

INSTITUTO FEDERAL DO ESPÍRITO SANTO
CURSO DE ENGENHARIA METALÚRGICA

LETICIA COSTA MACÊDO

**MANUTENÇÃO PREDITIVA NO CONTEXTO DA INDÚSTRIA 4.0: UM MODELO
PREDITIVO EM UMA FÁBRICA DO RAMO METALÚRGICO**

Vitória
2020

LETICIA COSTA MACÊDO

**MANUTENÇÃO PREDITIVA NO CONTEXTO DA INDÚSTRIA 4.0: UM MODELO
PREDITIVO EM UMA FÁBRICA DO RAMO METALÚRGICO**

Monografia apresentada à Coordenadoria do Curso de Engenharia Metalúrgica do Instituto Federal do Espírito Santo, Campus Vitória, como requisito parcial para a obtenção do título de Bacharel em Engenharia Metalúrgica.

Orientador: Prof. Dr. José Barrozo de Souza.

Vitória
2020

Dados Internacionais de Catalogação na Publicação (CIP)
(Biblioteca Nilo Peçanha do Instituto Federal do Espírito Santo)

M141m Macêdo, Letícia Costa.

Manutenção preditiva no contexto da indústria 4.0 : um modelo preditivo em uma fábrica do ramo metalúrgico / Letícia Costa Macêdo. – 2020.

42 f. : il. ; 30 cm.

Orientador: José Barrozo de Souza.

Monografia (graduação) – Instituto Federal do Espírito Santo, Coordenadoria de Cursos Superiores em Metalurgia, Curso Superior de Engenharia Metalúrgica, Vitória, 2020.

1. Máquinas – Manutenção e reparos. 2. Usinas siderúrgicas – Inovações tecnológicas. 3. Manutenção. 4. Processos de fabricação – Manutenção e reparos. 5. Produtividade industrial. 6. Engenharia metalúrgica. I. Souza, José Barrozo. II. Instituto Federal do Espírito Santo. III. Título.

CDD 21 – 621.816

Elaborada por Marcileia Seibert de Barcellos – CRB-6/ES - 656



MINISTÉRIO DA EDUCAÇÃO
INSTITUTO FEDERAL DO ESPÍRITO SANTO
Autarquia criada pela Lei nº 11.892, de 29 de dezembro de 2008
CAMPUS VITÓRIA
Avenida Vitória, 1729 - Jucubaquara - 29040-780 - Vitória - Espírito Santo

LETICIA COSTA MACÊDO

**MANUTENÇÃO PREDITIVA NO CONTEXTO DA INDÚSTRIA 4.0: UM MODELO
PREDITIVO EM UMA FÁBRICA DO RAMO METALÚRGICO**

Trabalho de conclusão de curso apresentado ao curso de Engenharia Metalúrgica do Ifes,
como requisito parcial para obtenção do título de Engenheira Metalúrgica.

Aprovado em 29 de junho de 2020

COMISSÃO EXAMINADORA:

Prof. Dr. José Barrozo de Souza
Instituto Federal do Espírito Santo
(Orientador)

Prof. Eng. MS.c. Guilherme Augusto de Moraes Pinto
Instituto Federal do Espírito Santo

Prof. Dr. Thalm de Paiva Coelho Junior
Instituto Federal do Espírito Santo

AGRADECIMENTOS

Primeiramente a Deus por me conceder mais essa vitória de obter um título tão sonhado de engenheira de metalurgia e por ter me abençoado em toda minha vida, além da família que me concedeu.

A meu pai Francisco e a minha mãe Luciene, ao qual serei eternamente grata por todo apoio, incentivo e dedicação para que eu chegasse a conclusão do curso. Pela criação com tanto amor e carinho, eles são peça fundamental dessa conquista.

A minhas irmãs Livia e Luiza, minhas melhores amigas, que junto com meus pais estiveram me apoiando e me ajudando a tomar as melhores decisões em minha vida.

A meus amigos Gabriel, Bruna, Daiane e Lara, que fizeram do IFES um lar.

A meus colegas de faculdade, que me ensinaram a importância de sermos colaborativos e solidários uns com os outros.

Ao IFES, que me preparou, ainda que pelo sofrimento, para enfrentar os desafios de uma vida em sociedade e do mundo corporativo.

Em especial ao meu orientador e Prof. Dr. José Barrozo de Souza, que com todo o seu conhecimento não mediu esforços para me passá-lo, sempre facilitando minha compreensão por meio de novas abordagens. Agradeço por toda a sua ajuda na construção do trabalho.

.

“Uma pessoa inteligente resolve um problema, um sábio o previne”.

Albert Einstein

RESUMO

A quantidade de dados levantados dos processos de produção aumentou devido à proliferação de tecnologias de detecção. Quando processados e analisados, os dados podem trazer informações e conhecimentos valiosos da Manufatura. Nas fábricas, o gerenciamento dos ativos físicos é fundamental, pois afeta a eficiência da fábrica. Assim, falhas nos equipamentos precisam ser identificadas e solucionadas, evitando paradas nos processos de produção. Este Trabalho de Conclusão de Curso apresenta uma abordagem baseada na Indústria 4.0, o método de *Machine Learning* uma ferramenta promissora nas aplicações de modelos preditivos para evitar falhas nos ativos físicos da fábrica. Foi descrito um modelo preditivo baseado em um filtro bayesiano (uma ferramenta do campo *Machine Learning*), para gerenciar a degradação gradual das máquinas, permitindo que os operadores tomem decisões informando sobre as tarefas da manutenção. O objetivo deste Trabalho de Conclusão de Curso foi apresentar a partir de uma revisão bibliográfica narrativa, concentrada em três bancos de dados (*Scopus*, *Web of Science* e *Science Direct*), um modelo preditivo baseado em um método de *Machine Learning* aplicado à Manutenção Preditiva. Que forneceu uma base útil sobre o método, seus principais resultados, desafios e oportunidades, além de apoiar novos trabalhos de pesquisa no campo da Manutenção Preditiva.

Palavras-chave: Manutenção 4.0. Manutenção preditiva. Manutenção prescritiva. Operações metalúrgicas. Processos metalúrgicos. Fabricação metalúrgica.

ABSTRACT

The amount of data collected from the production processes has increased due to the proliferation of detection technologies. When processed and analyzed, data can bring valuable information and knowledge from Manufacturing. In factories, the management of physical assets is essential, as it affects the efficiency of the factory. Thus, equipment failures need to be identified and resolved, avoiding downtime in production processes. This Course Conclusion Work presents an approach based on Industry 4.0, the Machine Learning method, a promising tool in the application of predictive models to avoid failures in the physical assets of the factory. A predictive model based on a Bayesian filter (a tool in the Machine Learning field) was described to manage the gradual degradation of the machines, allowing operators to make decisions informing maintenance tasks. The objective of this Course Conclusion Work was to present, based on a narrative bibliographic review, concentrated on three databases (Scopus, Web of Science and Science Direct), a predictive model based on a Machine Learning method applied to Predictive Maintenance. That provided a useful basis on the method, its main results, challenges and opportunities, in addition to supporting new research work in the field of Predictive Maintenance.

Keywords: Maintenance 4.0. Predictive maintenance. Prescriptive maintenance. Metallurgical operations. Metallurgical processes. Metallurgical manufacturing.

SUMÁRIO

1	INTRODUÇÃO	7
2	DESENVOLVIMENTO DA PESQUISA.....	9
2.1	REVISÃO BIBLIOGRÁFICA NARRATIVA – O ESTADO DA ARTE.....	10
2.1.1	Nomenclaturas e políticas de manutenção.....	10
2.1.2	Manutenção preditiva e sua evolução.....	11
2.1.3	A cadeia produtiva da indústria metalúrgica.....	16
2.1.4	Indústria 4.0.....	18
3	ABORDAGEM METODOLÓGICA.....	21
3.1	PLANEJANDO A REVISÃO BIBLIOGRÁFICA NARRATIVA	22
3.3	DOCUMENTANDO A REVISÃO BIBLIOGRÁFICA NARRATIVA	22
3.4	FORMULAÇÃO DO PROBLEMA DE PESQUISA E OBJETIVOS	23
3.4.1	Objetivos da pesquisa	23
3.4.1.1	Objetivo geral:	23
3.4.1.2	Objetivos específicos:.....	24
4	O MODELO PREDITIVO.....	25
5	CONSIDERAÇÕES FINAIS E TRABALHOS FUTUROS	33
	REFERÊNCIAS.....	34

1 INTRODUÇÃO

Iniciativas importantes surgem para a Indústria 4.0 (por exemplo, Estratégia de Alta Tecnologia 2020 (Kagermann et al., 2013), Parceria Avançada de Fabricação (Reif et al., 2014) ou Fábricas do Futuro (Comissão Europeia, 2013) compartilham o mesmo objetivo (Liao et al., 2017): tirar proveito dos avanços nos sistemas ciberfísicos (CPS) (Baheti e Gill, 2011), Internet das Coisas (IoT) (Xia et al., 2012), Internet dos Serviços (IoS) (Atzori et al., 2010) e *Big Data* (Khan et al., 2014), por enfrentar com sucesso as recentes mudanças nos requisitos econômicos, sociais e ambientais para as indústrias de transformação (LASI et al., 2014; SREEDHARAN V. e UNNIKISHNAN, 2017; KANG et al., 2016).

O paradigma Indústria 4.0 está sendo adotado cada vez mais nas cadeias de produção, distribuição e comercialização em todo o mundo. A integração das técnicas de ponta por trás disso implica uma revolução profunda e complexa - passando de processos baseados em agendados para processos inteligentes e reativos - que deve ser aplicada em diferentes níveis.

Corroborando os pesquisadores (Nikolic et al., 2017; O'Donovan et al. 2015) colocam que o objetivo principal desse paradigma é aumentar a eficiência da produção da indústria moderna, buscando alcançar as habilidades de autoconsciência, auto previsão e automanutenção comumente referidas.

A tarefa encarregada de minimizar essas situações é a manutenção, que pode envolver o reparo ou a substituição de componentes ou peças e o descarte de produtos danificados (COMITÊ EUROPEU DE NORMALIZAÇÃO, 2017).

