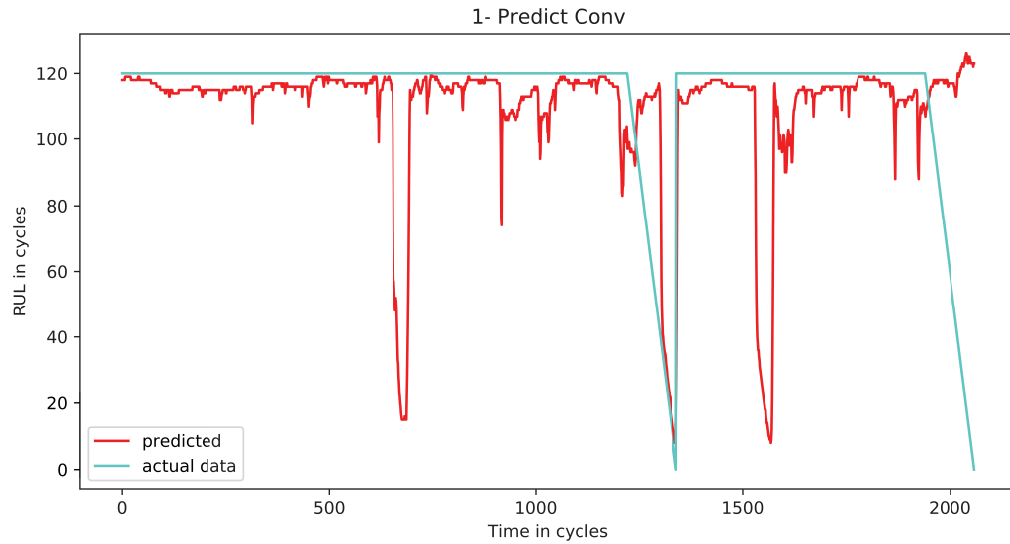
o que pode sugerir um ruído no conjunto de dados.

Conforme esperado, os resultados iniciais demonstram a necessidade de mais análises nos dados e avaliação da possibilidade da criação de informações que possam apoiar os modelos. Com isso, foi aplicada a primeira hipótese de criação de características diárias de média e desvio padrão da telemetria. O resultado possibilitou criar a análise da Figura 30, que demonstra que as informações diárias melhoram a correlação da telemetria. De qualquer forma, o gráfico contribuiu na identificação de que os dados de telemetria não apresentam um índice de correlação expressivo e isso se agrava quando não são conhecidas maiores informações de operação e *setup* das máquinas. Algo que pode ser observado é o exemplo da baixa correlação entre a tensão e a rotação, algo que não é muito comum, porque normalmente quando existe uma distorção de rotação a tensão tende a aumentar.

Para obter maiores informações, foi dada sequência nas hipóteses e foi testada a estacionaridade utilizando o *Augmented Dickey-Fuller*. O resultado obtido foi que a telemetria é estacionária. Quando uma série temporal está estacionária, pode contribuir no aprendizado do modelo. De qualquer forma, deve-se validar se a característica contribui para uma tendência sazonal de indicação da ocorrência da falha e, conseqüentemente, a predição do RUL. Para essa visualização também foi gerado um gráfico, apresentado na Figura 31, que mostra um exemplo da análise para uma máquina específica: os quatro primeiros gráficos mostram a telemetria de todos os sensores, enquanto os quatro últimos apresentam apenas a média diária. Essa análise colabora no entendimento de que a criação de características diárias melhora a identificação de tendência. Mas infelizmente, ainda é possível verificar que a tendência é bastante sutil - o que pode prejudicar na hora da predição. A característica esperada no gráfico




Figura 29 – Resultado da PdM da máquina 75 utilizando CNN sem a criação dos índices de degradação.



Fonte: O Autor

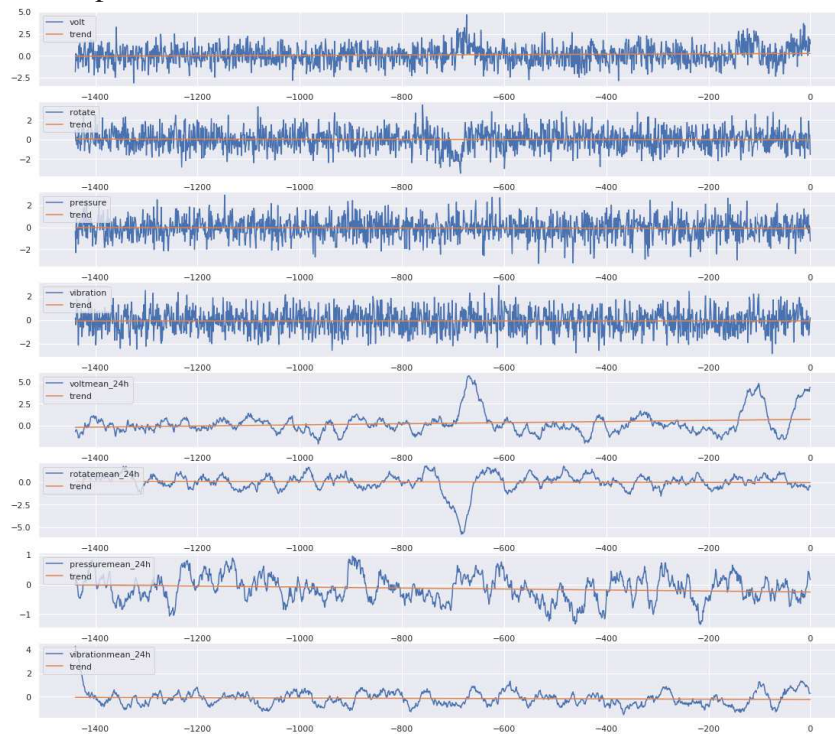
Figura 30 – Correlação da telemetria da máquina 75.



Fonte: O Autor

de tendência é de aumento ou diminuição da linha próximo ao momento da falha e não linear, como pode ser visto na figura.

Figura 31 – Análise de séries temporais e tendências para telemetria de cada sensor da máquina 75. Os primeiros quatro gráficos mostram a telemetria de todos os sensores, enquanto os quatro últimos apresentam apenas a média.



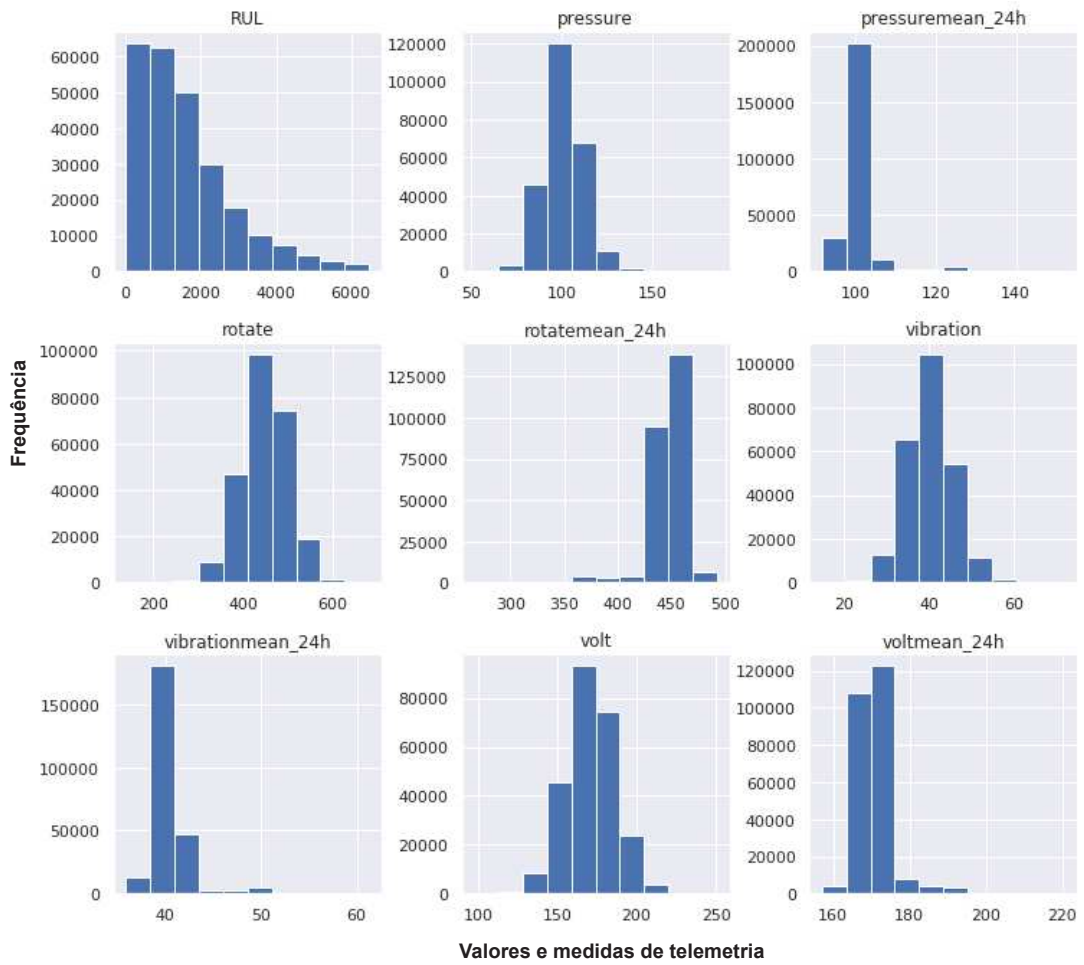
Fonte: O Autor

Outro gráfico que corrobora nesta análise é o histograma gerado a partir dos dados da telemetria original e a média diária apresentado na Figura 32. Os gráficos demonstram uma distribuição gaussiana normal que é considerada benéfica, mas, novamente, é possível observar a falta de comportamento contínuo, o que confirma a hipótese do modelo não convergir para o apontamento correto do RUL. No gráfico também é mostrada a distribuição do RUL, que tem uma sazonalidade decrescente, o que não se repete na telemetria.

## 6.2 Criação de características de degradação baseado na similaridade do dados


Com a aplicação das estratégias visuais e estatísticas, foi possível entender a dificuldade para os modelos em apresentar resultados satisfatórios de predição. Uma das hipóteses é que a falta de informações operacionais no conjunto de dados pode estar dificultando o aprendizado. Para isso, foi criado o DI e reavaliada a predição. Os resultados ficaram abaixo de 70% de  $R^2$  e MAPE, e o RMSE caiu para uma média de 30 a 40 ciclos de diferença, conforme apresentado na Figura 33. O gráfico já traz uma característica mais próxima da falha, mas ainda é perceptível que existem informações que o modelo está considerando como importantes para apontamento da falha.

Figura 32 – Histograma dos dados da telemetria e do RUL.



Fonte: O Autor


Figura 33 – Resultado da PdM da máquina 75 utilizando CNN com a criação do DI.



Fonte: O Autor

O próximo passo previsto na metodologia é a criação do HI para comparar com os resultados do DI. Após este processo, os testes foram refeitos e, conforme apresentado na Figura 34, o gráfico ficou muito próximo dos resultados da aplicação do DI, mas com identificação de falhas em pontos diferentes. Com isso, foi utilizado, novamente, o RRF para verificar a importância das *features* do conjunto de dados juntamente com o índices criados. Neste processo, foi percebido que os dados relacionados a erros e manutenção não são importantes no problema de PdM, como no exemplo de classificação supervisionada. Porém, a visualização dos gráficos trouxe a ideia de combinar os índices de DI e HI com o objetivo de melhorar os resultados.

Figura 34 – Resultado da PdM da máquina 75 utilizando CNN com a criação do HI.



Fonte: O Autor

### 6.3 Combinação dos índices baseados na similaridade dos dados e melhoria dos hiperparâmetros

A combinação dos índice seguiu a ideia aplicada em Liu et al. (2007), Wang et al. (2008), Dudek (2015), Zhang, Yang e Wang (2019), Liang et al. (2019) utilizando a funcionalidade da biblioteca do *sklearn.decomposition.PCA* que aplica a diminuição de dimensionalidade dos vetores usando PCA juntamente com o método *numpy.empty\_like*. Segundo Dudek (2015), o PCA transforma componentes do x-padrão linearmente correlacionados em um conjunto de componentes principais não correlacionados linearmente, e o número de componentes principais pode ser menor ou igual ao número de componentes originais. Esse processo criou uma nova *feature* chamada de *HI\_fitted*.