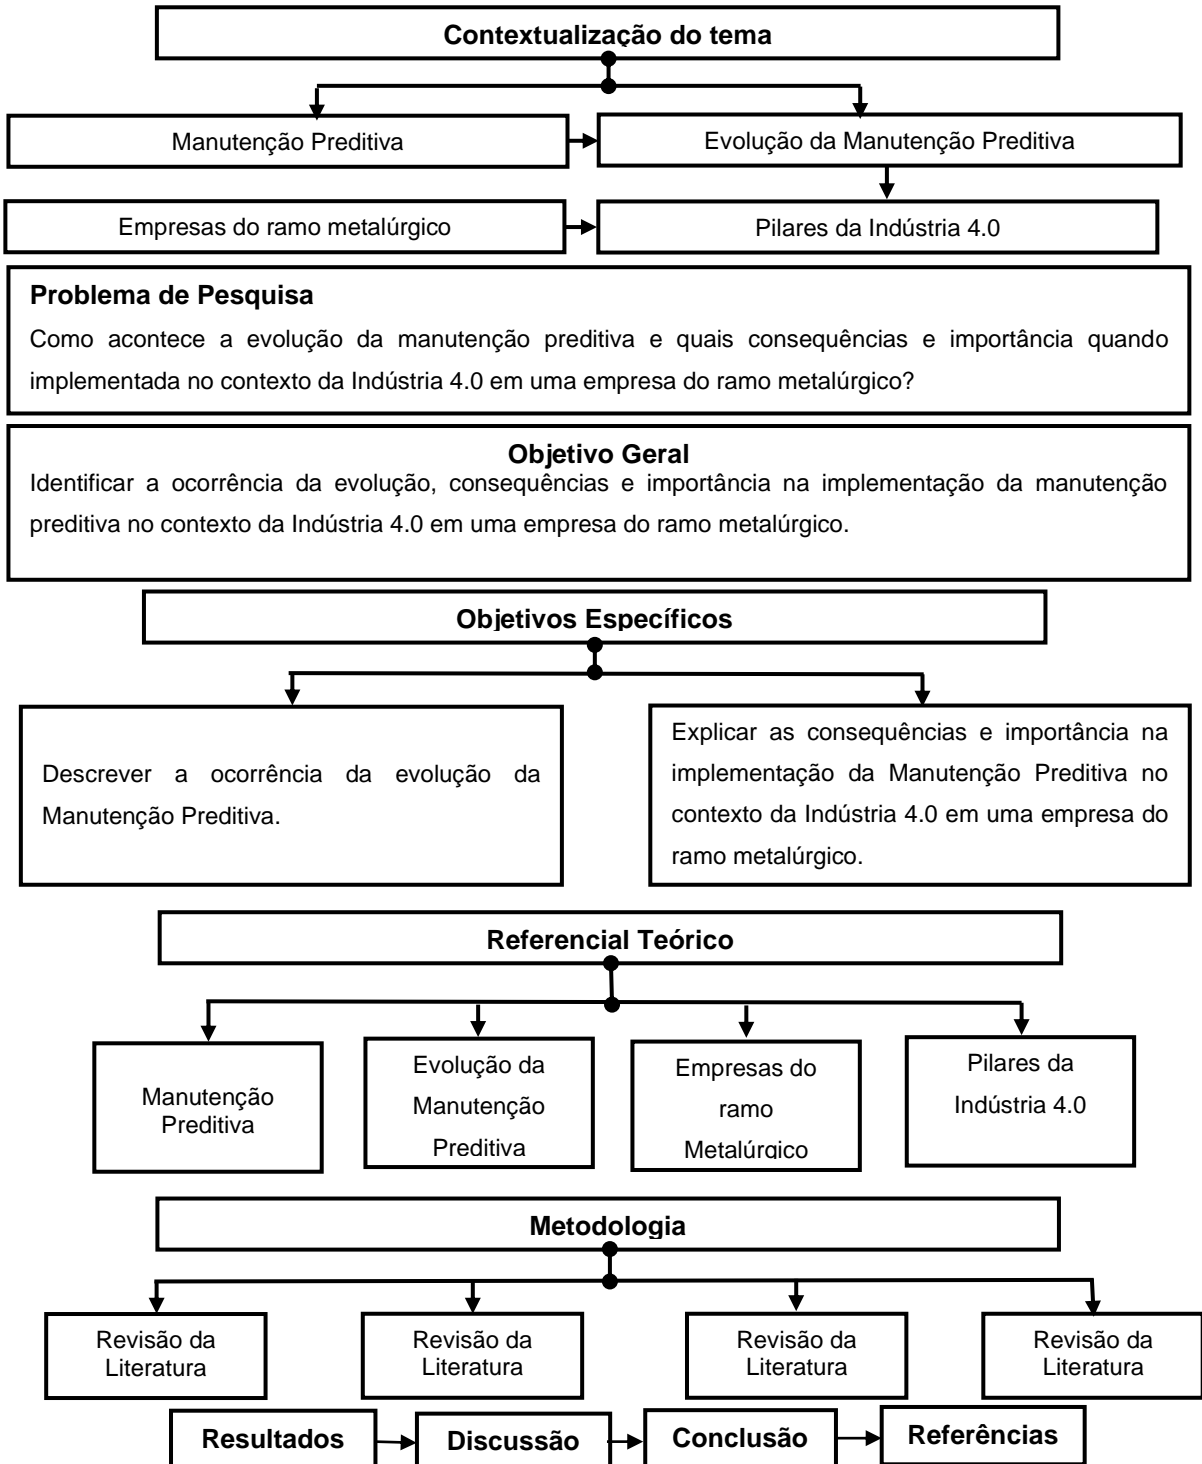
Neste Trabalho de Conclusão de Curso (TCC), contribuimos apresentando um modelo preditivo, proativo de manutenção para um ambiente industrial do ramo metalúrgico. Concretamente, apresentamos um modelo inteligente de manutenção preditiva baseado na filosofia prescritiva da manutenção (Särkkä, 2013; Blanco et al., 2013), uma das técnicas mais difundidas de Aprendizado de Máquinas e equipamentos (ALPAYDIN, 2009).

Para apresentação do modelo inteligente de manutenção preditiva o presente Trabalho de Conclusão de Curso (TCC) utilizou uma abordagem metodológica projetada a partir de uma revisão bibliográfica narrativa. Com o propósito de abordar esse estudo de forma objetiva o Trabalho de Conclusão de Curso (TCC) está estruturado na seguinte ordem. No capítulo 2 relata o desenvolvimento da pesquisa e é apresentando a revisão bibliográfica. No capítulo 3 é descrito a abordagem metodológica usada nesta pesquisa. No capítulo 4 é apresentado a implementação do Modelo Preditivo. E, finalmente no capítulo 5 são apresentadas as considerações finais mais relevantes do TCC e contribuições para trabalhos futuros.

2 DESENVOLVIMENTO DA PESQUISA

A Figura 1 apresenta o delineamento do desenvolvimento do TCC.

Figura 1 – Delineamento da pesquisa



Fonte: adaptado pela autora (2020)

2.1 REVISÃO BIBLIOGRÁFICA NARRATIVA – O ESTADO DA ARTE

Atualmente, a indústria está passando pelo que os especialistas chamam de "Quarta Revolução Industrial", também chamada Indústria 4.0. Esse fato está fortemente associado à integração entre sistemas físicos e digitais dos ambientes de produção.

A integração desses ambientes permite a coleta de uma grande quantidade de dados coletados por diferentes equipamentos, localizados em diferentes setores das fábricas (Borgi et al., 2017). Além disso, as novas tecnologias da Indústria 4.0 integram pessoas, máquinas e produtos, permitindo uma troca de informações mais rápida e direcionada (RAUCH et al., 2019).

Esta seção apresenta e descreve as abordagens de manutenção mais comuns e generalizadas (2.1.1), incluindo a manutenção preditiva de ativos e sua evolução (consulte as seções 2.1.2), bem como um contexto conceitual sobre “empresa do ramo metalúrgico” (seção 2.1.3) e os pilares da Indústria 4.0 (seção 2.1.4) para apresentar posteriormente, como resultado da pesquisa, um modelo de manutenção preditiva em uma empresa do ramo metalúrgico.

2.1.1 Nomenclaturas e políticas de manutenção

Na literatura, diferentes nomenclaturas e grupos de manutenção estratégias de gerenciamento podem ser encontradas. Este estudo considera as categorias propostas pelos trabalhos (Susto et al., 2012; Susto et al., 2015). Eles classificam os procedimentos de manutenção da seguinte maneira:

- a) A manutenção *Run-to-Failure* (R2F) ou corretiva ocorre apenas quando um equipamento para de funcionar. Essa é a estratégia de manutenção mais simples, pois é necessário que a parada na produção e o reparo das peças sejam substituídos, agregando um custo direto ao processo.
- b) Manutenção Preventiva, Manutenção baseada em tempo ou Manutenção programada é uma técnica de manutenção executada periodicamente com um cronograma planejado no tempo ou iterações de processo para antecipar

falhas de processo / equipamento. Geralmente, é uma abordagem eficaz para evitar falhas. No entanto, ações corretivas desnecessárias são tomadas, levando a um aumento nos custos operacionais.

- c) A Manutenção Preditiva usa ferramentas preditivas para determinar quando as ações de manutenção são necessárias. Baseia-se no monitoramento contínuo de uma máquina ou na integridade de um processo, permitindo que a manutenção seja executada apenas quando necessário. Além disso, permite a detecção precoce de falhas graças a ferramentas preditivas baseadas em dados históricos (por exemplo, técnicas de aprendizado de máquina), fatores de integridade (por exemplo, aspectos visuais, desgaste, coloração diferente do original, entre outros), métodos de inferência estatística e abordagens de engenharia.

2.1.2 Manutenção preditiva e sua evolução

Com base nos modelos de manutenção de máquinas publicados anteriormente, podemos dizer que há uma tendência crescente entre o desenvolvimento da manutenção e as tecnologias utilizadas. Os pesquisadores (Peter Poor et al., 2020) mostram que quanto mais sofisticada a manutenção das máquinas, são necessárias tecnologias mais sofisticadas e pessoal qualificado para sua operação. O tipo mais evoluído de Manutenção de Máquinas é chamado de Manutenção Preditiva ou Manutenção usando elementos da Indústria 4.0.

A definição mais "amplamente usada" de manutenção de máquinas é a norma sueca SS-EN 13306, que a define como uma "combinação de todas as ações técnicas, administrativas e gerenciais durante o ciclo de vida de um item destinado a retê-lo ou restaurá-lo" para, um estado no qual ele pode executar a função necessária (SS-EN 13306, 2001, p.7).

A metodologia fundamental usada neste artigo está relacionada à implementação da manutenção preditiva de máquinas nas empresas. Este modelo apresenta uma nova manutenção preditiva de mudança (radical) usando elementos da Indústria 4.0, cuja funcionalidade é otimizada na análise de dados on-line (fornecida principalmente por sensores). Os processos de manutenção são totalmente automatizados e as

máquinas e equipamentos digitalizados estão totalmente envolvidas no CMMS (*Computerized maintenance management system*) e na rede da empresa. Além disso, são utilizados sistemas inteligentes de manutenção, monitoramento remoto e controle de produção.

Wei et al. (2019) propõem uma estratégia de manutenção baseada em condições para determinar a ação ideal (por exemplo, nenhuma ação e substituição corretiva) com base no estado do sistema, a fim de minimizar a taxa de custo média.

Por outro lado, Dong et al. (2019) desenvolvem uma estrutura de gerenciamento prognóstico e de saúde para detectar a degradação do sensor nos sistemas de fabricação, a fim de otimizar o cronograma de manutenção, com o objetivo de reduzir o custo de manutenção, evitando tempos de inatividade desnecessários e apoiando a tomada de decisão.

Como descrito anteriormente, a manutenção preditiva lida com a previsão de falhas ou falhas antes que elas ocorram. De acordo, com os estudos dos autores Jardine et al. (2006), as abordagens de manutenção capazes de monitorar as condições do equipamento para fins de diagnóstico e prognóstico podem ser agrupadas em três categorias principais: abordagens estatísticas, abordagens de inteligência artificial e abordagens baseadas em modelos.

Como as abordagens baseadas em modelo precisam de conhecimento mecanicista e teoria do equipamento a ser monitorado, e as abordagens estatísticas exigem formação matemática, as abordagens de inteligência artificial foram cada vez mais aplicadas em aplicativos preditivos. O Quadro 1 mostra as correlações entre as revoluções industriais e manutenção.