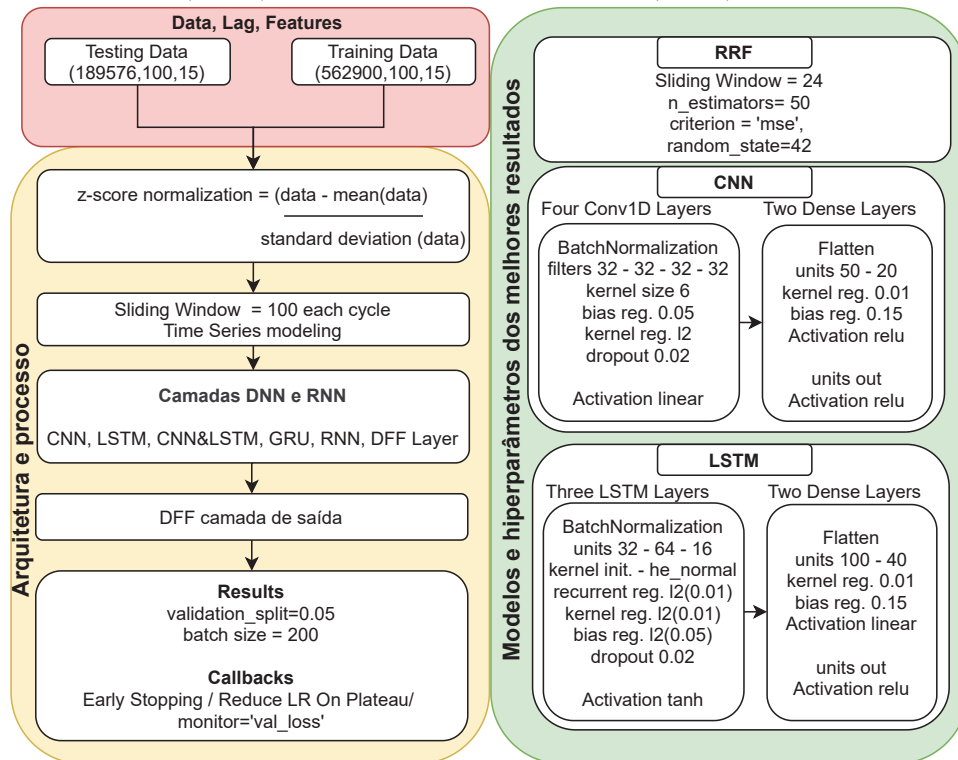
Juntamente com a aplicação da hipótese de combinação dos índices, foram realizadas adequações dos modelos DNN e RNN testando diferentes hiperparâmetros para funções de

perda, ativação, *optimizer* e *batch size*. Os resultados apresentados utilizaram *Loss Function* = MSE. Foi testada a *scoring loss function* proposta em (ZHENG et al., 2017), mas o MSE mostrou resultados mais estáveis. Para a função de ativação na camada NN = linear, função de ativação nas camadas DFF = relu, *optimizer* = RMSProp, *validation\_split* = 0.05 e *batch size* = 200. Estes foram os melhores resultados encontrados e isso permitiu a apresentação de uma arquitetura focada para o modelo proposto.

Para efeito de comparação, a arquitetura é igual para todos os modelos e na Figura 35 são destacados os três melhores resultados. Na estrutura RRF, foi utilizado 50 *estimators*, *criterion* = MSE e *random\_state* = 42. No CNN, são quatro camadas Conv1D = 32, *Kernel size* = 6, configuração do *regularizer* e *bias* seguida por duas camadas de saída Densa. No LSTM, são três camadas = 32-64-16 com a configuração *regularizer* e *bias*, e também foi utilizado duas camadas Densas para a saída.

A escolha em utilizar diferentes métodos de ML tem como objetivo analisar as características de cada técnica e, com isso, identificar qual delas é a mais adequada para o conjunto de dados escolhido. A ideia principal é estar preparado para identificar e estender essa proposta para outros casos na indústria. Com o conhecimento do funcionamento, parametrização e características de vários métodos será possível encontrar o mais adequado para diferentes situações e sinais gerados pelos sensores.

Figura 35 – Arquitetura com melhor resultado aplicada à *Regression Random Forest* (RRF), *Deep Neural Networks* (DNN) e *Recurrent Neural Network* (RNN).

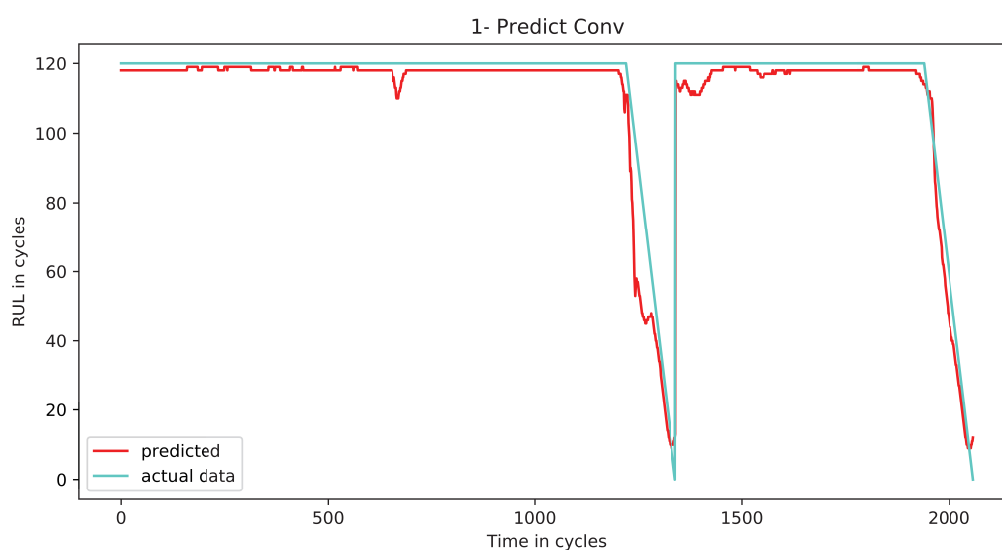


Fonte: O Autor

Durante a adequação dos hiperparâmetros foram percebidas melhorias consideráveis, mas

quando aplicada à arquitetura proposta com a combinação dos dois índices os resultados foram de 70% para 90% de  $R^2$  e MAPE e o RMSE caiu para uma média de 3 a 17 ciclos de diferença. Os resultados permitiram a predição da falha com uma antecedência de cento e vinte ciclos de telemetria o que equivale a 5 dias para a PdM. Se avaliada a Figura 36, o gráfico baseado nos dados de teste demonstra um processo de aprendizagem e predição muito importante, identificando, e não mais confundindo, possíveis falhas fora do período. Isso demonstrou que a combinação dos dois índices reduziu, significativamente, o ruído para a predição do RUL.

Figura 36 – Resultado da PdM da máquina 75 utilizando CNN combinando os índices DI e HI.



Fonte: O Autor

#### 6.4 Testes comparativos com aplicação de filtros de suavização

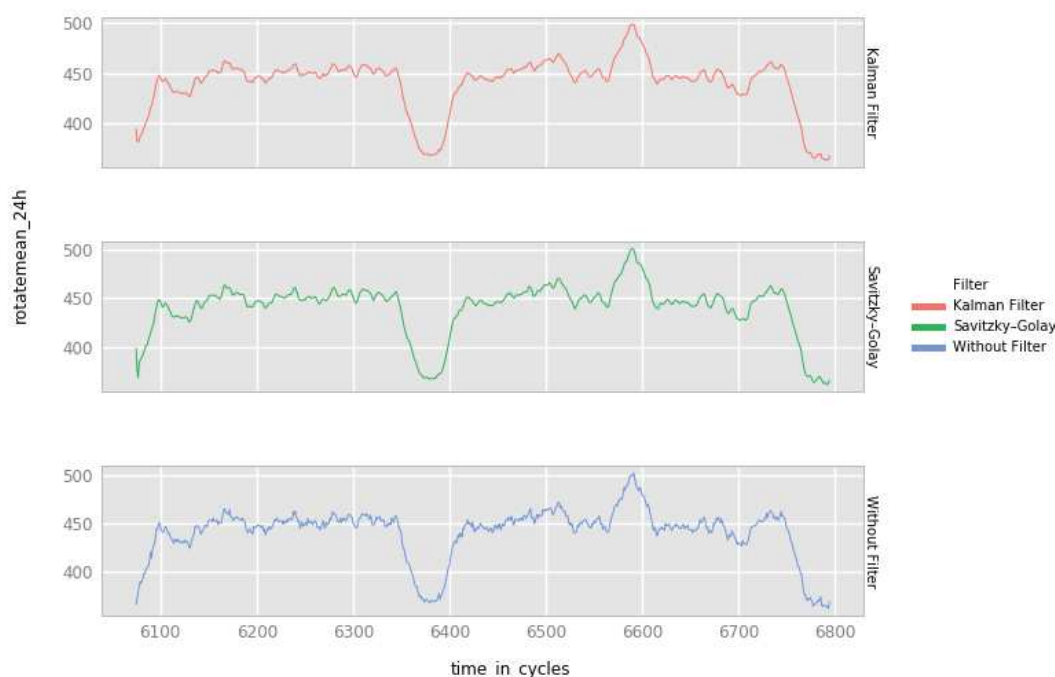
Mesmo que os testes tenham apresentado os resultados satisfatórios, observou-se, durante a criação dos índices, análise visual dos dados e exemplos na literatura, a possibilidade de aplicação de filtros de suavização. Filtros de suavização são comumente usados para tratamento de sinal e remoção de ruídos, e por isso, foram feitos testes para avaliação de seu impacto na telemetria (WANG et al., 2008; LIM et al., 2014; JIMENEZ-CORTADI et al., 2020; CAI et al., 2020).

Baseado nos trabalhos citados, foram selecionados os filtros de Kalman e de Savitzky-Golay. Segundo Jimenez-Cortadi et al. (2020), Savitzky-Golay, é um método baseado no valor médio móvel conhecido como convolução. São ajustados os pontos adjacentes com um polinômio de baixo grau pelo método dos mínimos quadrados lineares. No trabalho em questão, a aplicação do filtro contribuiu em até 10% na identificação de anomalias com o método de agrupamento iterativo, como foi chamado. Já no caso do filtro de Kalman,

segundo Lim et al. (2014), sua aplicação mais comum é como um estimador de estado de passagem para frente. O filtro prevê os estados ocultos para a próxima etapa de tempo, dado o histórico de estados estimados e, observando saídas ruidosas. Os estados previstos são considerados ótimos, pois o filtro visa minimizar as incertezas.

A Figura 37 mostra um exemplo da média diária da telemetria de rotação da máquina 50 com o sinal original e com a aplicação dos dois filtros. Mesmo sendo difícil a percepção visual, há melhora nos sinais e suavização nos picos, contribuindo para o aprendizado do modelo. O ruído é removido nas amostragem dos sensores porque os algoritmos de ML podem associar esse ruído à informações importantes para a previsão do RUL. O objetivo, então, é melhorar ainda mais o prognóstico de falha ou alterar o aprendizado do modelo. Por este motivo, não foi realizado um estudo aprofundado para aplicação dos procedimentos matemáticos dos filtros de suavização e, de forma experimental, foram utilizados os módulos *savgol\_filter* e *KalmanFilter* das bibliotecas SciPy (2021), Pykalman (2019).

Figura 37 – Comparação de sinais sem e com filtros da média diária de rotação dos dados de teste da máquina 50.



Fonte: O Autor

Para realização de um comparativo, foram criados gráficos para cada critério: RMSE, MSE, MAE,  $R^2$  e MAPE. Os critérios foram divididos em três situações: sem filtros de suavização com os resultados apresentados na Figura 38, com aplicação do filtro de Kalman apresentado na Figura 39 e aplicação de Savitzky–Golay na Figura 40. A Tabela 12 faz um comparativo dos melhores e piores resultados de cada situação e demonstra pequenos ajustes que trazem diferenças importantes para o aprendizado dos modelos.

Tabela 12 – Comparação do melhor e pior resultado de cada situação

Resultado	Modelo	RMSE	MSE	MAE	$R^2$	MAPE
Melhor resultado sem filtro	CNN	9.301	86.503	2.419	0.830	90.85
Pior resultado sem filtro	DFP	14.365	206.351	10.209	0.594	86.35
Melhor resultado com filtro de Kalman	CNN	9.669	93.484	2.504	0.816	90.64
Pior resultado com filtro de Kalman	DFP	15.724	247.229	9.724	0.514	86.7
Melhor resultado com Savitzky-Golay	CNN	8.789	77.253	2.262	0.848	92.22
Pior resultado com Savitzky-Golay	DFP	14.19	201.342	11.249	0.604	83.81

Fonte: O Autor

Analisando todos os testes, a discussão relacionada à utilização dos filtros de suavização mostrou que a aplicação do Savitzky-Golay teve os melhores resultados. Na Figura 40 pode ser observado resultados mais consistentes para o modelo CNN com  $RMSE = 8.789$ ,  $MSE = 77.253$ ,  $MAE = 2.262$ ,  $R^2 = 0.848$ ,  $MAPE = 92.22$  e RRF com  $RMSE = 10.102$ ,  $MSE = 102.052$ ,  $MAE = 2.887$ ,  $R^2 = 0.789$ ,  $MAPE = 95,01$ . Ao contrário dos modelos DNN e RNN, para RRF, foi utilizada uma janela de atraso de vinte e quatro ciclos. Desta forma, o tempo de resposta foi muito maior, o que influenciou na escolha da solução. Outro ponto importante é o comportamento dos resultados para a rede LSTM, os resultados para LSTM foram  $RMSE = 11.409$ ,  $MSE = 130.159$ ,  $MAE = 3.159$ ,  $R^2 = 0.744$ ,  $MAPE = 91.08$ , e se comparados com os trabalhos relacionados, ficaram abaixo das expectativas (HEIMES, 2008; ZHENG et al., 2017; DONG; LI; SUN, 2017; BRUNEO; De Vita, 2019).