Quadro 1 – Correlações entre as revoluções industriais e manutenção

Revoluções Industriais	Indústria 1.0	Indústria 2.0	Indústria 3.0	Indústria 4.0
Características	Mecanização Poder do vapor tear de tecelagem	Produção em Massa Linhas de montagem Energia elétrica	Automação Computadores, Eletrônicos	Cyber Physical IoT, Redes Computação em Nuvem
Tipo de Manutenção	Reativa	Planejada	Produtiva Total	Preditiva
Inspeção	Inspeção Visual	Inspeção Instrumentada	Monitoramento de Sensores	Preditiva e Análises
OEE	<50%	50% - 75%	75% - 90%	>90%
Equipe de Manutenção	Treinado artesãos	Inspetores	Engenharia de Confiabilidade	Dados Inteligentes

OEE Overall Equipment Effectiveness = Disponibilidade x Desempenho x Qualidade

Fonte: adaptado pela autora, a partir de Coleman, D. C. (1956) e Baptista et al. (2018)

Por exemplo, Baptista et al. (2018) comparam várias abordagens de inteligência artificial com uma abordagem estatística (chamada modelo de uso da vida) para prever quando um equipamento estará em risco de falha no futuro; e os resultados sugerem que as abordagens de inteligência artificial superam as abordagens estatísticas.

O *Machine Learning* (ML), dentro da inteligência artificial, surgiu como uma ferramenta poderosa para o desenvolvimento de algoritmos preditivos inteligentes em muitas aplicações. As abordagens de *Machine Learning* (ML), (Wuest et al., 2016) têm a capacidade de manipular dados de alta dimensão e multivariada e extrair relacionamentos ocultos dentro de dados em ambientes complexos e dinâmicos (como ambientes industriais).

Portanto, o *Machine Learning* (ML) fornece abordagens preditivas poderosas para aplicativos preditivos. No entanto, o desempenho dessas aplicações depende da escolha apropriada da técnica de *Machine Learning* (ML).

Técnicas de manutenção preditiva podem ser implementadas através da monitoração de equipamentos combinados com métodos de decisão inteligentes.

Conforme estudos de vários autores e pesquisadores (O'Donovan, Leahy, Bruton, & O'Sullivan, 2015; Selcuk, 2017; Wang, 2013). As técnicas de *Machine Learning* (ML) e *Data Mining* (DM) podem ser usadas para extrair informações dos dados e prever com precisão os resultados para apoiar a tomada de decisões e ajudar as organizações a melhorar suas operações e competitividade.

As abordagens de aprendizado de máquina comumente usadas para detecção e diagnóstico de falhas incluem redes neurais artificiais (Tian, 2012; Zhang, Wang & Wang, 2013), máquinas de vetores de suporte (Li et al., 2014; Susto, Schirru, Pampuri, McLoone e Beghi), 2015) e Árvores de Decisão (He, He, & Wang, 2013), entre outras. No entanto, essas abordagens tendem a se concentrar na análise de vibração e som (Banerjee & Das, 2012; Zhang et al., 2013), mas a coleta e análise de outros parâmetros, como dados de eventos, também devem ser consideradas (Lee, Lapira, Bagheri & Kao, 2013).

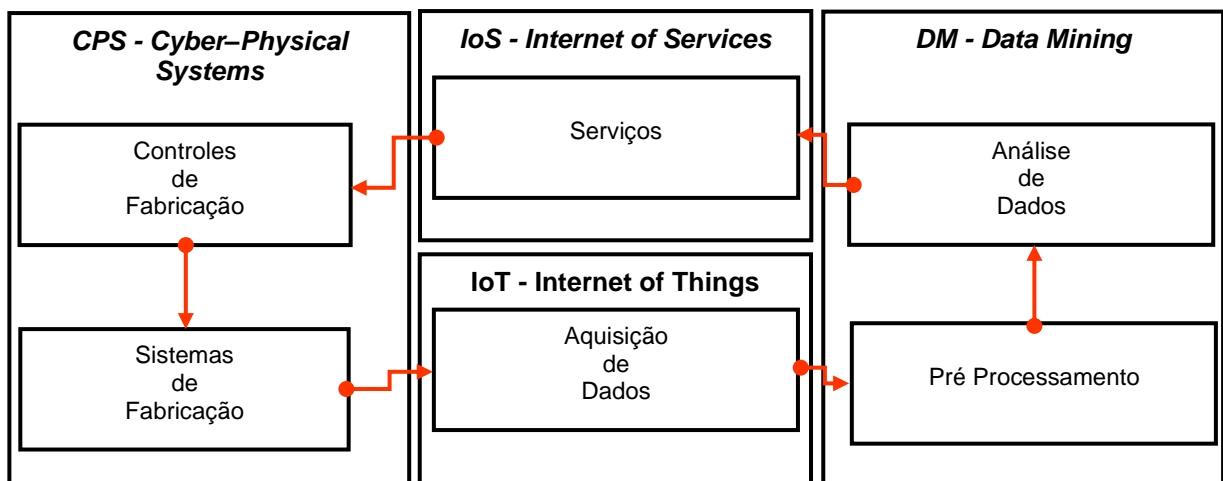
Entretanto, conforme os autores (Lee et al., 2013), a manutenção preditiva apresenta vários benefícios inerentes, a saber: uso otimizado de peças, custos reduzidos, aumento da vida útil das máquinas, segurança da fábrica, qualidade do produto (quase zero de falha na fabricação), número reduzido de acidentes ou integração sem esforço com a programação da empresa, entre outros (Lee et al., 2013). Apesar dos benefícios dos sistemas preditivos, sua implementação em fábricas reais permanece desafiadora, principalmente devido à integração exigida de diferentes tecnologias baseadas na Indústria 4.0 (PRAJAPATI et al., 2012; LEE et al., 2014). Os principais desafios são:

- a) O processamento de grandes repositórios de dados de séries temporais de logística, programação e produção (provenientes de sensores ruidosos montados nas máquinas), a fim de serem renderizados de forma útil para sua exploração (Ruiz-Sarmiento et al., 2017) e,
- b) O design de um modelo preditivo que, a partir desses dados processados, calcule a condição da maquinaria em pouco tempo para executar uma tomada de decisão ágil e informada.

Esse modelo também deve ser capaz de aprender com novos dados e adaptar sua operação de acordo com diferentes situações (Roger W. et al., 2014). Os sistemas preditivos também podem se beneficiar da consideração de informações provenientes de especialistas sobre a operação de máquinas, que é um conhecimento valioso tradicionalmente usado em soluções baseadas em inteligência artificial para a indústria. Esses problemas precisam ser enfrentados não apenas no sistema preditivo, mas na maioria das soluções baseadas no setor 4.0 (NIKOLIC et al., 2017).

Manutenção 4.0 (preditiva). Ela permite que os sistemas aprendam automaticamente, prevejam falhas, façam seus diagnósticos e acionem os fluxos de manutenção usando dados históricos, conhecimento do domínio e dados em tempo real coletados através de dispositivos de IoT (JI W, WANG L.2017; MOURTZIS D, VLACHOU E. 2018). Ao examinar como implementar especificamente o *Big Data* no contexto de fabricação e manutenção, (Li, et al. 2017) demonstra uma arquitetura que combina a visualização CPPS (*Cyber-Physical Production Systems*) e os subsistemas de *Big Data* com as tecnologias necessárias (veja a Figura 2).

Figura 2 – Visualização simplificada de uma arquitetura para manutenção preditiva



Fonte: adaptado pela autora (2020)

É um modelo modular que inclui feedback ao sistema em um módulo CPS, que é a parte física, ou seja, o sistema de fabricação. Os dados são adquiridos no módulo IoT e pré-processados e analisados em um módulo *Data Mining* (DM). Como no

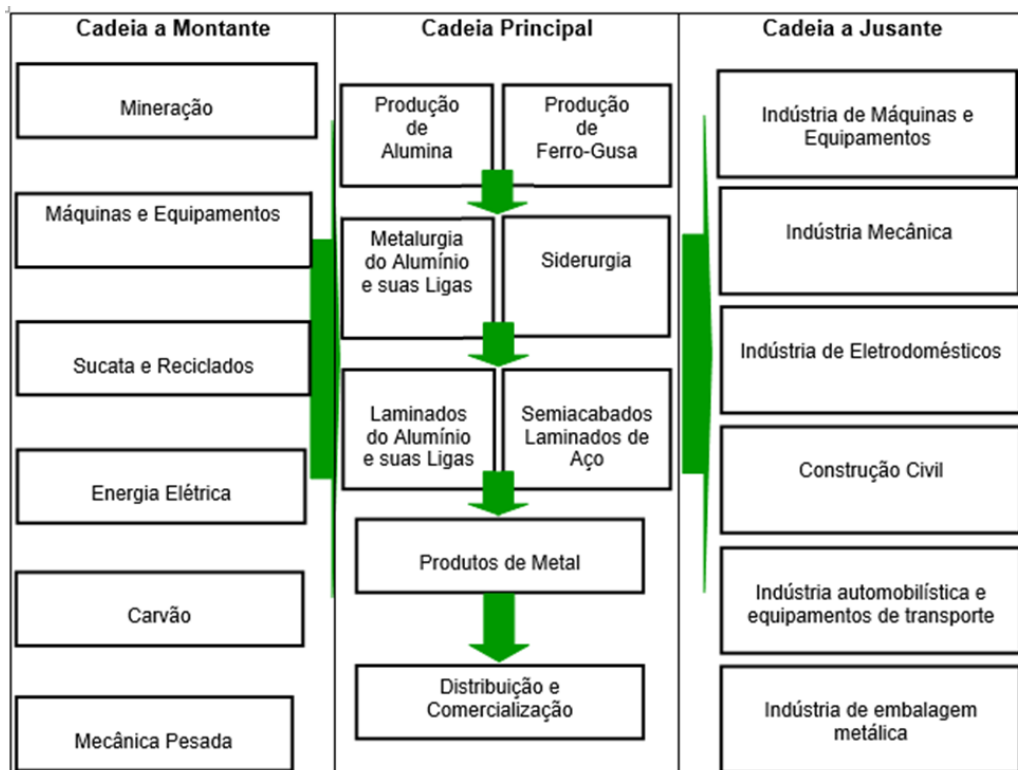
modelo de arquitetura 5C, os resultados são distribuídos como serviços no módulo *Internet of Services* (IoS).

A Manutenção Preditiva 4.0 possui vários atributos em vários domínios em que cada domínio tem requisitos diferentes. Este estudo tem como objetivo introduzir as dimensões da análise da Manutenção Preditiva 4.0 e os requisitos técnicos associados a partir de uma perspectiva de técnicas de análise de *big data* (que são adequadas para a tomada de decisão).

2.1.3 A cadeia produtiva da indústria metalúrgica

A cadeia produtiva da indústria metalúrgica e produtos de metal está organizada em três blocos: cadeia a montante, a cadeia principal e a cadeia a jusante, como mostra a Figura 3.

Figura 3 – Cadeia produtiva da metalurgia e dos produtos de metal



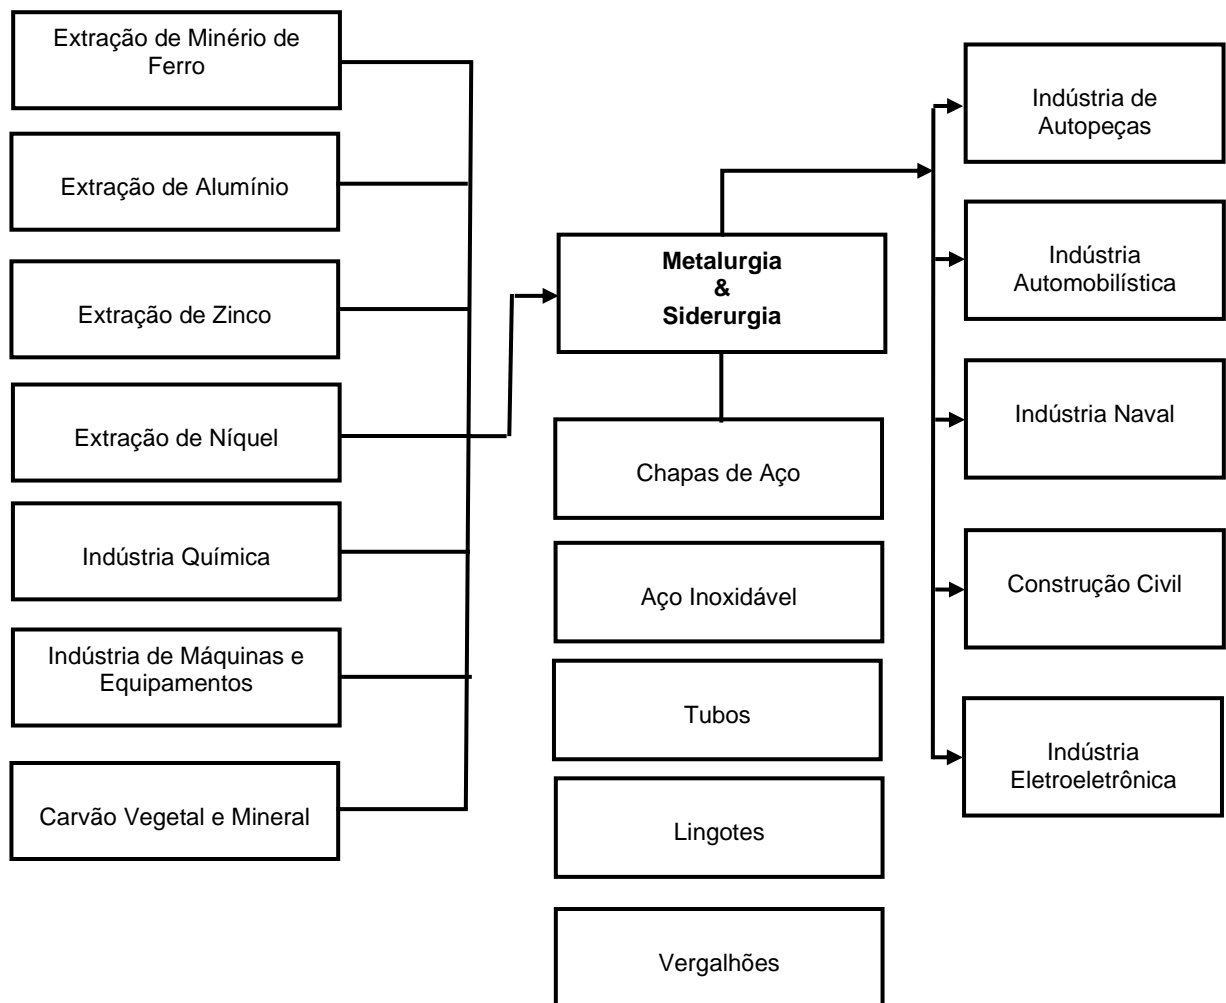
Fonte: adaptado pela autora (2020)

A cadeia a montante tem sua base no fornecimento de matéria-prima e insumos de valor agregado moderado, para produção da cadeia principal — no caso, a mineração é responsável pela atividade extrativa do minério de ferro, insumo básico

para a produção do ferro-gusa, e da bauxita, matéria-prima para produção de alumina.

Por outro lado, a cadeia a jusante é formada por elos que tomam os produtos resultantes da cadeia principal como insumos para a sua própria produção. Dentre tantas utilizações dos produtos da indústria metalúrgica e produtos de metal, destacam-se as indústrias de máquinas e equipamentos, metalomecânica, de eletrodomésticos, construção civil, automobilística e de equipamentos de transporte, e de embalagens. A Figura 4 apresenta a cadeia produtiva do setor metalúrgico/siderúrgico.

Figura 4 – Cadeia produtiva do setor metalúrgico/siderúrgico



Fonte: adaptado pela autora (2020)

A principal característica da cadeia metalúrgica e produtos de metal é o seu sistema de trabalho. Tradicionalmente se trabalha por encomenda (produção puxada), e não em produção contínua e em série (produção empurrada). Por outro lado, trabalha-se com uma grande diversidade de produtos.

2.1.4 Indústria 4.0

Um princípio-chave do paradigma Indústria 4.0 é que processos e máquinas devem ser conectados em rede como uma comunidade colaboradora para a coleta, troca e análise de dados, a fim de prever comportamentos futuros e buscar soluções ideais para possíveis problemas (LASI et al., 2014; KANG et al., 2016).

Os autores (Baheti e Gill, 2011), informam que atualmente, esse princípio está começando a ser atingido graças ao desenvolvimento de várias tecnologias promissoras. Uma dessas tecnologias é o chamado *Cyber-Physical Systems* que se refere a sistemas com capacidades computacionais e físicas integradas que podem ser interconectadas de diferentes maneiras (MONOSTORI, 2014; LEE et al., 2015).

Essa integração permite a interconexão entre o espaço virtual e o mundo físico, implicando processos de fabricação mais flexíveis e a análise em tempo real de grandes quantidades de informações (XU et al., 2018; ALQAHTANI et al., 2019).

Embora a maioria das tecnologias tenha sido desenvolvida antes do reconhecimento formal da Indústria 4.0 (Wan et al., 2015; Rüßmann et al., 2015), foi somente após o barateamento de alguns componentes-chave que a Indústria 4.0 se tornou mais viável financeiramente (PORTER e HEPPELMANN, 2014).

As tecnologias incluídas na Indústria 4.0 permitem monitorar e controlar equipamentos, produtos e serviços de uma maneira que grandes quantidades de dados são coletadas, inseridas em sistemas integrados e analisadas por modelos virtuais, aprimorando os processos de tomada de decisão (WANG et al., 2015; FRANK et al., 2019a).

Além disso, as tecnologias da Indústria 4.0 sustentam a integração digital de três perspectivas principais: engenharia vertical, horizontal e de ponta a ponta (WEYER et al., 2015; FATORACHIAN e KAZEMI, 2018).

Essa integração digital permite a interconectividade e a troca de informações em toda a cadeia de valor (Liao et al., 2017), o que pode favorecer uma colaboração aprimorada e um aprendizado sistemático em todos os níveis.

Muitos autores propuseram estruturas diferentes para a implementação da Indústria 4.0. Lu (2017), por exemplo, apresentou uma estrutura conceitual de interoperabilidade de Indústria 4.0 composta por quatro níveis: operacional (organizacional), sistemático (aplicável), técnico e semântico. Mittal et al. (2019), com base em uma extensa revisão da literatura, consolidou um conjunto de cinco características definidoras, 11 tecnologias e três fatores facilitadores relevantes para a implementação da Indústria 4.0.

Da mesma forma, Xu et al. (2018) listaram quatro principais facilitadores da Indústria 4.0:

- a) IoT e tecnologias relacionadas,
- b) Computação em nuvem,
- c) Sistemas ciber-físicos e
- d) Integração industrial, arquitetura corporativa e integração de aplicativos corporativos.

No geral, essas estruturas surgiram de uma extensa revisão da literatura como diretrizes para a implementação da Indústria 4.0, embora a maioria ainda não possua validação empírica e negligencie a influência potencial do contexto.

Em oposição, Frank et al. (2019b) realizaram um estudo baseado em pesquisas em fabricantes brasileiros e validaram empiricamente um quadro teórico composto por quatro tecnologias Indústria 4.0 principais, denominadas “tecnologias de base” devido à sua versatilidade e ampla utilização.

Eles incluem: Internet das Coisas (IoT), *Cloud Computing*, *Big Data* e *Data Analytics* (por exemplo, aprendizado de máquina e mineração de dados). Alega-se que essas tecnologias básicas aproveitam os conceitos da Indústria 4.0, facilitando a interconectividade e fornecendo inteligência aos sistemas de fabricação. Portanto, devido às semelhanças no contexto estudado (setor industrial brasileiro) e à validação empírica da estrutura proposta, as tecnologias de base de Frank et al. (2019b) foram adotadas nesta pesquisa como medidas para a implementação da Indústria 4.0.

3 ABORDAGEM METODOLÓGICA

A abordagem metodológica projetada para o presente Trabalho de Conclusão de Curso (TCC) tem o objetivo de fornecer uma estrutura de orientação, a fim de identificar o impacto da adoção da estratégia da Manutenção Preditiva no contexto dos princípios da Indústria 4.0 no desenvolvimento de uma empresa do ramo metalúrgico e como os recursos da empresa em diferentes níveis de contexto influenciam a associação entre os princípios da Indústria 4.0 e a melhoria do desempenho operacional.

Para tanto foi necessário à preparação (“planejamento da revisão da literatura”), um estágio operacional (“realização da revisão narrativa”) e um estágio de relatório (“documentação da revisão”) (M. PETTICREW *and* H. ROBERTS, 2006); (D. DENYER *and* D. TRANFIELD 2009). Essa abordagem é descrita na Figura 5.

A revisão narrativa da literatura centrou-se, na questão científica “Como acontece a evolução da manutenção preditiva e quais consequências e importância quando implementada no contexto da Indústria 4.0 em uma empresa do ramo metalúrgico”?

Figura 5 – Processo de estruturação revisão da literatura

Etapa 1		Etapa 2	(d) Identificar pesquisas relevantes	Etapa 3	
Planejamento da Revisão	(a) Estruturar a Pergunta de pesquisa	Realizando a Revisão	(e) Selecionar estudos primários	Documentar a Revisão	(i) Escrever relatório da revisão (TCC)
	(b) Desenvolver o protocolo de revisão		(f) Acessar estudo qualificado		(j) Defender o relatório de revisão (TCC)
	(c) Validar o protocolo de revisão		(g) Extrair dados obrigatórios		
			(h) Sintetizar dados		

Fonte: adaptado pela autora, (2020)

3.1 PLANEJANDO A REVISÃO BIBLIOGRÁFICA NARRATIVA

No estudo, o foco foi entender o impacto da adoção da Manutenção Preditiva no contexto da Indústria 4.0 no desenvolvimento e melhoria do desempenho operacional de uma empresa do ramo metalúrgico.

Para selecionar estudos relevantes, foi realizada uma triagem, com base no título e resumo apresentado de cada artigo encontrado na revisão bibliográfica para determinar se o escopo do documento incluía ou não os conceitos relacionados ao impacto da adoção da Manutenção Preditiva no contexto da Indústria 4.0 no desenvolvimento e melhoria do desempenho operacional de uma empresa do ramo metalúrgico.