Nos resultados, aplicando filtros de telemetria, foi observada alteração apenas em alguns pontos. Isso porque, após a geração dos índices de saúde, a importância do aprendizado concentra-se nos recursos criados. Os resultados com os índices já apresentam a remoção de ruído e destacam a característica de decaimento. De qualquer forma, os resultados da aplicação do filtro de Savitzky-Golay permitiu melhorias, e sua suavização está melhor adaptada à telemetria do conjunto de dados utilizado. Já no caso dos resultados do filtro de Kalman apresentados na Figura 39, percebe-se que a sua utilização possivelmente seria uma solução para situações com ruído mais complexo (LIM et al., 2014).

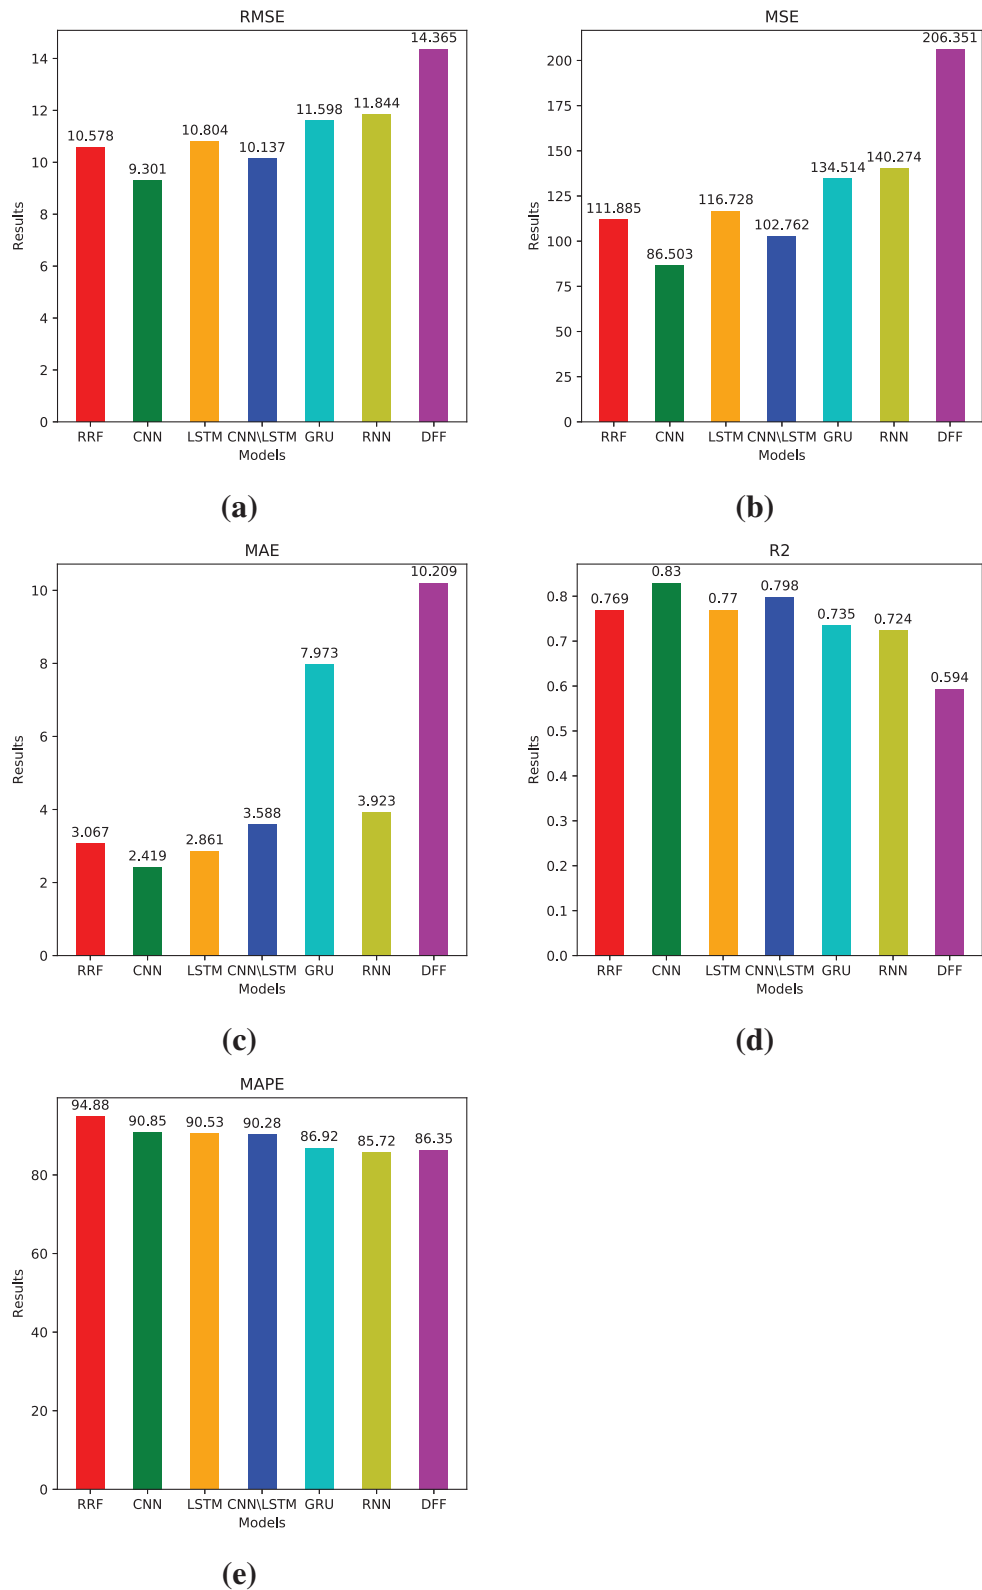
Também podem ser comparados os resultados da Figura 41 com a aplicação do filtro Savitzky-Golay e a Figura 36 dos testes iniciais da combinação de DI e HI sem o filtro. Pôde-se perceber que os resultados tiveram uma melhora visual e estatística entre 2% a 3% no  $R^2$  e MAPE devido à suavização de alguns picos.

Referente à comparação entre os modelos, a Figura 41 apresenta os resultados da máquina 75 aplicando CNN e LSTM, sendo os dois modelos com melhor desempenho. Nas figuras é possível perceber que, mesmo com duas falhas, os modelos mantêm uma característica sem sinais de falhas durante um período e, próximo ao período de cento e vinte ciclos, começam os sinais de degradação até a falha.

Os resultados superiores da CNN, quando comparados ao LSTM e outras DNNs, podem



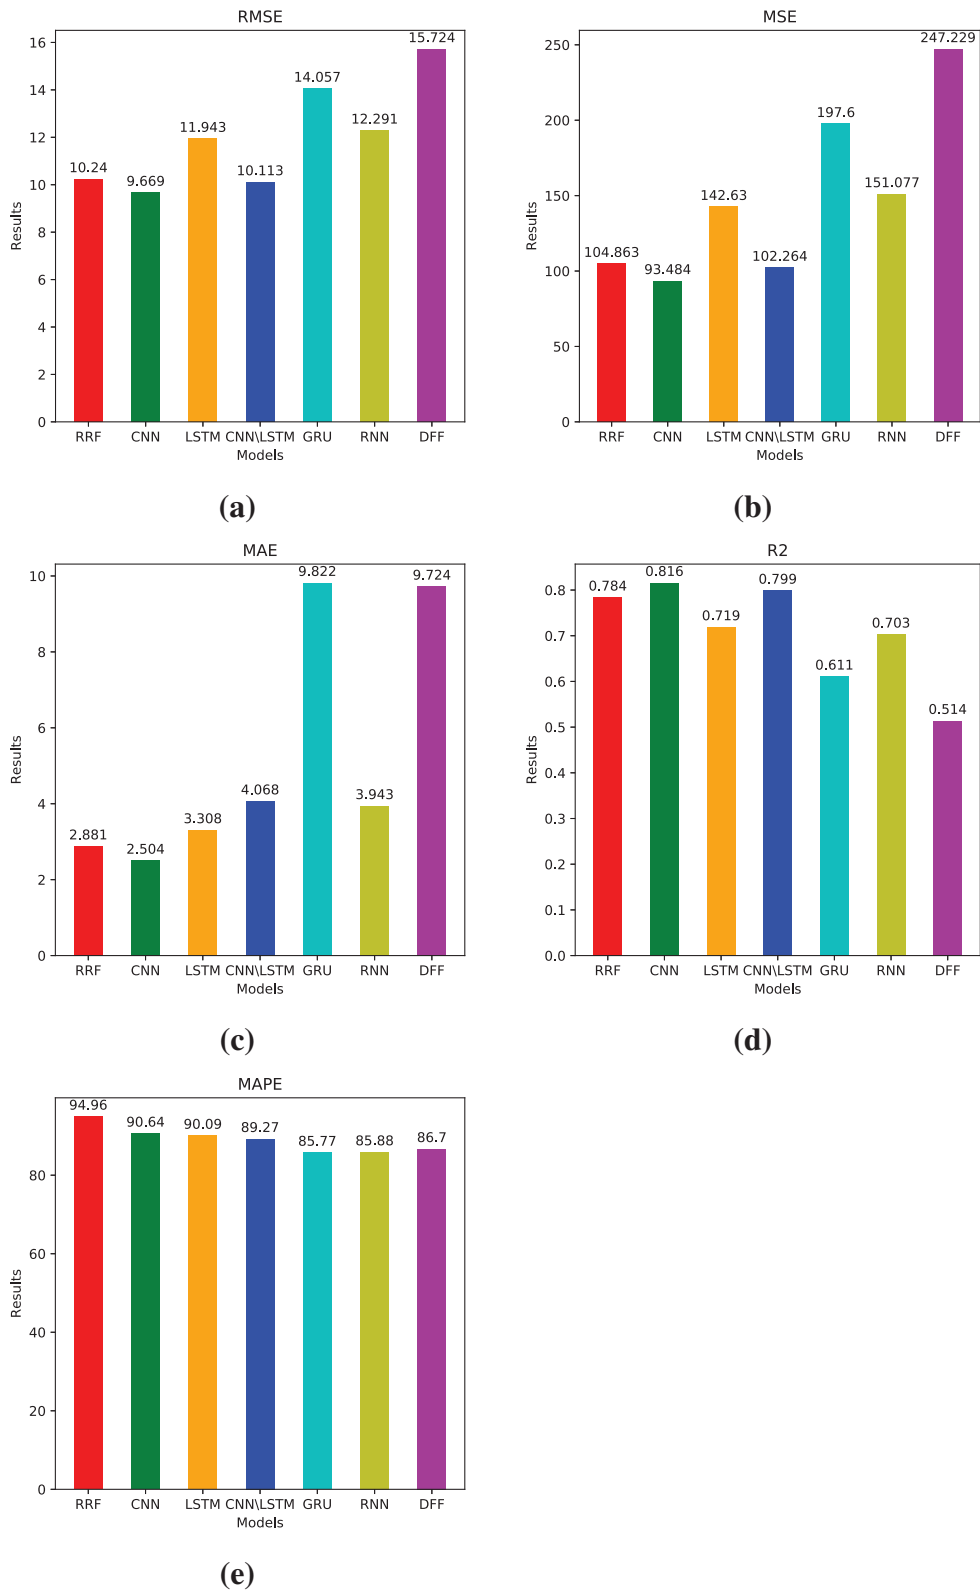
Figura 38 – Comparação de resultados sem aplicação de filtros de suavização em telemetria. (a) RMSE. (b) MSE. (c) MAE. (d)  $R^2$ . (e) MAPE.



Fonte: O Autor

estar relacionados à capacidade das CNNs de se adaptarem a dados ruidosos. Além disso, as CNNs são capazes de extrair informações profundas independentemente de conexões temporais

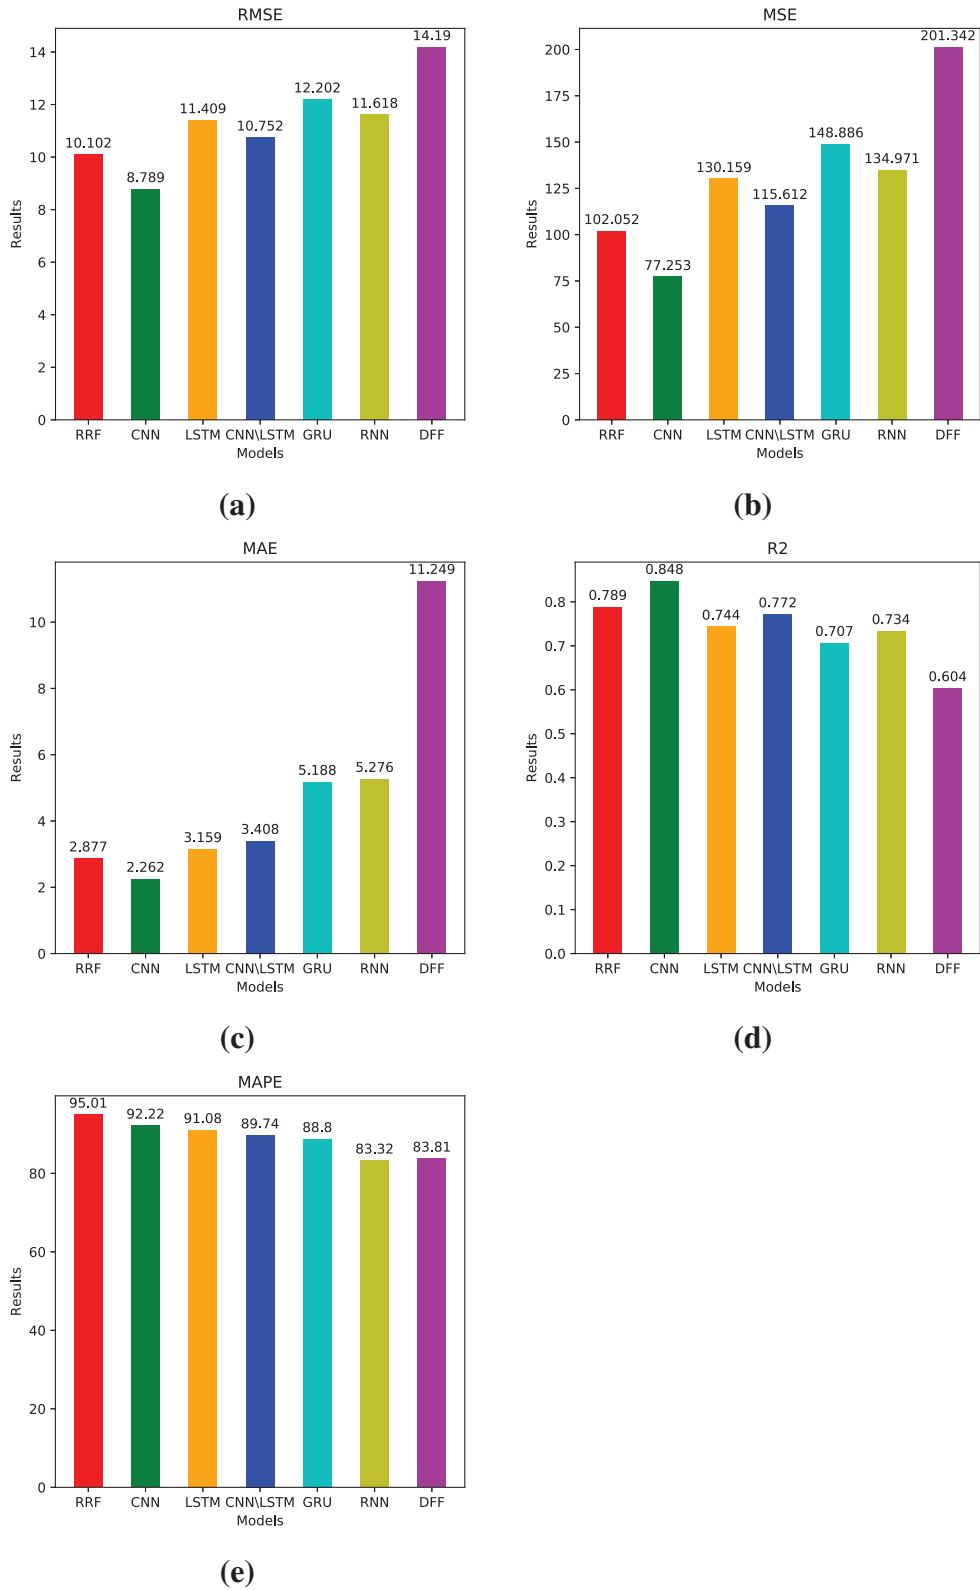
Figura 39 – Comparação de resultados usando o filtro de Kalman na telemetria. (a) RMSE. (b) MSE. (c) MAE. (d)  $R^2$ . (e) MAPE.



Fonte: O Autor

(CUI; CHEN; CHEN, 2016). Outro fator importante foi o uso de DFF para camadas de rede de saída. As aplicações isoladas de DFF não apresentaram resultados satisfatórios com  $RMSE =$

Figura 40 – Comparação de resultados usando o filtro Savitzky-Golay na telemetria. (a) RMSE. (b) MSE. (c) MAE. (d)  $R^2$ . (e) MAPE.

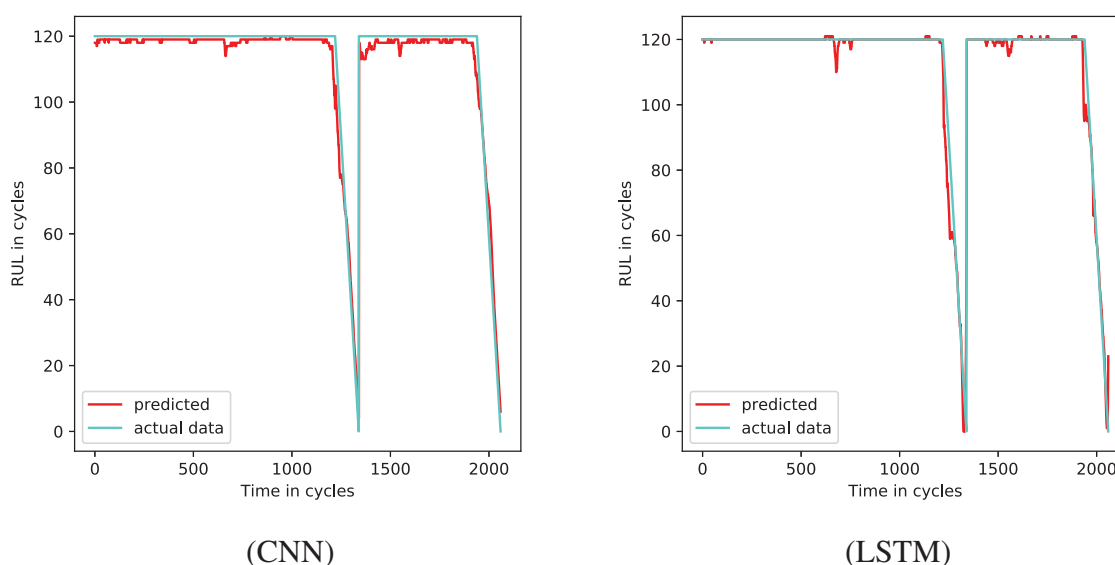


Fonte: O Autor

14.19,  $MSE = 201.342$ ,  $MAE = 11.249$ ,  $R^2 = 0.604$ ,  $MAPE = 83.81$ , como pode ser avaliado na Figura 40. Ainda assim, quando usado em conjunto com as DNNs ou RNNs, seu

desempenho melhorou. As DFFs, além de agrupar características extraídas pelos DNNs ou RNNs durante a inferência dos dados, trouxeram resultados não lineares e permitiram picos, identificando valores próximos ao mínimo e máximo do RUL (XIA et al., 2020).

Figura 41 – Comparação da previsão do RUL nos dados de teste da máquina 75 usando CNN e LSTM com filtro de Savitzky-Golay.



Fonte: O Autor

Para finalizar, as discussões e comparações realizadas na fase da PdM foram baseadas nos resultados e na evolução da aplicação da metodologia e do modelo proposto. Uma das limitações deste trabalho está relacionada à comparação dos resultados com a literatura, porque, conforme já mencionado, grande parte dos trabalhos relacionados utilizam conjuntos de dados do PCoE, então os índices e critérios alcançados não servem de parâmetro comparativo. Ainda assim, essa limitação é resultante de um dos objetivos desta fase, que foi a busca de um conjunto de dados mais próximo da ideia da aplicação real na indústria. Isso porque, serão encontrados, dados de sensores e informações de operação que não são geradas conforme o caso do C-MAPSS.

Mesmo com a impossibilidade de comparação dos resultados, foi criada a Tabela 13 para demonstrar as contribuições deste trabalho. Foram analisados quantos trabalhos utilizaram as estratégias de criação de índices de degradação, como o DI e HI, quantos usam *Piecewise*, filtros de suavização, se utilizaram similaridade e séries temporais e quais os modelos de ML foram testados e comparados.

Tabela 13 – Comparação das contribuições deste trabalho com as abordagens de PdM dos trabalhos relacionados

	Dataset	Utilizou (DI)	Utilizou (HI)	Piecewise	Filtros	Modelos	Baseado em Similaridade	Séries Temporais
Modelo PdMS	Azure AI para soluções de PdM	Sim	Sim	Sim	Savitzky-Golay e Kalman Filter	RFF and DNN (CNN, LSTM, GRU, RNN, FNN)	Sim	Sim
(WANG et al., 2008)	Desafio PHM08	-	Sim	-	-	Modelos de Regressão e Métodos de Média Móvel	Sim	-
(ZHENG et al., 2017)	C-MAPSS, Desafio PHM08 e Milling	-	-	Sim	-	Multi-Layer Perceptron (MLP), Support Vector Regression (SVR), Relevance Vector Regression (RVR), CNN and LSTM	-	Sim
(DONG; LI; SUN, 2017)	C-MAPSS~ Jet Engine Failure	-	-	-	-	LSTM	Sim	Sim
(BRUNEO; De Vita, 2019)	C-MAPSS	-	-	-	-	LSTM	-	Sim
(LIANG et al., 2019)	C-MAPSS	Sim	-	-	-	Regressão Linear, Modelo baseado em coeficiente de Spearman	Sim	-
(CAI et al., 2020)	C-MAPSS	-	-	-	Particle Filter	Rao-Blackwellized Particle Filter (RBPF)	Sim	-

Fonte: O Autor

## 6.5 Modelagem do problema do escalonamento e integração com a PdM


Com a fase da PdM atendendo o período de predição de cinco dias nos experimentos realizados na base de dados escolhida, é possível simular o processo de integração e as decisões relacionadas ao problema do escalonamento. Com a decisão da utilização do *OR-Tools* foi necessário estudar os parâmetros necessários para seu funcionamento. Como o modelo utilizado foi o JSSP, serão várias tarefas, processadas em várias máquinas. Para cada tarefa deve ser montada a previsão do agendamento da seguinte forma:  $jobX = [task(M, T)]$ , sendo que  $X$  é o número da tarefa, e, para cada um são criadas tarefas em que  $M$  é a máquina e o  $T$  o tempo.

O experimento considerou o período de um ano de planejamento, sendo 365 dias divididos em 52 semanas. A nível de avaliação, foram selecionadas 5 máquinas e, para cada máquina, é apontada a semana que a PdM previu a necessidade de manutenção. Devido à complexidade dos algoritmos, os testes utilizaram 4 tarefas. Para gerar o *makespan* foi considerado um período de trabalho de 126 horas, sendo 3 turnos de 6 horas por dia durante uma semana. Este valor é chamado de horizonte no *OR-Tools*. Outra característica é o tempo. O *OR-Tools* espera o período de início até o fim da tarefa da máquina e não somente o tempo.

A Figura 42 traz o resultado exibido de forma visual utilizando o gráfico de Gantt. Este é um exemplo com cinco máquinas na semana 6 em que uma das máquinas teve predição de falha no período previsto. Neste gráfico de Gantt a distribuição das tarefas por máquina é visualizada.

No caso da Figura 43, o gráfico de Gantt traz o resultado da distribuição das máquinas por

Figura 42 – Resultado do escalonamento para a semana 6 do ano de 5 máquinas sendo uma retornou como necessidade de manutenção pela PdM. Gráfico de Gantt máquina x tarefa



tarefa, neste, é possível visualizar que são 3 máquinas do modelo 3 e uma máquina do modelo 4, devido o período da tarefa.

Outra avaliação realizada foi a simulação da leitura de vinte e quatro ciclos de telemetria para validar como seria o comportamento da ideia do *feedback* contínuo. Como o conjunto de dados possui dados de um ano e um mês, este último mês foi utilizado para realizar inserções de telemetria. Foram testadas situações sem características de degradação e outras com degradação, que ao repetir o processo da PdM solicitou a modificação da sugestão do escalonamento devido a predição antecipação da necessidade da manutenção. Este é um ponto muito importante para a tomada de decisão, sendo que o apontamento da necessidade de alteração do planejamento com antecedência é benéfico a nível de negócio para a indústria e funcionamento dos setores envolvidos.

Conforme realizado para a PdM, foi criada a Tabela 14 que destaca trabalhos relacionados que mostram a preocupação com a tomada de decisão e a integração da I4.0. No entanto, as soluções sempre possuem características específicas relacionadas a um estudo de caso ou otimização no processo de escalonamento. A solução proposta neste trabalho gerou discussões e preocupação com a ideia de uma aplicação genérica voltada para a antecipação da decisão. Para isso, foram utilizadas hipóteses de trabalhos que não enfocam a integração, mas sim, a predição por meio de aprendizado de máquina.