3.2 REALIZANDO A REVISÃO BIBLIOGRÁFICA NARRATIVA

A busca de palavras-chave, acompanhada por descritores usando o banco de dados da *Capes (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior)* nas bases *Scopus*, *Science Direct* e *Web of Science*, a revisão foi composta de artigos de periódicos, com a preocupação de não perder trabalhos relevantes.

Esse método permitiu confiar não apenas nas palavras-chave de pesquisa (Manutenção 4.0. Manutenção preditiva. Manutenção prescritiva. Operações metalúrgicas. Processos metalúrgicos. Fabricação metalúrgica) e seus descritores (“*And Or*”), mas também em verificar a lista de referência de artigos relevantes.

3.3 DOCUMENTANDO A REVISÃO BIBLIOGRÁFICA NARRATIVA

Para validação da amostra bibliográfica, foi dispensada uma atenção especial à confiabilidade dos periódicos utilizados, considerando as suas indexações nos referidos bancos de dados. Assim sendo foi criado um arquivo biblioteca eletrônica com o objetivo de guardar os artigos extraídos dos referidos periódicos.

A amostra bibliográfica teve um foco geral com conteúdo sobre Manutenção Preditiva, Indústria 4.0 e empresas do ramo metalúrgico.

3.4 FORMULAÇÃO DO PROBLEMA DE PESQUISA E OBJETIVOS

Os dados pesquisados neste Trabalho de Conclusão de Curso (TCC) foram coletados usando uma ampla revisão bibliográfica, utilizando as bases do Portal de Periódicos da CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior), *Scopus*, *Web of Science* e *ScienceDirect*, como mostrado no Quadro 2.

Quadro 2 – Desenvolvimento do problema de pesquisa e objetivos

Eventos	Soluções metodológicas
Pergunta de pesquisa	Revisão bibliográfica Narrativa/Desenvolvimento da pesquisa
Objetivo geral	
Objetivos específicos	

Fonte: adaptado pela autora (2020)

No âmbito do cenário acadêmico e profissional é relevante focar o processo de estruturação do conhecimento a respeito da metodologia científica de pesquisa, quanto aos fatores e requisitos envolvidos neste Trabalho de Conclusão de Curso e seu rigor metodológico, assim sendo a formulação da pergunta científica foi conduzida pela seguinte questão: “Como acontece a evolução da manutenção preditiva e quais consequências e importância quando implementada no contexto da Indústria 4.0 em uma empresa do ramo metalúrgico”?

3.4.1 Objetivos da pesquisa

Os objetivos utilizados na pesquisa foram oriundos da questão de pesquisa e focaram em:

3.4.1.1 Objetivo geral:

O presente Trabalho de Conclusão de Curso apresenta o seguinte objetivo geral:

- Identificar a ocorrência da evolução, consequências e importância na implementação da manutenção preditiva no contexto da Indústria 4.0 em uma empresa do ramo metalúrgico.

3.4.1.2 Objetivos específicos:

- Descrever a ocorrência da evolução da Manutenção Preditiva;
- Explicar as consequências e importância na implementação da Manutenção Preditiva no contexto da Indústria 4.0 em uma empresa do ramo metalúrgico.

4 O MODELO PREDITIVO

A competitividade de uma empresa é mais crucial do que nunca no atual cenário econômico, sendo imensamente influente na capacidade da empresa de fornecer produtos de qualidade a preços baixos, ou seja, ser para o mercado competitiva e com um bom nível de produtividade. A manutenção das máquinas e equipamentos, com seu impacto direto no tempo de inatividade e nos custos de produção, está diretamente relacionada à capacidade das empresas de manufatura de serem competitivas em termos de custo, qualidade e desempenho (ABOELMAGED, 2014; HOLMBERG et al., 2010).

As modernas abordagens de manutenção pretendem reduzir as taxas de falhas e melhorar os tempos de produção, mas ainda não são amplamente aplicadas (Holmberg et al., 2010), com empresas menores demonstrando um nível mais baixo de prontidão para manutenção (ABOELMAGED, 2014).

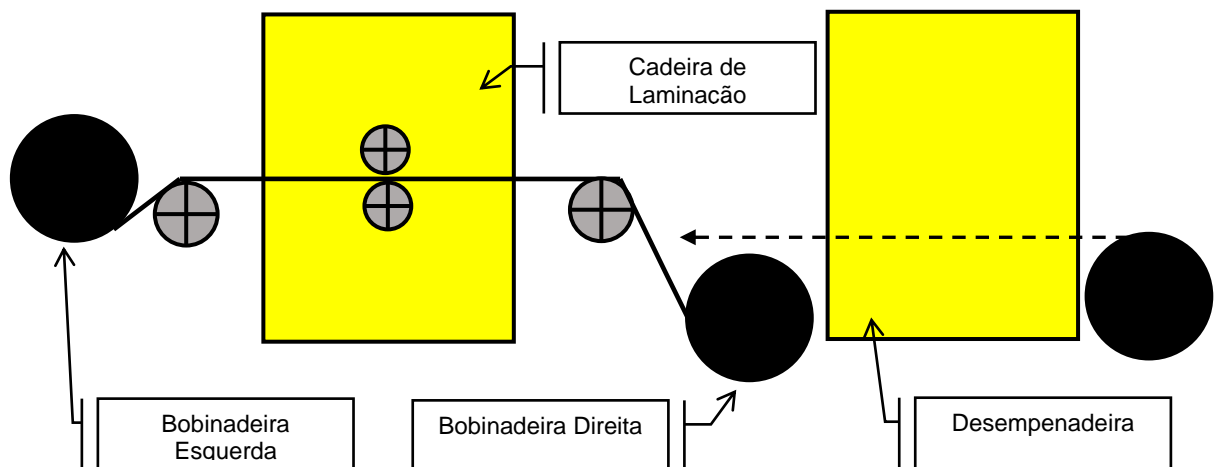
Essas técnicas modernas refletem uma transição das práticas de manutenção corretiva e/ou preventivas para as mais proativas: a manutenção proativa tem a vantagem de corrigir os problemas antes que eles ocorram, substituindo as peças após um certo nível de deterioração ter sido identificado, em vez de corrigir a falha após o fato (MULLER, MARQUEZ e IUNG, 2008). A manutenção proativa inclui manutenção preditiva.

Como já discutido em seções anteriores, as técnicas de manutenção preditiva podem ser implementadas através da monitoração de equipamentos combinados com métodos inteligentes de decisão. As técnicas de *Machine Learning* e *Data Mining* podem ser usadas para extrair informações dos dados e prever com precisão os resultados para apoiar a tomada de decisões e ajudar as organizações a melhorar suas operações e competitividade (O'DONOVAN, LEAHY, BRUTON e O'SULLIVAN, 2015; SELCUK, 2017; WANG, 2013).

Este TCC descreve um modelo preditivo baseado em uma ferramenta do campo *Machine Learning* (Indústria 4.0), para estimar e prever a degradação gradual máquinas laminadoras de produção de chapas de aço inoxidável de alta qualidade,

em uma fábrica (concretamente, as máquinas em estudo são os tambores de bobina, componentes críticos no processo de laminação a quente para a produção de chapas finas de aço inoxidável), ou seja, processo de laminação a quente, permitindo que os operadores tomem decisões informadas sobre as operações mais adequadas de manutenção. A Figura 6 mostra a configuração de um laminador.

Figura 6 – Configuração de laminador tipo Sendzimir

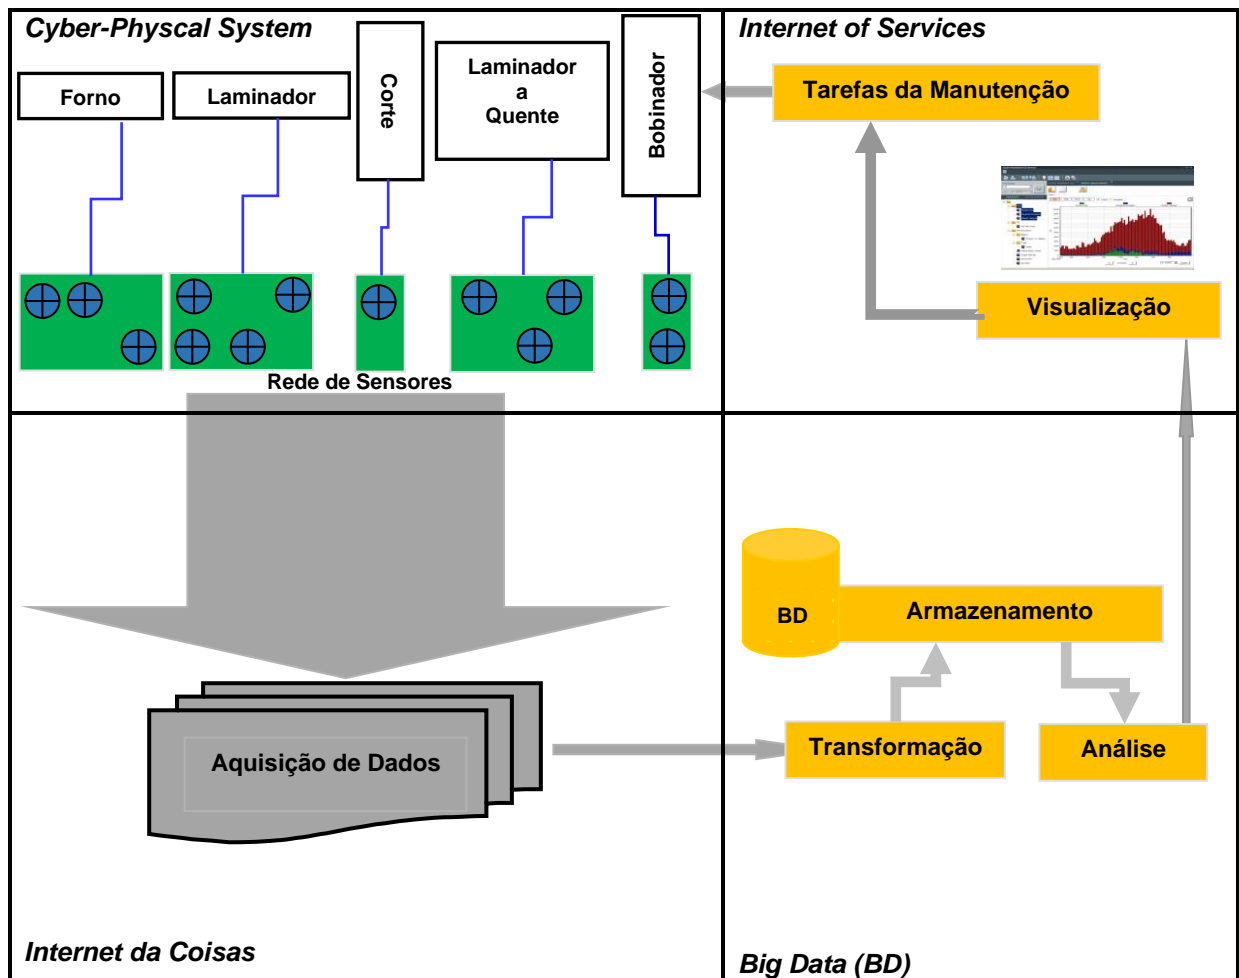


Fonte: adaptado pela autora (2020).