## 6.6 Considerações finais

Ao finalizar este capítulo foram apresentados os resultados esperados integrando a PdM com o escalonamento criando o PdMS. A predição permitiu retirar a máquina do agendamento

Figura 43 – Resultado do escalonamento para a semana 6 do ano de 5 máquinas sendo uma retornou como necessidade de manutenção pela PdM. Gráfico de Gantt tarefa x máquina




Tabela 14 – Comparação dos diferenciais deste trabalho com as abordagens de integração dos trabalhos relacionados

	Tipo de manutenção	Escalonamento Abordagem do problema	Resultados e foco principal
PdMS	Preditiva	OR-Tools	Apresentar um modelo de integração PdM e agendamento no mesmo processo usando modelos DNN e RNN
(SCHMIDT, 2000)	-	Otimização polinomial Algoritmos de aproximação	Escalonamento com limite de disponibilidade
(LEVRAT; THOMAS; IUNG, 2008)	Manutenção oportunistas	-	Algoritmo de probabilidades baseado em teoria de parada ideal
(VARNIER; ZERHOUNI, 2012)	Preditiva com o RUL já estimado	Guruby <i>library</i>	Modelo <i>flow-shop</i> considerando otimizar dois critérios: tarefas de produção e manutenção antes do RUL identificar degradação
(SARKER et al., 2013)	Preventiva ou por quebra	Algoritmos evolucionário híbrido	Algoritmo para otimizar o problema de escalonamento
(FITOURI et al., 2016)	Preditiva com o RUL já estimado	Heurística Job-Shop	Tomada de decisão com job-shop abordagem com restrição do PdM
(KAO et al., 2018)	Preventiva criando o <i>Equipment Health Index (EHI)</i>	Programação linear inteira	Apresenta dois modelos: um estatístico assumindo EHI constante e outro dinâmico baseado na degradação
(LI; WANG; LIN, 2021)	Manutenção oportunistas	<i>Ant Colony</i> Otimização	Proposta de escalonamento reverso, otimização da manutenção baseada nos espaços encontrados na produção
(PATER, 2021)	Preditivo e baseado em condição	Escalonamento para substituição de componentes	Usa o prognóstico do RUL para agendar a substituição dos componentes da frota de aeronaves
(MI et al., 2021)	Preditivo	-	Proposta de framework para tomada de decisão integrada para orientar o PdM com maior precisão
(ZHAI; KANDEMIR; REINHART, 2021)	Módulo PHM específico de operação preditiva	<i>Flexible job shop</i>	Proposta de um framework para programação de produção integrada de manutenção preditiva (PdM-IPS) usando um algoritmo genético de dois estágios aplicado ao monitoramento de condição simulada

da produção e reconfigurar as tarefas inserindo a máquina no agendamento da manutenção. Todo o processo foi baseado em simulação e nos desafios resultantes da revisão sistemática (ZONTA et al., 2020). A busca por um conjunto de dados diferenciado e sem publicações na literatura trouxe a necessidade de se utilizar hipóteses e avaliação incremental, mas conforme já mencionado limitou as comparações com critérios de avaliação encontrados nos trabalhos relacionados.

Os estudos realizados contribuíram na identificação, de que, a simples aplicação de abordagens de ML em dados ruidosos podem não apresentar resultados aplicáveis. Isso reforça algo que foi apontado na revisão referente a importância do conhecimento físico na aplicação da predição baseada em dados (*data-driven*). A aplicação da PdM tem que ser uma análise multidisciplinar e com o aumento das pesquisas vem-se percebendo a inserção da Computação como primordial.

No caso do problema do escalonamento o que chamou atenção foi os esforços da Google Developers (2020) na resolução de problemas classificados de alta complexidade NP, que podem ser aplicados em processos industriais. O *OR-Tools* contribuiu para o processo de integração proposto exigindo o seu entendimento e parametrização. Os resultados da integração especificamente no escalonamento não tiveram critérios de avaliação devido sua complexidade, isso pode ser citado com uma limitação, porque o objetivo foi comprovar a possibilidade da aplicação integrada focando na predição antecipada da falha e que fosse possível gerar os cronogramas da produção corretamente. A avaliação do escalonamento seguiu as regras do algoritmo, mas não foi avaliado o desempenho e verificado em detalhes se teria a possibilidade de melhoria. De qualquer forma, a proposta do PdMS apresentou resultados diferenciados dos trabalhos relacionados porque apresentou um modelo integrado completo. A proposta deste trabalho se preocupou em entender e integrar dois desafios complexos e deixa o desafio da aplicação em ambiente real de produção.

A abordagem apresentada segue uma lacuna científico-prática relevante. Como já mencionado, nos trabalhos relacionados à integração e otimização de processos usando PdM é um potencial tanto em abordagem quanto em situações de aplicação (ZHAI; KANDEMIR; REINHART, 2021; MI et al., 2021). Neste trabalho, a preocupação foi entender a possibilidade de uma indústria com aquisição de dados iniciar o processo de predição permitindo melhorar o plano de produção. É por isso que nos concentramos em obter resultados de dados que não apresentam relevância de degradação usando *Deep Learning*.



## 7 CONCLUSÃO

Este trabalho apresentou o modelo PdMS, uma abordagem para integração das agendas de manutenção e produção. O estudo buscou, inicialmente, mostrar a situação da aplicação da PdM na I4.0 com a realização de uma revisão sistemática. A partir desta, foram buscadas contribuições científicas guiadas pela questão principal e cinco subquestões, abrangendo: a identificação de padrões; principais meios de publicação; aplicações, e os termos mais comuns sobre PdM e I4.0. Como principal contribuição, foi criada uma taxonomia da PdM no contexto da I4.0. A taxonomia apresentou os tipos de aplicação, princípios, seguindo modelos de aplicação, métodos, enfoque e delimitação de objetivos. A limitação da pesquisa esteve relacionada à visão da manutenção como um simples monitoramento, sem a ideia principal de prever a possibilidade de falhas com base no tempo (*time-based*). Os conteúdos vinculados ao prognóstico de falhas também podem ser considerados uma limitação por serem dominantes nos estudos de engenharia e incomuns na computação.

Com o foco na PdM, foram identificadas e discutidas sete direções futuras, desafios que podem ser utilizados por empresas e pesquisadores. Ficou claro, também, a interdisciplinaridade envolvida nos novos desafios da I4.0 e a necessidade de integração entre os processos. Já em relação aos dados e à realização dos testes, foi levantada a necessidade de responder algumas questões: "Como permitir a falha de um ativo para verificar o ponto de manutenção correto?" e "Como simular os diferentes cenários de uma I4.0?"

Utilizando-se deste estudo, o objetivo para este trabalho foi proporcionar maior agilidade e diminuição do *downtime* no processo produtivo, através da identificação de falhas utilizando dados de sensores e catalogação dos apontamentos dos manuais dos ativos aliado aos conhecimentos prévios dos engenheiros. A partir dos resultados da predição da falha, foi realizada a integração com o problema de escalonamento, determinando quais máquinas podem fazer parte do processo produtivo. Desta forma, foram traçados dois desafios científicos: um para a PdM e outro para o problema do escalonamento e sua integração.

Relacionado à PdM, o que chamou atenção durante o período da realização deste trabalho foi o crescimento de resultados aplicados que apresentam predição baseado no tempo. Durante a realização da revisão, no final de 2018 início de 2019, eram poucos os trabalhos que apresentavam resultados com antecedência de tempo. Para tanto, foi destacado o trabalho de Amihai et al. (2018) que fez predições em períodos de 7 dias. Grande parte dos trabalhos traziam uma proposta denominada por este autor como "Alerta Autônomo de Monitoramento de Falha", que é a ideia da criação de um limite para falha (*threshold*) baseado nos apontamentos dos manuais e conhecimento dos engenheiros.

Com a busca para atender as hipóteses do primeiro modelo apresentado, outros trabalhos com resultados expressivos foram encontrados (BRUNEO; De Vita, 2019; MODE; CALYAM; HOQUE, 2019; JIMENEZ-CORTADI et al., 2020; XIA et al., 2020). Estes trabalhos já trazem esforços baseados na similaridade de dados e a possibilidade de modificação dos limites de

falha com o tempo de aquisição dos dados. O estudo destas soluções motivou o incremento no modelo e ajudou na descrição detalhada de uma metodologia que pode ser aplicada em outras situações.

O modelo e a metodologia propostos resultaram numa predição de até cinco dias para falha, em uma base de dados sem informações de operação e com dados ruidosos. Com os resultados alcançados na PdM, foi possível atender a proposta de modificação do escalonamento a tempo de replanejar a produção e prevenir o *downtime*. Essa possibilidade de integração pode melhorar a relação entre dois setores essenciais da indústria. As manutenções corretivas geram atritos e situações inesperadas, e manutenções preventivas podem ser realizadas antes da necessidade. Ambas aumentam os custos de produção.

A utilização de dados heterogêneos com mais de uma falha por máquina também pode ser considerado um resultado importante, fato que trouxe diferenças no cálculo dos índices de degradação. O estudo se concentrou na ideia de que, usar dados de sensores sem outros tratamentos e esperar resultados satisfatórios, é uma prática errônea. É importante identificar e explicar para as indústrias que o simples fato de realizar a telemetria não permite a afirmação de previsões inteligentes e assertivas.

Mesmo com os pontos positivos citados, o trabalho teve limitações - como já mencionado - em relação à disponibilidade de dados para simulação. Com isso, fica o desafio de aplicar o PdMS em situação real, sendo que o cenário criado foi baseado em estudos e exemplos de utilização, trazendo o diferencial de integração e comunicação entre dois setores, oferecendo um resultado visual para acompanhamento. Na aplicação nas indústrias, uma das medidas que poderá ser verificada é a confiabilidade do processo e a otimização de tempo de reagendamento, objetivo principal de problemas de otimização e combinatória, como por exemplo, o escalonamento.

Em resumo, o PdMS apresentou a integração prevista. Foram criadas informações baseadas nos dados de telemetria, índices de degradação e a combinação com abordagens da literatura. Os resultados exibidos de forma visual e gráfica são importantes para sugerir a possibilidade de alterações das duas agendas gerando resultados diferenciados que podem ser aplicados. Por fim, algo a ser destacado, foi a preocupação em criar um processo que pudesse ter conteúdo tanto científico como aplicado, informações e conteúdos que permitam a continuidade do trabalho e que possam ser apresentados para a indústria como alternativa para problemas comumente encontrados.

## 7.1 Publicações

Como contribuições parciais ao longo da pesquisa, foram produzidos artigos para publicação em periódicos, listados a seguir:

- Artigos publicados:

- ZONTA, Tiago, da Costa, C. A., da Rosa Righi, R.,LIMA, M. J,Silveira, E., GP Li. (2020). **Predictive maintenance in the Industry 4.0: A systematic literature review.** Computers & Industrial Engineering, p. 1–17, oct 2020. doi:10.1016/j.cie.2020.106889
- ZONTA, Tiago, da Costa, C. A., da Rosa Righi, R.,Zeiser, F. A.,Ramos, G. O.,Kunst, R. (2021). **A Predictive Maintenance model for Optimizing Production Schedule using Deep Neural Networks.** Journal of Manufacturing Systems, p. 450–462, jan 2022. doi:10.1016/J.JMSY.2021.12.013.
- Artigos em avaliação:
  - ZONTA, Tiago, da Costa, C. A., da Rosa Righi, R.,Zeiser, F. A.,Ramos, G. O.,Kunst, R. (2022). **Combining Degradation Index and Deep Neural Networks for Predictive Maintenance in the Industry 4.0.** Journal of Computing and Information Science in Engineering, Computers & Industrial Engineering, p. 1–13.

## 7.2 Trabalhos Futuros

Os trabalhos futuros podem ser divididos em dois grupos: um, ligado à necessidade e visão da aplicação e gestão de processos industriais, e, outro, ligado à melhoria do modelo proposto, levando em consideração as possibilidades científicas.

Ao atender os objetivos, motivou-se a aplicação da integração em mais processos relacionados à manutenção, como: produção, armazenamento, expedição e logística. De acordo com a frase inicial deste trabalho, a I4.0 motiva a ideia de aplicações inteligentes e aumenta a necessidade de comunicação e integração entre os processos. Este é um dos principais conceitos da chamada "Revolução Tecnológica": permitir maior volume de dados, comunicação, inteligência e agilidade na indústria.

De qualquer forma, este trabalho traz o desafio da aplicação do PdMS utilizando a coleta de dados direto das máquinas, em uma situação real na indústria. Desta forma, é possível analisar o tempo de inatividade e a melhoria da comunicação entre os setores de manutenção e produção, dando continuidade à proposta de integração com novos setores. Para a aplicação futura, contatos com indústrias já estão sendo realizados.

Com relação aos resultados, o trabalho apresentou uma evolução durante os experimentos em que foram adicionadas novas hipóteses, como os filtros de suavização, e isso pode se repetir com dados em tempo real. As arquiteturas utilizadas nos modelos DNN e RNN podem ser adequadas e testadas com novos hiperparâmetros, juntamente com novas estratégias de pré-processamento, normalização e *Loss Function*, melhorando, ainda mais, as taxas de acerto no tempo avaliando períodos distintos. Além disso, pode ser melhorada a avaliação estatística dos resultados. Já em relação aos problemas de otimização e combinatória, o uso do *OR-Tools* pode ser estendido para a proposta de outros setores. Em ambas as fases, foram utilizadas

ferramentas e bibliotecas com evolução constate e grupos de desenvolvedores importantes, o que sugere possibilidade de melhorias futuras.

## REFERÊNCIAS

- AMIHAI, Ido et al. An industrial case study using vibration data and machine learning to predict asset health. In: **2018 IEEE 20th Conference on Business Informatics (CBI)**. Vienna, Austria: IEEE, 2018. p. 178–185.
- ARDOLINO, Marco et al. The role of digital technologies for the service transformation of industrial companies. **International Journal of Production Research**, Taylor & Francis, v. 56, n. 6, p. 2116–2132, 3 2018.
- AYAD, Soheyb; TERRISSA, Labib Sadek; ZERHOUNI, Nouredine. An iot approach for a smart maintenance. In: **2018 International Conference on Advanced Systems and Electric Technologies, IC\_ASET 2018**. Hammamet, Tunisia: IEEE, 2018. p. 210–214.
- AZURE, Microsoft. **Azure AI guide for predictive maintenance solutions**. 2020. Disponível em: <<https://docs.microsoft.com/pt-br/azure/machine-learning/team-data-science-process/predictive-maintenance-playbook#solution-templates-for-predictive-maintenance>>.
- BRUNEO, Dario; De Vita, Fabrizio. On the use of lstm networks for predictive maintenance in smart industries. In: **Proceedings - 2019 IEEE International Conference on Smart Computing, SMARTCOMP 2019**. Washington, DC, USA: IEEE, 2019. p. 241–248.
- CAI, Haoshu et al. Similarity-based particle filter for remaining useful life prediction with enhanced performance. **Applied Soft Computing Journal**, Elsevier, v. 94, p. 106474, 2020.
- CARVALHO, Thyago P. et al. A systematic literature review of machine learning methods applied to predictive maintenance. **Computers and Industrial Engineering**, Elsevier, v. 137, p. 106024, 2019.
- CHEN, Yan; ZHU, Feibai; LEE, Jay. Data quality evaluation and improvement for prognostic modeling using visual assessment based data partitioning method. **Computers in Industry**, Elsevier, v. 64, n. 3, p. 214–225, 2013.
- CHO, Sangje et al. A hybrid machine learning approach for predictive maintenance in smart factories of the future. In: **APMS 2018: Advances in Production Management Systems. Smart Manufacturing for Industry 4.0**. Seoul, Korea (Republic of): Springer, 2018. p. 311–317.
- \_\_\_\_\_. Industrial iot devices and cyber-physical production systems: Review and use case. In: **HELIX 2018: Innovation, Engineering and Entrepreneurship**. Guimarães, Portugal: Springer, 2018. v. 505, p. 292–298.
- CIPOLLINI, Francesca et al. Condition-based maintenance of naval propulsion systems: Data analysis with minimal feedback. **Reliability Engineering and System Safety**, Elsevier, v. 177, p. 12–23, 2018.
- CUI, Weiwei et al. A proactive approach to solve integrated production scheduling and maintenance planning problem in flow shops. **Computers and Industrial Engineering**, Elsevier, v. 115, p. 342–353, 2018.
- CUI, Zhicheng; CHEN, Wenlin; CHEN, Yixin. Multi-scale convolutional neural networks for time series classification. **arXiv:1603.06995**, Cornell University, p. 10, 2016.

DATASETS, PCoE. **Prognostics Center of Excellence**. 2018. 1–25 p. Disponível em: <<https://ti.arc.nasa.gov/tech/dash/groups/pcoe/prognostic-data-repository/#turbofan>>.

DEUTSCH, Jason; HE, David. Using deep learning-based approach to predict remaining useful life of rotating components. **IEEE Transactions on Systems, Man, and Cybernetics: Systems**, IEEE, v. 48, n. 1, p. 11–20, 1 2018.

DEVELOPERS, Google. **Scheduling OR-Tools Google Developers**. 2020. Disponível em: <<https://developers.google.com/optimization/scheduling>>.

DONG, Dong; LI, Xiao Yang; SUN, Fu Qiang. Life prediction of jet engines based on lstm-recurrent neural networks. **2017 Prognostics and System Health Management Conference, PHM-Harbin 2017 - Proceedings**, IEEE, 2017.

DUDEK, Grzegorz. Pattern similarity-based methods for short-term load forecasting - part 1: Principles. **Applied Soft Computing Journal**, Elsevier, v. 37, p. 277–287, 2015.

ECK, Ludo Waltman Nees Jan van. **Manual - VOSviewer visualizing scientific landscapes**. 2016.

FALCÃO, António Jorge Teixeira. **Detecção de correlação e causalidade em séries temporais não categóricas**. 83 p. Tese (Doutorado) — Universidade Nova de Lisboa Faculdade de Ciências e Tecnologia, 2012. Disponível em: <<http://run.unl.pt/handle/10362/7814>>.

FITOURI, C. et al. A decision-making approach for job shop scheduling with job depending degradation and predictive maintenance. **IFAC-PapersOnLine**, Elsevier, v. 49, n. 12, p. 1490–1495, 2016.

FRANK, Alejandro Germán; DALENOGARE, Lucas Santos; AYALA, Néstor Fabián. Industry 4.0 technologies: Implementation patterns in manufacturing companies. **International Journal of Production Economics**, Elsevier, v. 210, p. 15–26, 2019.

GEISBAUER, Reinhard; VEDSO, Jesper; SCHRAUF, Stefan. **Industry 4.0: Building the digital enterprise**. Global, 2016. 1–36 p. Disponível em: <[www.pwc.com/industry40](http://www.pwc.com/industry40)>.

GUNES, Volkan et al. A survey on concepts, applications, and challenges in cyber-physical systems. **KSII Transactions on Internet and Information Systems**, Citeseerx, v. 8, n. 12, p. 4242–4268, 2014.

HAARMAN, Mark; MULDER, Michel; VASSILIADIS, Costas. **Predictive Maintenance 4.0: Predict the unpredictable**. Netherlands, Germany and Belgium, 2017. 31 p. Disponível em: <<https://www.pwc.nl/nl/assets/documents/pwc-predictive-maintenance-4-0.pdf>>.

HATAMI, Sara. **The Distributed and Assembly Scheduling Problem**. 215 p. Tese (Doutorado) — Universitat Politècnica de Valencia, 2016.

HE, Miao; HE, David. Deep learning based approach for bearing fault diagnosis. **IEEE Transactions on Industry Applications**, IEEE, v. 53, n. 3, p. 3057–3065, 2017.

HE, Yuan; GUO, Junchen; ZHENG, Xiaolong. From surveillance to digital twin: Challenges and recent advances of signal processing for industrial internet of things. **IEEE Signal Processing Magazine**, IEEE, v. 35, n. 5, p. 120–129, 2018.

HEIMES, Felix O. Recurrent neural networks for remaining useful life estimation. In: **2008 International Conference on Prognostics and Health Management, PHM 2008**. Denver, CO, USA: IEEE, 2008. p. 1–6.

JANTUNEN, Erkki et al. Optimising maintenance: What are the expectations for cyber physical systems. In: **2016 3rd International Workshop on Emerging Ideas and Trends in Engineering of Cyber-Physical Systems, EITEC 2016**. Vienna, Austria: IEE, 2016. p. 53–58.

JAYASINGHE, Lahiru et al. Temporal convolutional memory networks for remaining useful life estimation of industrial machinery. **Proceedings of the IEEE International Conference on Industrial Technology**, IEEE, v. 2019-Febru, p. 915–920, 2019.

JIMENEZ-CORTADI, Alberto et al. Predictive maintenance on the machining process and machine tool. **Applied Sciences (Switzerland)**, mdpi, v. 10, p. 224, 2020.

JIN, Wenjing et al. Cps-enabled worry-free industrial applications. In: **2017 Prognostics and System Health Management Conference, PHM-Harbin 2017 - Proceedings**. Harbin, China: IEEE, 2017. p. 1–7.

KAO, Yu Ting et al. Impact of integrating equipment health in production scheduling for semiconductor fabrication. **Computers and Industrial Engineering**, Elsevier, v. 120, p. 450–459, 2018.

KAUR, Karamjit et al. Towards an open-standards based framework for achieving condition-based predictive maintenance. In: **Proceedings of the 8th International Conference on the Internet of Things**. New York, USA: ACM, 2018. p. 16:1–16:8.

KERAS. **Keras: the Python deep learning API**. 2020. Disponível em: <<https://keras.io/>>.

KIANGALA, Kahiomba Sonia; WANG, Zenghui. Initiating predictive maintenance for a conveyor motor in a bottling plant using industry 4.0 concepts. **International Journal of Advanced Manufacturing Technology**, Springer, v. 97, n. 9-12, p. 3251–3271, 2018.

KLAVANS, Richard; BOYACK, Kevin W. Which type of citation analysis generates the most accurate taxonomy of scientific and technical knowledge? **Journal of the Association for Information Science and Technology**, asis&t, v. 68, n. 4, p. 984–998, apr 2017.

KU, Jin Hee. A study on prediction model of equipment failure through analysis of big data based on rhadoop. **Wireless Personal Communications**, Springer, v. 98, n. 4, p. 3163–3176, 2018.

KWON, Daeil et al. Iot-based prognostics and systems health management for industrial applications. **IEEE Access**, IEEE, v. 4, p. 3659–3670, 2016.

LADJ, Asma; Benbouzid-Si Tayeb, Fatima; VARNIER, Christophe. An integrated prognostic based hybrid genetic-immune algorithm for scheduling jobs and predictive maintenance. In: **2016 IEEE Congress on Evolutionary Computation, CEC 2016**. Vancouver, BC, Canada: IEEE, 2016. p. 2083–2089.

LAMONACA, F et al. Internet of things for structural health monitoring. In: **2018 Workshop on Metrology for Industry 4.0 and IoT**. Brescia, Italy: IEEE, 2018. p. 95–100.

LEE, Hyunsoo. Framework and development of fault detection classification using iot device and cloud environment. **Journal of Manufacturing Systems**, Elsevier, v. 43, p. 257–270, 2017.

LEE, Jay; ABUALI, Mohamed. Innovative product advanced service systems (i-pass): Methodology, tools, and applications for dominant service design. **International Journal of Advanced Manufacturing Technology**, Springer-Verlag, v. 52, n. 9-12, p. 1161–1173, 2011.

LEE, Jay et al. Industrial big data analytics and cyber- physical systems for future maintenance & service innovation. **Procedia CIRP**, Elsevier, v. 38, n. July, p. 3–7, 2015.

LEE, Jay; AZAMFAR, Moslem; SINGH, Jaskaran. A blockchain enabled cyber-physical system architecture for industry 4.0 manufacturing systems. **Manufacturing Letters**, Elsevier, v. 20, p. 34–39, 2019.

LEE, Jay; BAGHERI, Behrad; KAO, Hung-An. Recent advances and trends of cyber-physical systems and big data analytics in industrial informatics. In: **12th IEEE International Conference on Industrial Informatics (INDIN)**. Porto Alegre, Brazil: IEEE, 2014. p. 1–6.

LEE, J.; JIN, C.; BAGHERI, B. Cyber physical systems for predictive production systems. **Production Engineering**, Springer, v. 11, n. 2, p. 155–165, 2017.

LEE, Jay et al. Recent advances and trends in predictive manufacturing systems in big data environment. **Manufacturing Letters**, Elsevier, v. 1, n. 1, p. 38–41, oct 2013.

\_\_\_\_\_. Intelligent prognostics tools and e-maintenance. **Computers in Industry**, Elsevier, v. 57, n. 6, p. 476–489, aug 2006.

LEVRAT, E.; THOMAS, E.; IUNG, B. Odds-based decision-making tool for opportunistic production-maintenance synchronization. **International Journal of Production Research**, Taylor & Francis Group, v. 46, n. 19, p. 5263–5287, 2008.

LI, Defang. Perspective for smart factory in petrochemical industry. **Computers and Chemical Engineering**, Elsevier, v. 91, p. 136–148, 2016.

LI, Li; WANG, Yong; LIN, Kuo Yi. Preventive maintenance scheduling optimization based on opportunistic production-maintenance synchronization. **Journal of Intelligent Manufacturing**, Elsevier, v. 32, n. 2, p. 545–558, feb 2021.

LIANG, Zeming et al. A degradation degree considered method for remaining useful life prediction based on similarity. **Computing in Science and Engineering**, IEEE, v. 21, n. 1, p. 50–64, jan 2019.

LIM, Pin et al. Estimation of remaining useful life based on switching kalman filter neural network ensemble. In: **PHM 2014 - Proceedings of the Annual Conference of the Prognostics and Health Management Society 2014**. Fort Worth, TX, USA: phmsociety, 2014. p. 2–9.

LIU, J. et al. Dynamic deep learning algorithm based on incremental compensation for fault diagnosis model. **International Journal of Computational Intelligence Systems**, Atlantis Press, v. 11, n. 1, p. 846–860, 2018.

LIU, Jianbo et al. Similarity based method for manufacturing process performance prediction and diagnosis. **Computers in Industry**, v. 58, p. 558–566, 2007.



MA, Ying; CHU, Chengbin; ZUO, Chunrong. A survey of scheduling with deterministic machine availability constraints. **Computers and Industrial Engineering**, Elsevier, v. 58, n. 2, p. 199–211, mar 2010.

MAN, Jianing; ZHOU, Qiang. Prediction of hard failures with stochastic degradation signals using wiener process and proportional hazards model. **Computers and Industrial Engineering**, Elsevier, v. 125, p. 480–489, 2018.

MATHWORKS. **Three Ways to Estimate Remaining Useful Life Predictive Maintenance with MATLAB**. USA, 2018. 9 p. Disponível em: <<https://www.mathworks.com/content/dam/mathworks/ebook/estimating-remaining-useful-life-ebook.pdf>>.

MATYAS, Kurt et al. A procedural approach for realizing prescriptive maintenance planning in manufacturing industries. **CIRP Annals - Manufacturing Technology**, Elsevier, v. 66, n. 1, p. 461–464, 2017.

MI, Shanghua et al. Prediction maintenance integrated decision-making approach supported by digital twin-driven cooperative awareness and interconnection framework. **Journal of Manufacturing Systems**, Elsevier, v. 58, p. 329–345, jan 2021.

MIRSHEKARIAN, Sadegh; ŠORMAZ, Dušan N. Correlation of job-shop scheduling problem features with scheduling efficiency. **Expert Systems with Applications**, IEEE, v. 62, p. 131–147, nov 2016.