A Figura 7 mostra o modelo preditivo no contexto da busca do sincronismo sistêmico entre as tarefas da manutenção com os processos e operações. O sincronismo começa montando no laminador vários sensores inteligentes (incorporados). Esses sensores são conectados a uma rede local, convertendo o laminador em um sistema *ciber-físico* (CPS), e são responsáveis por medir parâmetros que mudam de acordo com modificações e distúrbios no processo do laminador. Para cada processo de laminação realizado na fábrica, as técnicas da *Internet of Things* são usadas para recuperar as informações coletadas dos sensores e encaminhá-las com segurança para um servidor centralizado.

Avanços recentes no *Big Data* são usados para transformar esses dados em rede em um formato válido para armazenamento em um banco de dados, por exemplo, o NoSQL (meios mais eficientes de armazenamento de grandes volumes de dados e/ou mecanismos de pesquisa de baixa latência), fatores importantes que precisam ser considerados durante a escolha de uma solução de armazenamento de dados, proporcionando alta capacidade e rápida execução de consultas (POKORNY, 2013).

Figura 7 – Componentes lógicos do sistema de manutenção preditiva (tecnologias de sistemas *ciber-físicos*, *Internet das Coisas*, *Big Data* e *Internet de serviços*)



Fonte: adaptado pela autora (2020)

A Figura 7 mostra que existe possibilidades tecnológicas com a utilização da ferramenta *Machine Learning* (Indústria 4.0), para estimar e prever a degradação gradual máquinas laminadoras e seus respectivos itens críticos (sistemas). Esses sistemas são aprimorados com recursos da tecnologia *Internet of Things* (IoT) (Xia et al., 2012), fornecendo a capacidade de obter informações continuamente de conjuntos de sensores ou processos em toda a fábrica e enviá-las com segurança para um sistema de armazenamento (geralmente em nuvem). *Data centers*) (Wan et al., 2016).

Durante a revisão da literatura, observou-se que as técnicas de *Machine Learning* estão sendo gradualmente aplicadas para o design de aplicativos a Manutenção

Preditiva. Em algumas aplicações, o sincronismo entre *Machine Learning* e Manutenção Preditiva leva a resultados positivos com redução de custos.

Essa produção massiva de dados implica o desenvolvimento de novas ferramentas baseadas nas técnicas de *Big Data* (Khan et al., 2014; O'Donovan et al., 2015; Khan et al., 2017), para armazená-las, gerenciá-las e processá-las. Esse conjunto de tecnologias é concluído com o *Internet of Services* (IoS), que pega as informações processadas das ferramentas de *Big Data* e as implanta no local certo e na forma correta (ATZORI et al. 2010).

Devido ao conjunto de tecnologias apresentado pela Indústria 4.0 é necessário para cada um desses elementos verificar se o elemento é:

- a) Usado para fins de manutenção;
- b) Usado na empresa e implantado na manutenção;
- c) Usado na empresa, implantado na empresa;
- d) Se eles estão planejando implantar o elemento ou não saber sobre isso.

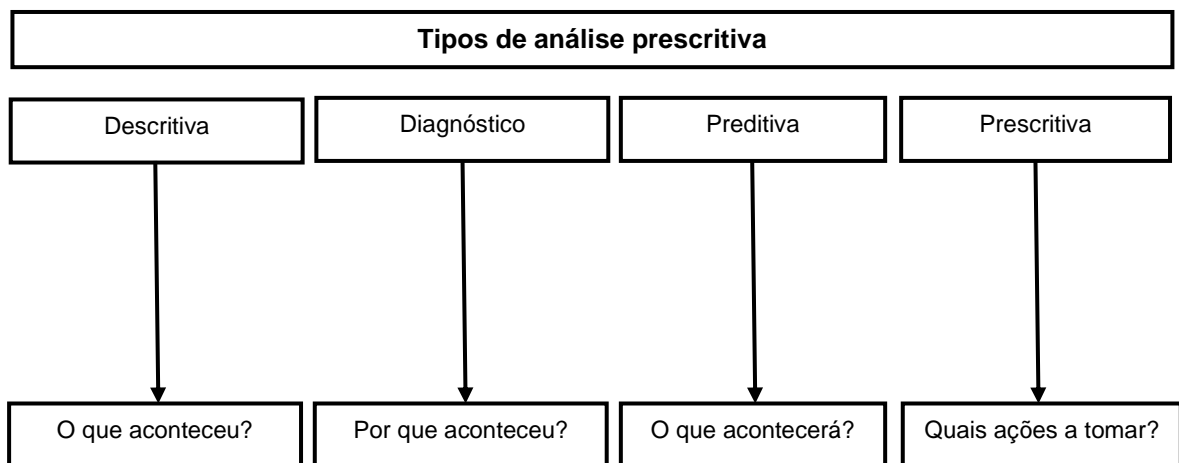
Toda essa preocupação da escolha da tecnologia mais adequada da Indústria 4.0 para sincronizar com as operações e processos instalados nos diversos *layouts* das empresas, se dá devido a Manutenção 4.0 (Prescritiva) ser ainda é um tipo de manutenção de aplicação incipiente, mas que se tornará cada vez mais comum com o avanço da Quarta Revolução Industrial.

A estratégia prescritiva da manutenção está baseada na análise prescritiva cuja diferença da análise preditiva está em, além de predizer, também pode oferecer alternativas de solução na tomada de decisão (ver Figura 8).

No presente TCC, apresentamos um modelo preditivo que se baseia em uma técnica de *Machine Learning* (ML), um filtro discreto de Bayes (Särkkä, 2013) (DBF), para converter informações de sensores, processos e especialistas em domínio em conhecimento sobre o estado de degradação de máquinas e seu futuro comportamento. As informações latentes nesse tipo de sistema são modeladas naturalmente pelo filtro, fornecendo também uma medida valiosa de crença sobre seu resultado.

Conforme os estudos apresentados pelos pesquisadores (Roger W. et al., 2014), outra vantagem clara dos DBFs em relação a outras alternativas de *Machine Learning* (ML) é sua robustez contra dados flutuantes e ruidosos. O filtro proposto também pode aprender com a experiência, superando, assim, o teste rigoroso de tempo exigido pelas configurações industriais.

Figura 8 – Tipos de monitoramento prescritivo



Fonte: adaptado pela autora 2020

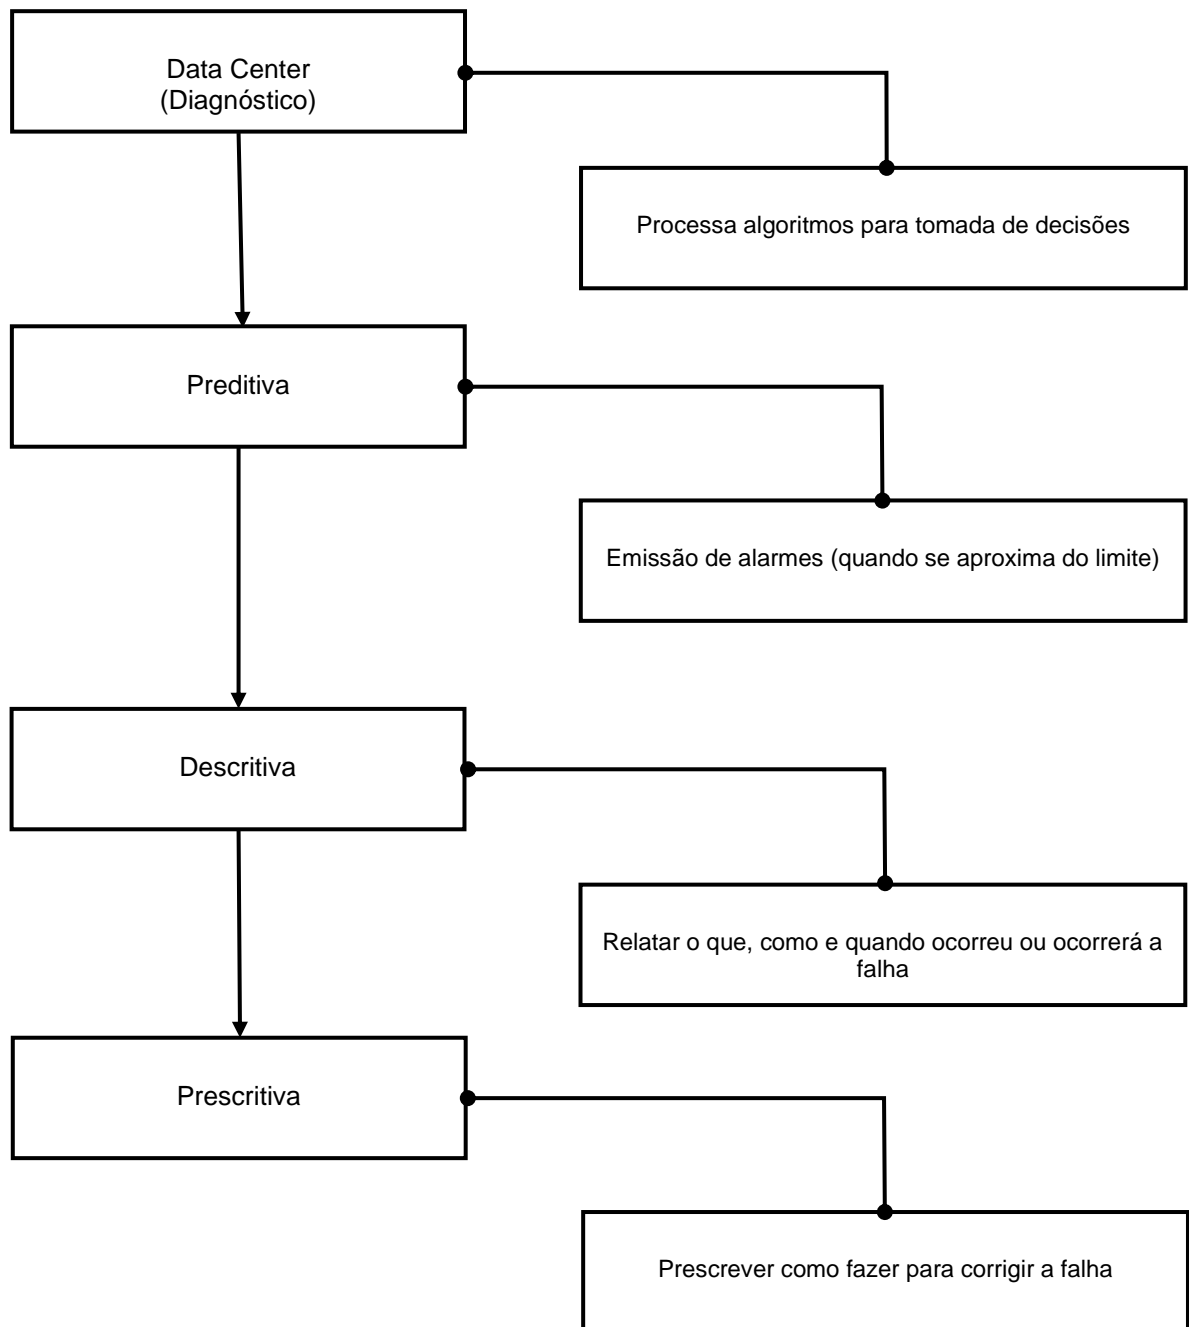
O modelo prescritivo escolhido se baseia em um filtro discreto de Bayes (DBF) (Särkkä, 2013). Essa decisão foi tomada levando em consideração os desafios impostos pelos sistemas de manutenção preditiva no contexto da Indústria 4.0, que são enfrentados pelos DBF's graças às suas capacidades para:

- Permitir integrar perfeitamente dados provenientes de logística, programação e produção, bem como conhecimento de especialistas;
- Manipular naturalmente a incerteza inerente às medições de sensores, transmissão de dados, modelos imprecisos etc., que podem levar a sistemas defeituosos se forem desconsiderados;
- Adaptação rápida de seu comportamento às mudanças na fábrica, ajustando seus parâmetros internos aos novos dados;
- Funcionando em pouco tempo, fornecendo novas informações aos operadores após cada processo realizado na fábrica.

Dados oriundos da política norte americana de manutenção afirmam que 89% das falhas em equipamentos são aleatórias, mesmo com a utilização da manutenção

preventiva, corroborando, Souza, J. B. et al, (2019), esses autores mostram que isso significa que motivos ainda não alcançados pela análise humana continuam causando problemas e quebras de equipamentos. A Figura 9 mostra a ocorrência da evolução das análises que permitem a tomada de decisão no contexto da filosofia prescritiva da manutenção.

Figura 9 – A evolução das análises que permitem a tomada de decisão no contexto da Manutenção Prescritiva



Fonte: adaptado pela autora 2020

Esses mesmos autores afirmam que fazer a gestão prescritiva (modelo prescritivo) é o futuro da manutenção, apesar dos desafios e isso só é possível graças às soluções tecnológicas em ascensão oriundas da Indústria 4.0. Ao contrário da manutenção preventiva, ela não tem como base um cronograma que visa cobrir as falhas mais comuns. Da mesma forma, ela se diferencia da preditiva ao ir além a suas análises.

5 CONSIDERAÇÕES FINAIS E TRABALHOS FUTUROS

Este Trabalho de Conclusão de Curso (TCC) focou nas principais características para implementação da técnica de Manutenção Preditiva (Manutenção 4.0) em uma fábrica do ramo metalúrgica e apresentou os resultados da análise preliminar para implementação da Manutenção Preditiva no contexto dos princípios da Indústria 4.0 (Quarta Revolução Industrial).

Foi mostrado como ocorreram as evoluções da Manutenção Preditiva como política e estratégia nas fábricas. E conseqüentemente, o advento da Indústria 4.0 está levando a fábrica agregar tecnologia de alto nível, portanto fazer a implementação e acompanhar as tendências da Indústria 4.0 pode guiar à fábrica na elaboração de uma infraestrutura eficiente com agregação de valores.

A implementação da estratégia preditiva 4.0 (desenvolvimento de práticas e filosofias cognitiva, inovação, desenvolvimento tecnológico e socioeconômico) descreverão as dinâmicas da indústria na Inovação Tecnológica, perante a Quarta Revolução Industrial (Indústria 4.0) apresentando novos ambientes estratégicos e operacionais.

Para tanto, é proposto um modelo preditivo como parte de um sistema de prognóstico que aproveita as principais tecnologias por trás do paradigma da Indústria 4.0.

Por intermédio das análises dos resultados, infere-se que o tema abordado tem crescido e se tornando de grande relevância para o aparecimento e desenvolvimento de novas e importantes aplicações com o uso de sistemas ciber-físicos para os sistemas de manufatura, conceito este relacionado ao da manufatura digitalizada (inteligente).

O fluxo de trabalho desse sistema é o seguinte: sensores montados no maquinário (Sistemas Ciber-Físicos) produzem dados que são conectados em rede (Internet das Coisas), armazenados e gerenciados (Big Data) para informar os operadores sobre o estado do maquinário (Internet dos Serviços), como foi mostrado na Figura 7.

Por fim, com base na pesquisa, nos resultados atingidos fundamentados na revisão bibliográfica inferimos que os objetivos (geral e específicos) foram alcançados e a pergunta científica foi plenamente respondida.

Outra informação que foi obtida da pesquisa é quanto as vantagens apresentadas pelos princípios da Indústria 4.0 na condução preditiva da manutenção, ou seja, a utilização da estratégia prescritiva da manutenção proporciona excelentes índices de disponibilidade e confiabilidade para a fábrica, com isso gerando impactos positivos, como redução dos custos operacionais, maior produtividade, maior nível de flexibilização do fluxo produtivo, ótima interconectividade do fluxo produtivo com a gestão melhorando a competitividade da fábrica.

Como contribuição recomendamos para os pesquisadores e autores da área trabalhos futuros, empregando uma Revisão Sistemática da literatura para estudar as possibilidades da monitoração preditiva 4.0 para outros setores, conseqüentemente para outras máquinas para determinar se essas conclusões podem ser estendidas a diferentes setores e equipamentos. O monitoramento de máquinas e equipamentos industriais em tempo real resulta em grandes quantidades de dados que não podem ser analisados usando métodos tradicionais. Assim, trabalhos futuros também incluirão o uso de tecnologias de *Big Data* e outras ferramentas oriunda da Indústria 4.0 (Quarta Revolução Industrial).

REFERÊNCIAS

- ABOELMAGED, M. G. Predicting e-readiness at firm-level: An analysis of technological, organizational and environmental (TOE) effects on e-maintenance readiness in manufacturing firms. **International Journal of Information Management**, v. 34, n. 5, p. 639 – 651, 2014.
- ALPAYDIN, E., 2009. **Introduction to Machine Learning**. MIT Press.
- ALQAHTANI, A.Y., GUPTA, S.M., NAKASHIMA, K. Warranty and maintenance analysis of sensor embedded products using internet of things in industry 4.0. **Int. J. Prod. Econ.** v. 208, p. 483 – 499, 2019.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 6023: informação e documentação** – referências – elaboração. Rio de Janeiro, 2002. 24 p.
- ATAÍDE, ANTONIO CARLOS. **Desenvolvimento e aplicação de uma metodologia para avaliação da capacidade dos mordentes de mandris de bobinadeiras de laminadores a frio tipo Sendzimir**. Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Mecânica da Universidade Federal de Minas Gerais. 2011.
- ATZORI, L., IERA, A., MORABITO, G. The internet of things: A survey. **Comput. Netw.**, v. 54, n. 15, p. 2787 – 2805, 2010.
- BAHETI, R., GILL, H. **Cyber-physical systems. The impact of control technology**. v. 12, p. 161 – 166, 2011
- BANERJEE, T. P., & DAS, S. Multi-sensor data fusion using support vector machine for motor fault detection. **Information Sciences**, v. 217, p. 96 – 107, 2012.
- BAPTISTA, M., SANKARARAMAN, S., DE MEDEIROS, I. P., NASCIMENTO, C., PRENDINGER, H., & HENRIQUES, E. M. Forecasting fault events for predictive maintenance using data-driven techniques and ARMA modeling. **Computers & Industrial Engineering**, v.115, p.41 – 53, 2018.
- BLANCO, J.-L., MONROY, J., GONZALEZ-JIMENEZ, J., LILIENTHAL, A. **A kalman filter based approach to probabilistic gas distribution mapping**. In: Proceedings of the 28th Annual ACM Symposium on Applied Computing, p. 217–222, 2013. Disponível em: <<http://mapir.isa.uma.es/mapirwebsite/index.php/mapir-downloads/papers/205>>. Acesso em: 12 fev. 2020.
- BORGI, T., HIDRI, A., NEEF, B., & NACEUR, M. S. Data analytics for predictive maintenance of industrial robots. **International conference on advanced systems and electric technologies (IC_ASET)** p. 412 – 417, 2017.
- COLEMAN, D. C. Industrial growth and industrial revolutions. **Economica**, v.23, n. 89, p. 1 – 22, 1956.
- D. DENYER, D. TRANFIELD. Producing a Systematic Review, **The SAGE Handbook of Organizational Research Methods**, London, p. 671 – 689, 2009.

DONG, Y., XIA, T., FANG, X., ZHANG, Z., & XI, L. Prognostic and health management for adaptive manufacturing systems with online sensors and flexible structures. **Computers & Industrial Engineering**, v. 133, p.57 – 69, 2019.

EUROPEAN COMMISSION. Factories of the Future PPP: Towards Competitive EU Manufacturing. **Research and Innovation**, European Union, 2013. Disponível em: <http://ec.europa.eu/research/press/2013/pdf/ppp/fof_factsheet.pdf> Acesso em: 16 fev. 2020.

EUROPEAN COMMITTEE FOR STANDARDIZATION. **Maintenance - maintenance terminology**. In: 13306 European Standard, 2017.

FATORACHIAN, H., KAZEMI, H. A critical investigation of Industry 4.0 in manufacturing: theoretical operationalisation framework. **Prod. Plann. Cont.**, v.29, n. 8, p.633 – 644, 2018.

FRANK, A., DALENOGARE, L., AYALA, N. Industry 4.0 technologies: implementation patterns in manufacturing companies. **Int. J. Prod. Econ.** v. 210, p.15–26, 2019.

FRANK, A., MENDES, G., AYALA, N., GHEZZI, A., 2019b. **Servitization and Industry 4.0 Convergence in the Digital Transformation of Product Firms: A Business Model Innovation Perspective**. Technological Forecasting and Social Change (forthcoming).

HE, S. G., HE, Z., & WANG, G. A. Online monitoring and fault identification of mean shifts in bivariate processes using decision tree learning techniques. **Journal of Intelligent Manufacturing**, v. 24, n. 1, p. 25 – 34, 2013.

HOLMBERG, K., ADGAR, A., ARNAIZ, A., JANTUNEN, E., MASCOLO, J., & MEKID, S. (Eds.). E-maintenance. **Springer Science & Business Media**, 2010.

JARDINE, A. K., LIN, D., & BANJEVIC, D. A review on machinery diagnostics and prognostics implementing condition-based maintenance. **Mechanical Systems and Signal Processing**, v.20, p.1483 – 1510, 2006.

JI W, WANG L. Big data analytics based fault prediction for shop floor scheduling. **J. Manuf. Syst.**, v.43, p. 187–94, 2017. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0278612517300389>> Acesso em: 20 fev. 2020.

JOSE-RAUL RUIZ-SARMIENTO, JAVIER MONROY, FRANCISCO-ANGEL MORENO, CIPRIANO GALINDO, JOSE-MARIA BONELO, JAVIER GONZALEZ-JIMENEZ. A predictive model for the maintenance of industrial machinery in the context of industry 4.0. **Engineering Applications of Artificial Intelligence**, v. 87, 2020.

KAGERMANN, H., WAHLSTER, W., HELBIG, J. Recommendations for Implementing the Strategic Initiative Industrie 4.0 – Securing the Future of German Manufacturing Industry. **Final report of the industrie 4.0 working group, acatech – National Academy of Science and Engineering**, München, 2013. Disponível em: <http://forschungsunion.de/pdf/industrie_4_0_final_report.pdf> Acesso em: 12 fev. 2020.