MODE, Gautam Raj; CALYAM, Prasad; HOQUE, Khaza Anuarul. False data injection attacks in internet of things and deep learning enabled predictive analytics. In: **IEEE NOMS 2020 conference**. Budapest, Hungary: IEEE, 2019. p. 11.

MOURTZIS, Dimitris; ANGELOPOULOS, John; PANOPOULOS, Nikos. Intelligent Predictive Maintenance and Remote Monitoring Framework for Industrial Equipment Based on Mixed Reality. **Frontiers in Mechanical Engineering**, Frontiers, v. 6, p. 99, dec 2020.

MOURTZIS, Dimitris; ANGELOPOULOS, John; ZOGOPOULOS, Vasilios. Integrated and adaptive ar maintenance and shop-floor rescheduling. **Computers in Industry**, Elsevier, v. 125, p. 103383, feb 2021.

MUHURI, Pranab K; SHUKLA, Amit K; ABRAHAM, Ajith. Industry 4.0: A bibliometric analysis and detailed overview. **Engineering Applications of Artificial Intelligence**, Elsevier, v. 78, p. 218–235, feb 2019.

MULRENNAN, Konrad et al. A soft sensor for prediction of mechanical properties of extruded pla sheet using an instrumented slit die and machine learning algorithms. **Polymer Testing**, Elsevier, v. 69, p. 462–469, 8 2018.

NEMETH, Tanja et al. Prima-x: A reference model for realizing prescriptive maintenance and assessing its maturity enhanced by machine learning. **Procedia CIRP**, Elsevier, v. 72, p. 1039–1044, 2018.

NIKOLAKIS, Nikolaos et al. On a versatile scheduling concept of maintenance activities for increased availability of production resources. **Procedia CIRP**, Elsevier, v. 78, p. 172–177, 2018.

O'DONOVAN, Peter et al. Big data in manufacturing: a systematic mapping study. **Journal of Big Data**, Springer, v. 2, n. 1, p. 20, dec 2015.

PATER, Mihaela Mitici Ingeborg de. Predictive maintenance for multi-component systems of repairables with remaining-useful-life prognostics and a limited stock of spare components. **Reliability Engineering and System Safety**, Elsevier, v. 214, p. 107761, oct 2021.

PINEDO, Michael L. **Scheduling: Theory, Algorithms, and Systems**. Cham: Springer International Publishing, 2016. 670 p.

PYKALMAN. **Pykalman — Pykalman 0.9.2 Documentation**. 2019. Disponível em: <<https://pykalman.github.io/>>.

QIN, Jian; LIU, Ying; GROSVENOR, Roger. Data analytics for energy consumption of digital manufacturing systems using internet of things method. In: **IEEE International Conference on Automation Science and Engineering**. Xi'an, China: IEEE, 2018. v. 2017-Augus, p. 482–487.

REN, Lei et al. Bearing remaining useful life prediction based on deep autoencoder and deep neural networks. **Journal of Manufacturing Systems**, Elsevier, v. 48, p. 71–77, 2018.

RODRÍGUEZ-MAZAHUA, Lisbeth et al. A general perspective of big data: applications, tools, challenges and trends. **Journal of Supercomputing**, Springer, v. 72, n. 8, p. 3073–3113, 8 2016.

ROY, R. et al. Continuous maintenance and the future – foundations and technological challenges. **CIRP Annals - Manufacturing Technology**, Elsevier, v. 65, n. 2, p. 667–688, 2016.

SAEZ, M et al. Anomaly detection and productivity analysis for cyber-physical systems in manufacturing. In: **IEEE International Conference on Automation Science and Engineering**. Xi'an, China: IEEE, 2018. v. 2017-Augus, p. 23–29.

SARKER, Ruhul et al. Hybrid evolutionary algorithm for job scheduling under machine maintenance. **Applied Soft Computing Journal**, Elsevier, v. 13, n. 3, p. 1440–1447, 2013.

SCHMIDT, Bernard; WANG, Lihui; GALAR, Diego. Semantic framework for predictive maintenance in a cloud environment. **Procedia CIRP**, Elsevier, v. 62, p. 583–588, 2017.

SCHMIDT, Günter. Scheduling with limited machine availability. **European Journal of Operational Research**, Elsevier, v. 121, n. 1, p. 1–15, 2000.

SCIKIT-LEARN. **Metrics and scoring: quantifying the quality of predictions**. 2007. Disponível em: <[https://scikit-learn.org/stable/modules/model\\_evaluation.html#accuracy-score](https://scikit-learn.org/stable/modules/model_evaluation.html#accuracy-score)>.

SCIPY. **scipy.signal.savgol\_filter — SciPy v1.7.1 Manual**. 2021. Disponível em: <[https://docs.scipy.org/doc/scipy/reference/generated/scipy.signal.savgol\\_filter.html](https://docs.scipy.org/doc/scipy/reference/generated/scipy.signal.savgol_filter.html)>.

SEZER, Erim et al. An industry 4.0-enabled low cost predictive maintenance approach for smes. In: **2018 IEEE International Conference on Engineering, Technology and Innovation, ICE/ITMC 2018 - Proceedings**. Stuttgart, Germany: IEEE, 2018. p. 1–8.

SILVA, Ademir F. Aderair F et al. A cloud-based architecture for the internet of things targeting industrial devices remote monitoring and control. **IFAC-PapersOnLine**, Elsevier, v. 49, n. 30, p. 108–113, 2016.

SOCIETY, PHM. **PHM Society - The Prognostics and Health Management Society (PHM Society) is a non-profit organization dedicated to the advancement of PHM as an engineering discipline**. 2018. Disponível em: <<https://phmsociety.org/>>.

SPENDLA, Lukas et al. Concept of predictive maintenance of production systems in accordance with industry 4.0. In: **SAMI 2017 - IEEE 15th International Symposium on Applied Machine Intelligence and Informatics, Proceedings**. Herl'any, Slovakia: IEEE, 2017. p. 405–410.

STATSMODELS. **statsmodels**. 2010. Disponível em: <<https://www.statsmodels.org/stable/gettingstarted.html>>.

TERRISSA, Labib Sadek et al. A new approach of phm as a service in cloud computing. In: **2016 4th IEEE International Colloquium on Information Science and Technology (CiSt)**. Tangier, Morocco: IEEE, 2016. p. 610–614.

VARNIER, Christophe; ZERHOUNI, Nouredine. Scheduling predictive maintenance in flow-shop. In: **Proceedings of IEEE 2012 Prognostics and System Health Management Conference, PHM-2012**. Beijing, China: IEEE, 2012. p. 1–6.

VEEN, Fjodor Van. **Neural Network Zoo Prequel: Cells and Layers**. 2017. Disponível em: <<http://www.asimovinstitute.org/neural-network-zoo-prequel-cells-layers/>>.

WANG, Jianwu et al. Sensor data based system-level anomaly prediction for smart manufacturing. In: **2018 IEEE International Congress on Big Data (BigData Congress)**. San Francisco, CA, USA: IEEE, 2018. p. 158–165.

WANG, Tianyi et al. A similarity-based prognostics approach for remaining useful life estimation of engineered systems. In: **2008 International Conference on Prognostics and Health Management, PHM 2008**. Denver, CO, USA: IEEE, 2008. p. 1–6.

WANG, Xianpeng; TANG, Lixin. A machine-learning based memetic algorithm for the multi-objective permutation flowshop scheduling problem. **Computers and operations research**, Elsevier, v. 79, p. 60–77, 2017.

WU, Dazhong et al. Cloud-based machine learning for predictive analytics: Tool wear prediction in milling. In: **Proceedings - 2016 IEEE International Conference on Big Data, Big Data 2016**. NEW YORK, USA: IEEE, 2016. p. 2062–2069.

\_\_\_\_\_. Cloud-based parallel machine learning for prognostics and health management: A tool wear prediction case study. **Journal of Manufacturing Science and Engineering**, ASME, v. 140, n. 4, 2017.

\_\_\_\_\_. A comparative study on machine learning algorithms for smart manufacturing: Tool wear prediction using random forests. **Journal of Manufacturing Science and Engineering**, Elsevier, v. 139, n. 7, p. 071018, 4 2017.

\_\_\_\_\_. Data-driven prognostics using random forests: Prediction of tool wear. In: **Volume 3: Manufacturing Equipment and Systems**. NEW YORK, USA: ASME, 2017.

\_\_\_\_\_. A fog computing-based framework for process monitoring and prognosis in cyber-manufacturing. **Journal of Manufacturing Systems**, Elsevier, v. 43, p. 25–34, 2017.

XIA, Min et al. Intelligent fault diagnosis approach with unsupervised feature learning by stacked denoising autoencoder. **IET Science, Measurement & Technology**, IEEE, v. 11, n. 6, p. 687–695, 2017.

\_\_\_\_\_. Data-driven prognosis method using hybrid deep recurrent neural network. **Applied Soft Computing Journal**, Elsevier, v. 93, p. 106351, 2020.

YAN, Hehua et al. Industrial big data analytics for prediction of remaining useful life based on deep learning. **IEEE Access**, IEEE, v. 6, p. 17190–17197, 2018.

YAN, Jihong et al. Industrial big data in an industry 4.0 environment: Challenges, schemes, and applications for predictive maintenance. **IEEE Access**, IEEE, v. 5, p. 23484–23491, 2017.

YANG, Zhi Xin; ZHANG, Peng Bo. Elm meets rae-elm: A hybrid intelligent model for multiple fault diagnosis and remaining useful life predication of rotating machinery. In: **Proceedings of the International Joint Conference on Neural Networks**. Vancouver, Canada: IEEE, 2016. v. 2016-October, p. 2321–2328.

ZERHOUNI, Noureddine et al. Prognostics and health management for maintenance practitioners-review, implementation and tools evaluation. **Article in International Journal of Prognostics and Health Management**, phmsociety, v. 8, p. 31, 2017.

ZHAI, Simon; KANDEMIR, Meltem Göksu; REINHART, Gunther. Predictive maintenance integrated production scheduling by applying deep generative prognostics models: approach, formulation and solution. **Production Engineering**, Springer Science and Business Media Deutschland GmbH, p. 1–24, jul 2021.

ZHANG, Weiting; YANG, Dong; WANG, Hongchao. Data-driven methods for predictive maintenance of industrial equipment: A survey. **IEEE Systems Journal**, IEEE, v. 13, n. 3, p. 2213–2227, 2019.

ZHENG, Shuai et al. Long short-term memory network for remaining useful life estimation. In: **2017 IEEE International Conference on Prognostics and Health Management, ICPHM 2017**. Dallas, TX, USA: IEEE, 2017. p. 88–95.

ZONTA, Tiago et al. Predictive maintenance in the Industry 4.0: A systematic literature review. **Computers and Industrial Engineering**, Elsevier, v. 150, p. 1–17, oct 2020.

## APÊNDICE

### A Artigo selecionados na revisão sistemática

Tabela 15: Artigos selecionados ordenados por ano.

Artigo	Tipo	Editores	Nome
(LEE; BAGHERI; KAO, 2014)	Conference	IEEE	International Conference on Industrial Informatics (INDIN)
(GUNES et al., 2014)	Journal	Citeseerx	KSII Transactions on Internet and Information Systems
(SILVA et al., 2016)	Journal	Elsevier	IFAC-PapersOnLine
(TERRISSA et al., 2016)	Conference	IEEE	International Colloquium on Information Science and Technology (CiSt)
(LEE et al., 2015)	Journal	Elsevier	Procedia CIRP
(JANTUNEN et al., 2016)	Conference	IEEE	International Workshop on Emerging Ideas and Trends in Engineering of Cyber-Physical Systems, EITEC
(ROY et al., 2016)	Journal	Elsevier	CIRP Annals - Manufacturing Technology
(RODRÍGUEZ-MAZAHUA et al., 2016)	Journal	Springer	Journal of Supercomputing
(YANG; ZHANG, 2016)	Conference	IEEE	International Joint Conference on Neural Networks (IJCNN)
(KWON et al., 2016)	Journal	IEEE	Access
(WU et al., 2016)	Conference	IEEE	International Conference on Big Data (Big Data)
(LI, 2016)	Journal	Elsevier	Computers and Chemical Engineering
(HE; HE, 2017)	Journal	IEEE	Transactions on Industry Applications
(LEE; JIN; BAGHERI, 2017)	Journal	Springer	Production Engineering
(JIN et al., 2017)	Conference	IEEE	Prognostics and System Health Management Conference, PHM-Harbin
(SPENDLA et al., 2017)	Conference	IEEE	International Symposium on Applied Machine Intelligence and Informatics (SAMII)
(YAN et al., 2017)	Journal	IEEE	Access
(WU et al., 2017c)	Conference	ASME	Manufacturing Equipment and Systems
(WU et al., 2017a)	Journal	ASME	Journal of Manufacturing Science and Engineering
(WU et al., 2017b)	Journal	ASME	Journal of Manufacturing Science and Engineering
(WU et al., 2017d)	Journal	Elsevier	Journal of Manufacturing Systems
(LEE, 2017)	Journal	Elsevier	Journal of Manufacturing Systems
(XIA et al., 2017)	Journal	IEEE	IET Science, Measurement & Technology
(SCHMIDT; GALAR, 2017)	Conference	Elsevier	CIRP Conference on Intelligent Computation in Manufacturing Engineering