- KANG, H.S., LEE, J.Y., CHOI, S., KIM, H., PARK, J.H., SON, J.Y., KIM, B.H., DO NOH, S. Smart manufacturing: Past research, present findings, and future directions. **Int. J. Precis. Eng. Manuf.-Green Technol.**, v. 3, n. 1, p. 111–128, 2016.
- KHAN, M., WU, X., XU, X., DOU, W. Big data challenges and opportunities in the hype of industry 4.0. In: **IEEE International Conference on Communications. ICC**, p. 1 – 6, 2017.
- KHAN, N., YAQOUB, I., HASHEM, I., INAYAT, Z., KAMALELDIN, W., ALAM, M., SHIRAZ, M., GANI, A. **Big data: Survey, technologies, opportunities, and challenges**. 2014, 18.
- LASI, H., FETTKE, P., KEMPER, H.-G., FELD, T., HOFFMANN, M., 2014. Industry 4.0. **Bus. Inf. Syst. Eng.** v. 6, n. 4, p.239–242, 2014.
- LEBOLD, M., REICHARD, K., BYINGTON M. PETTICREW, H. ROBERTS, Systematic Reviews in the Social Sciences: A Practical Guide, **Blackwell**, Oxford, 2006.
- LEE, J., BAGHERI, B., KAO, H., A. A cyber-physical systems architecture for industry 4.0-based manufacturing systems. **Manuf. Lett.** v. 3, p. 18 – 23, 2015.
- LEE, J., LAPIRA, E., YANG, S., KAO, A. Predictive manufacturing system – trends of next-generation production systems. In: **11th IFAC Workshop on Intelligent Manufacturing Systems. IFAC Proc.** v. 46, n. 7, p. 150–156. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1474667015356664>.> Acesso em: 9 fev. 2020.
- LEE, J., WU, F., ZHAO, W., GHAFARI, M., LIAO, L., SIEGEL, D. Prognostics and health management design for rotary machinery systems—reviews, methodology and applications. **Mech. Syst. Signal Process.**, v. 42, n. 1–2, p. 314 – 334, 2014.
- LI, H., PARIKH, D., HE, Q., QIAN, B., LI, Z., FANG, D. Improving rail network velocity: A machine learning approach to predictive maintenance. **Transportation Research Part C: Emerging Technologies**, v. 45, p. 17 – 26, 2014.
- LIAO, Y., DESCHAMPS, F., DE FREITAS ROCHA LOURES, E., RAMOS, L.F.P. Past, present and future of industry 4.0 - a systematic literature review and research agenda proposal. **Int. J. Prod. Res.** v. 55, n. 12, p. 3609–3629, 2017. Disponível em: <<http://dx.doi.org/10.1080/00207543.2017.1308576>. > Acesso em: 10 fev. 2020.
- LU, Y. Industry 4.0: a survey on technologies, applications and open research issues. **Journal of Industrial Information Integration**, v. 6, p. 1 – 10, 2017.
- M. BRETTEL, N. FRIEDERICHSEN, M. KELLER, M. ROSENBERG. How Virtualization, Decentralization and Network Building Change the Manufacturing Landscape: An Industry 4.0 Perspective. **World Acad. Sci. Eng. Technol. Int. J. Mech. Aerospace, Ind. Mechatron. Manuf. Eng.**, v. 8, n. 1, p. 37 – 44, 2014.
- M. PETTICREW, H. ROBERTS, Systematic Reviews in the Social Sciences: A Practical Guide, **Blackwell**, Oxford, 2006.

MITTAL, S., KHAN, M.A., ROMERO, D., WUEST, T. Smart manufacturing: characteristics, technologies and enabling factors. **Proc. IME B J. Eng. Manufact.**, v. 233, n. 5, p. 1342 – 1361, 2019.

MONOSTORI, L. Cyber-physical production systems: roots, expectations and r & d challenges. **Procedia CIRP**, v. 17, p. 9 – 13, 2014.

MOURTZIS D, VLACHOU E. A cloud-based cyber-physical system for adaptive shop-floor scheduling and condition-based maintenance. **J Manuf Syst**, v. 47, p.179–98, 2018. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0278612518300700>.> Acesso em: 3 mar. 2020.

MULLER, A., MARQUEZ, A. C., & IUNG, B. On the concept of e-maintenance: Review and current research. **Reliab. Eng. Syst.**, v. 8, p. 1165 –1187, 2008.

NIKOLIC, B., IGNJATIC, J., SUZIC, N., STEVANOV, B., RIKALOVIC, A. Predictive manufacturing systems in industry 4.0: Trends, benefits and challenges. In: **Proceedings of the 28th DAAAM International Symposium**, p. 796 – 802, 2017.

NORMA **NBR 14,724**: informação e documentação – trabalhos acadêmicos – apresentação. Rio de Janeiro, p. 11, 2011.

O'DONOVAN, P., LEAHY, K., BRUTON, K., O'SULLIVAN, D.T. Big data in manufacturing: a systematic mapping study. **J. Big Data**, v. 2, n. 1, p. 20, 2015.

PETER POOR, JOSEF BASL, DAVID ŽENÍŠEK. Assessing the predictive maintenance readiness of enterprises in West Bohemian region. **Procedia Manufacturing**, v. 42, p. 422 – 428, 2020.

POKORNY, J. Nosql databases: a step to database scalability in web environment. **Int. J. Web Inf. Syst.** v. 9, n. 1, p. 69 – 82, 2013.

PORTER, M., HEPPELMANN, J. How smart, connected products are transforming competition. **Harv. Bus. Rev.** v. 92, n. 11, p. 64 – 88, 2014.

PRAJAPATI, A., BECHTEL, J., GANESAN, S. Condition based maintenance: a survey. **Journal Qual. Maintenance Eng.**, v. 18, n. 4, p. 384 – 400, 2012. Disponível em: <<http://dx.doi.org/10.1108/13552511211281552>.> Acesso em: 10 mar. 2020.

RAUCH, E., LINDER, C., & DALLASEGA, P. Anthropocentric perspective of production before and within Industry 4.0. **Computers & Industrial Engineering**, 2019. Disponível em: <<https://doi.org/10.1016/j.cie.2019.01.018>.> Acesso em: 18 mar. 2020.

REIF, R., JACKSON, S.A., LIVERIS, A. Report To the President Accelerating U.S. Advanced Manufacturing. **The President's Council of Advisors on Science and Technology**, Washington, DC, 2014. Disponível em: <https://www.broadinstitute.org/files/sections/about/PCAST/2014%20amp%20_report_final.pdf.> Acesso em: 12 mar. 2020.

ROGER W., H., RONALD D., S., RICHARD D., D.V. Applying statistical thinking to big data problems. **Wiley Interdiscip. Rev. Comput. Stat.**, v. 6, n. 4, p. 222–232, 2014. Disponível em: <<http://dx.doi.org/10.1002/wics.1306>.> Acesso em: 20 fev. 2020

RUIZ-SARMIENTO, J.R., GALINDO, C., GONZALEZ-JIMENEZ, J. Building multiversal semantic maps for mobile robot operation. **Knowl. Based. Syst.**, v. 119, p. 257–272, 2017. Disponível em: <<http://dx.doi.org/10.1016/j.knosys.2016.12.016>.> Acesso em: 13 fev. 2020

RUSMANN, M., LORENZ, M., GERBERT, P., WALDNER, M., JUSTUS, J., ENGEL, P., HARNISCH, M. Industry 4.0. The Future of Productivity and Growth in Manufacturing Industries. **Boston Consulting Group.**, v. 9, 2015.

SÄRKKÄ, S. Bayesian Filtering and Smoothing. **Cambridge University Press.**, v. 3, 2013.

SEBRAE. Cadeia produtiva da indústria metalúrgica e produtos de metal - Cenários econômicos e estudos setoriais. **SEBRAE**, Recife, 2008.

SELCUK, S. Predictive maintenance, its implementation and latest trends. Proceedings of the Institution of Mechanical Engineers. **Journal of Engineering Manufacture**, v. 231, n. 9, p. 1670 – 1679, 2017.

SOUZA, J. B., SACOMANO, J. B., KYRILLOS, S. L., VAGO, A. T. A função prescritiva da manutenção sincronizada à gestão de ativos. **XXXIX Encontro Nacional de Engenharia de Produção**, 2019.

SREEDHARAN V., R., UNNIKRISHNAN, A., 2017. Moving towards industry 4.0: A systematic review. **Int. J. Prod. Res.**, v. 117, n. 20, p. 929 – 936, 2001.

SUSTO, G. A., MEMBER, S., BEGHI, A., & LUCA, C. D. A predictive maintenance system for epitaxy processes based on filtering and prediction techniques. **IEEE Transactions on Semiconductor Manufacturing**, v. 25, p. 638 – 649, 2012.

SUSTO, G. A., SCHIRRU, A., PAMPURI, S., MCLOONE, S., & BEGHI, A. Machine learning for predictive maintenance: A multiple classifier approach. **IEEE Transactions on Industrial Informatics**, v. 11, p. 812 – 820, 2015.

TIAN, Z. An artificial neural network method for remaining useful life prediction of equipment subject to condition monitoring. **Journal of Intelligent Manufacturing**, v. 23, n. 2, p. 227 – 237, 2012.

WAN, J., CAI, H., ZHOU, K. Industry 4.0: enabling technologies. In: Proceedings of Intelligent Computing and Internet of Things (ICIT). **International Conference on. IEEE**, p. 135 – 140, jan. 2015.

WAN, J., TANG, S., SHU, Z., LI, D., WANG, S., IMRAN, M., VASILAKOS, A.V. Software defined industrial internet of things in the context of industry 4.0. **IEEE Sens. J.**, v. 16, n. 20, p. 7373–7380, 2016. Disponível em: <<http://dx.doi.org/10.1109/JSEN.2016.2565621>.> Acesso em: 12 dez. 2019.

WANG, K. S. Towards zero-defect manufacturing (ZDM)—a data mining approach. **Advances in Manufacturing**, v. 1, n. 1, p. 62 – 74, 2013.

WANG, L., TORNGREN, M., ONORI, M. Current Status and advancement of cyberphysical systems in manufacturing. **J. Manuf. Syst.**, v. 37, p. 517 – 527, 2015.

WEI, G., ZHAO, X., HE, S., & HE, Z. Reliability modeling with condition-based maintenance for binary-state deteriorating systems considering zoned shock effects. **Computers & Industrial Engineering**, v. 130, p. 282 – 297, 2019.

WEYER, S., SCHMITT, M., OHMER, M., GORECKY, D. Towards industry 4.0 – standardization as the crucial challenge for highly modular, multi-vendor production systems. **IFAC Papers Online**, v. 48, p. 579 – 584, 2015.

WUEST, T., WEIMER, D., IRGENS, C., & THOBEN, K.-D. Machine learning in manufacturing: Advantages, challenges, and applications. **Production & Manufacturing Research**, v. 4, p. 23 – 45, jun. 2016.

XIA, F., YANG, L.T., WANG, L., VINEL, A. Internet of things. **Int. J. Commun. Syst.**, v. 25, n. 9, p. 1101, 2012.

XU, L., XU, E., LI, L. Industry 4.0: state of the art and future trends. **Int. J. Prod. Res.**, v. 56, n. 8, p. 2941 – 2962, 2018.

Z. LI, Y. WANG, AND K.-S. WANG. Intelligent predictive maintenance for fault diagnosis and prognosis in machine centers: Industry 4.0 scenario. **Advances in Manufacturing**, v. 5, p. 377 - 387, 2017.

ZHANG, Z., WANG, Y., & WANG, K. Fault diagnosis and prognosis using wavelet packet decomposition, Fourier transform and artificial neural network. **Journal of Intelligent Manufacturing**, v. 24, n. 6, p.1213 – 1227, 2013.