**continua na próxima página**

Tabela 15 – continuação da página anterior

<b>Artigo</b>	<b>Tipo</b>	<b>Editores</b>	<b>Nome</b>
(MATYAS et al., 2017)	Journal	Elsevier	CIRP Annals - Manufacturing Technology
(QIN; LIU; GROSVENOR, 2018)	Conference	IEEE	Conference on Automation Science and Engineering (CASE)
(DEUTSCH; HE, 2018)	Journal	IEEE	Transactions on Systems, Man, and Cybernetics: Systems
(KU, 2018)	Journal	Springer	Wireless Personal Communications
(AYAD; TERRISSA; ZERHOUNI, 2018)	Conference	IEEE	International Conference on Advanced Systems and Electric Technologies, IC_ASET
(MAN; ZHOU, 2018)	Journal	Elsevier	Computers & Industrial Engineering
(WANG et al., 2018)	Conference	IEEE	International Congress on Big Data (BigData Congress)
(MULRENNAN et al., 2018)	Journal	Elsevier	Polymer Testing
(SAEZ et al., 2018)	Conference	IEEE	Conference on Automation Science and Engineering (CASE)
(KAUR et al., 2018)	Conference	ACM	International Conference on the Internet of Things
(CHO et al., 2018a)	Conference	Springer	Advances in Production Management Systems. Smart Manufacturing for Industry 4.0
(CHO et al., 2018b)	Conference	Springer	HELIX - Innovation, Engineering and Entrepreneurship
(REN et al., 2018)	Journal	Elsevier	Journal of Manufacturing Systems
(SEZER et al., 2018)	Conference	IEEE	International Conference on Engineering, Technology and Innovation (ICE/ITMC)
(NEMETH et al., 2018)	Journal	Elsevier	Procedia CIRP
(YAN et al., 2018)	Journal	IEEE	Access
(CIPOLLINI et al., 2018)	Journal	Elsevier	Reliability Engineering & System Safety
(HE; GUO; ZHENG, 2018)	Journal	IEEE	Signal Processing Magazine
(LIU et al., 2018)	Journal	Atlantis-Press	International Journal of Computational Intelligence Systems
(AMIHAI et al., 2018)	Journal	IEEE	20th Conference on Business Informatics (CBI)
(KIANGALA; WANG, 2018)	Journal	Springer	International Journal of Advanced Manufacturing Technology
(LAMONACA et al., 2018)	Conference	IEEE	Workshop on Metrology for Industry 4.0 and IoT
(ARDOLINO et al., 2018)	Journal	Taylor & Francis	International Journal of Production Research

Fonte: O Autor

## B Modelos, métodos ou arquiteturas

Tabela 16: Modelos, métodos ou arquitetura.

Artigos	Nome ou descrição	Case	Variáveis
(LEE; BAGHERI; KAO, 2014)	Estrutura da aplicação de algoritmos PHM na detecção de problemas invisíveis na indústria usando a ferramenta Watchdog Agent®	Robô industrial e bateria virtual	Torque, velocidade e corrente de tensão, temperatura, velocidade GPS, peso EV
(GUNES et al., 2014)	Uma pesquisa sobre conceitos, aplicativos e desafios no CPS	-	-
(SILVA et al., 2016)	Arquitetura baseada em nuvem para monitoramento e controle de dispositivos	Sistema de exaustão	Vibração, temperatura, umidade
(TERRISSA et al., 2016)	PHM como um serviço na nuvem	Método genérico	Genérico
(HE; HE, 2017)	Deep learning método baseado para o diagnóstico de falhas em rolamentos	Rolamentos	AE
(LEE et al., 2015)	Estrutura da plataforma de análise de big data para PdM	Máquinas de serra de fita	Vibração, Temperatura, AE
(JANTUNEN et al., 2016)	Arquitetura genérica de processamento de dados em Mantis	Usinagem electro-química, Veículos <i>Off-road</i> e especiais, Produção de energia, Sistemas de imagens de saúde	Genérico
(ROY et al., 2016)	Manutenção contínua e o futuro	-	-
(RODRÍGUEZ-MAZAHUA et al., 2016)	Uma perspectiva geral aplicando dig data	-	-
(YANG; ZHANG, 2016)	Estrutura RAE-ELM para um conjunto de camadas do ELM	Carga elétrica, motor primário, caixa de velocidades, volante, gerador assíncrono	Vibração
(KWON et al., 2016)	<i>Physics of failure</i> (PoF) PHM, PHM baseado em IoT	-	-
(WU et al., 2016)	Aprendizado de máquina baseado em nuvem para análise preditiva	CNC vertical de alta velocidade de 3 eixos	Força de corte, vibração, AE
(LI, 2016)	Estrutura estratégica da fábrica inteligente na indústria petroquímica	-	-

Continua na próxima página

Tabela 16 – continuação da página anterior

Artigos	Nome ou descrição	Case	Variáveis
(LEE; JIN; BAGHERI, 2017)	5C Arquitetura do CPS, Estrutura dos sistemas de prognóstico de fuso de esferas CPS	Parafuso da esfera	Aceleração, temperatura, AE
(JIN et al., 2017)	Arquitetura 5C para futuro parque eólico inteligente com suporte a CPS	Turbinas eólicas	Desempenho da turbina, velocidade, potência
(LEE, 2017)	Fabricação de cabos e problemas de detecção de falhas da HID com arquitetura em nuvem	Cabo HID	Torque, proximidade
(SPENDLA et al., 2017)	Modelo de descoberta de conhecimento	Modelo Genérico	Genérico
(YAN et al., 2017)	Novo <i>framework</i> para estruturação de informações heterogêneas <i>multisource</i>	Centro de moagem vertical	Vibração do cortador, imagens por um scanner a laser 3D, sinal acústico, energia
(WU et al., 2017c)	Métodos baseados em dados para previsão de desgaste de ferramentas	CNC vertical de alta velocidade de 3 eixos	Força de corte, vibração, AE
(WU et al., 2017a)	Aprendizado de máquina paralela baseada em nuvem para previsão de desgaste de ferramentas, <i>MapReduce Programming Framework</i>	CNC vertical de alta velocidade de 3 eixos	Força de corte, vibração, AE
(WU et al., 2017b)	Estudo comparativo sobre algoritmos de aprendizado de máquina para manufatura inteligente	CNC vertical de alta velocidade de 3 eixos	Força de corte, vibração, AE
(WU et al., 2017d)	<i>Framework</i> para <i>cyber</i> sistema de fabricação de baseado em <i>fog computing</i>	Bombas e máquinas CNC	Força de corte, vibração, AE
(XIA et al., 2017)	<i>Autoencoder denoising</i> empilhado aprendizado de recursos baseado em SDA e diagnóstico de falhas	Rolamento	Vibração, AE
(SCHMIDT; WANG; GALAR, 2017)	Estrutura semântica para manutenção preditiva em um ambiente de nuvem	<i>Framework</i> genérico	Vibração
(MATYAS et al., 2017)	Abordagem procedural para o planejamento de manutenção prescritiva, abordagem para o cálculo do desgaste de um componente da máquina	Centros de usinagem triaxiais de um fabricante de automóveis	Protocolos de falha

Continua na próxima página



Tabela 16 – continuação da página anterior

Artigos	Nome ou descrição	Case	Variáveis
(QIN; LIU; GROSVENOR, 2018)	Estrutura de IoT de análise do consumo de energia	Consumo de energia de sistemas de manufatura digital	Temperatura, energia
(DEUTSCH; HE, 2018)	Abordagem Baseada em <i>Deep Learning</i>	Componentes rotativos	Indicadores de condição de vibração (CIs), massa de detritos de óleo (ODM)
(KU, 2018)	Plataforma de análise de big data baseada em RHadoop	Método genérico baseado em PLC	Temperatura, velocidade, distância
(AYAD; TERRISSA; ZERHOUNI, 2018)	Abordagem para Manutenção Inteligente IoT	Mpetodo Genérico	Genérico
(MAN; ZHOU, 2018)	Sinais de degradação estocástica usando o processo Wiener e o modelo de riscos proporcionais	Acionamento do motor automotivo	Resistências da bateria
(WANG et al., 2018)	Estrutura para previsão de anomalia baseada em dados de sensores em manufatura	Moinho de Carvão	Sensor de alimentação de carvão, eletricidade, vibração do rolamento
(MULRENNAN et al., 2018)	<i>Soft Sensor</i> para previsão de propriedades mecânicas de chapas de PLA extrudadas	Estresse da folha de PLA extrudado	Transdutor de pressão, termopar
(SAEZ et al., 2018)	Detecção de anomalias e análise de arodutividade para CPS	Esteiras de partida e parada, montadora automotiva	Velocidade, tensão atual, sensores de presença, botão de parada de emergência
(KAUR et al., 2018)	Arquitetura OIE para IIoT	Arquitetura genérica	Genérico
(CHO et al., 2018a)	Arquitetura piloto para o PdM	Fresadoras e máquinas CMM	Genérico
(CHO et al., 2018b)	Arquitetura de um CPS	Motores elétricos	Gravidade da vibração
(REN et al., 2018)	Modelo de predição RUL de <i>Deep autoencoder</i>	Rolamentos	Vibração
(SEZER et al., 2018)	Abordagem PdM de baixo custo	Centro de torneamento CNC	Girosópio, acelerômetro, magnetômetro, temperatura, pressão barométrica e umidade

Continua na próxima página

Tabela 16 – continuação da página anterior

Artigos	Nome ou descrição	Case	Variáveis
(NEMETH et al., 2018)	PriMa-X: Um modelo de referência para realizar manutenção prescritiva e avaliação de sua maturidade aprimorada pelo aprendizado de máquina	-	-
(YAN et al., 2018)	Eletrocardiograma do dispositivo	Centro de usinagem CNC	Não informado
(CIPOLLINI et al., 2018)	Manutenção baseada em condições de sistemas de propulsão naval	Planta de propulsão diesel-elétrica e a gás	Velocidade, torque, temperatura, pressão
(HE; GUO; ZHENG, 2018)	<i>Pavatar-Power Systems Digital Twin</i>	estação conversora de ultra-alta tensão (UHVCS)	Temperatura, umidade, ruído, qualidade do ar, vazamento de líquido
(LIU et al., 2018)	Algoritmo de Deep Learning dinâmico baseado em compensação incremental	Rolamento	Dez condições de vibração
(AMIHAI et al., 2018)	Estudo de caso baseado em monitoramento de vibração	Equipamento rotativo com alto desequilíbrio	Vibração
(KIANGALA; WANG, 2018)	Monitoramento de velocidade de vibração descentralizada através de ferramenta de relatórios baseada em nuvem	Motor transportador em uma fábrica de engarrafamento	Vibração
(LAMONACA et al., 2018)	IoT para monitoramento de integridade estrutural(SHM)	Estruturas de engenharia	Vibração, AE
(ARDOLINO et al., 2018)	Quadro de pesquisa - hierarquia de tecnologias digitais e dados-informação-conhecimento-sabedoria (DIKW)	-	-

Fonte: O Autor

## C Comparação com os trabalhos relacionados

Tabela 17: Comparação entre os trabalhos relacionados

Artigo	Ano	Aborda PdM	Aborda problema de escalonamento	Citações
(SCHMIDT, 2000)	2000	Não aborda	Sim e apresenta comparativos entre soluções	501
(LEVRAT; THOMAS; IUNG, 2008)	2008	Cita e considera que as paradas de manutenção já estão previstas baseadas no RUL	Sim e traz uma abordagem de manutenção oportunista	30
(MA; CHU; ZUO, 2010)	2010	Cita e fala sobre manutenção preventiva e considera como <i>constraint</i>	Sim e é o foco do Survey que cataloga pesquisas e suas soluções	329
(VARNIER; ZERHOUNI, 2012)	2012	Cita e utiliza informação do RUL em sua solução, mas não detalha como funciona o que chamou de sistemas de prognóstico	Sim, apresenta algoritmos e comparativos com a manutenção como <i>constraint</i>	16
(MIRSHEKARIAN; ŠORMAZ, 2016)	2016	Não aborda	Sim e traz importantes contribuições no uso de ML e critérios de avaliação das soluções	18
(FITOURI et al., 2016)	2016	Cita e utiliza o RUL como parâmetro de entrada, mas não detalha como obteve as informações relacionadas a manutenção	Sim, apresenta algoritmos e um fluxo que pode ser utilizado para o trabalho em questão	4
(LADJ; Benbouzid-Si Tayeb; VARNIER, 2016)	2016	Cita e já percebemos uma maturidade maior em falar sobre a manutenção, mas também considera o RUL como entrada juntamente com um controle contínuo de degradação, mas apenas cita um módulo PHM sem muitos detalhes	Sim e é o foco da publicação apresentar sua solução híbrida	4
(CUI et al., 2018)	2018	Cita e utiliza a ideia de manutenção preventiva integrada na modelagem matemática do problema	Sim e possui uma importante contribuição matemática na modelagem do problema que pode ser utilizada	13

continua na próxima página

Tabela 17 – continuação da página anterior

<b>Artigo</b>	<b>Ano</b>	<b>Aborda PdM</b>	<b>Aborda problema de escalonamento</b>	<b>Citações</b>
(NIKOLAKIS et al., 2018)	2018	Sim, mas não detalha, a publicação fica numa abordagem mais alto nível de discussão da integração das informações de produção na tomada de decisão da manutenção	Cita, mas sem detalhes da solução, apresenta a produção como entrada para a agenda de manutenção, uma abordagem contrária dos outros trabalhos relacionados	1

Fonte: O Autor