

**UNIVERSIDADE FEDERAL DO AMAZONAS
INSTITUTO DE CIÊNCIAS EXATAS E TECNOLOGIA
CURSO DE ENGENHARIA DE SOFTWARE**

DIOGO MANOEL PEREIRA DOS SANTOS

**MEMP – MÉTODO DE MANUTENÇÃO PREDITIVA APLICADO EM
MÁQUINAS DE SOLDA INDUSTRIAIS**

Itacoatiara – Amazonas
Novembro – 2019

DIOGO MANOEL PEREIRA DOS SANTOS

**MEMP – MÉTODO DE MANUTENÇÃO PREDITIVA APLICADO EM
MÁQUINAS DE SOLDA INDUSTRIAIS**

Monografia apresentada ao Instituto de Ciências Exatas e Tecnologia da Universidade Federal do Amazonas como parte dos requisitos necessários para a obtenção do título de Bacharel em Engenharia de Software.

NOME DO (A) ORIENTADOR (A): Dr. VANDERMI JOÃO DA SILVA

Itacoatiara – Amazonas
Novembro – 2018

Ficha Catalográfica

Ficha catalográfica elaborada automaticamente de acordo com os dados fornecidos pelo(a) autor(a).

S237m Santos, Diogo Manoel Pereira dos
MEMP - Método de manutenção preditiva aplicado em máquinas de solda industriais / Diogo Manoel Pereira dos Santos. 2019
73 f.: il. color; 31 cm.

Orientador: Vandermi João da Silva
TCC de Graduação (Engenharia de Software) - Universidade Federal do Amazonas.

1. Industria 4.0. 2. Internet das coisas. 3. Internet das coisas industriais. 4. manutenção preditiva. I. Silva, Vandermi João da II. Universidade Federal do Amazonas III. Título

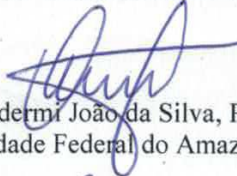
DIOGO MANOEL PEREIRA DOS SANTOS

**MEMP – MÉTODO DE MANUTENÇÃO PREDITIVA APLICADO
EM MÁQUINAS DE SOLDA INDUSTRIAIS**

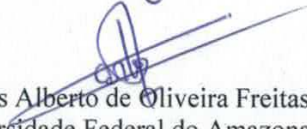
Monografia apresentada ao Instituto de Ciências Exatas e Tecnologia da Universidade Federal do Amazonas como parte dos requisitos necessários para a obtenção do título de Bacharel em Engenharia de Software.

Aprovado em 26 de Novembro de 2019 .

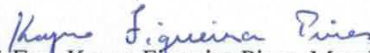
BANCA EXAMINADORA



Prof. Dr. Vanderlei João da Silva, Presidente
Universidade Federal do Amazonas



Prof. Dr. Carlos Alberto de Oliveira Freitas, Membro
Universidade Federal do Amazonas



Prof. Esp. Kayro Figueira Pires, Membro
Universidade do Estado do Amazonas

AGRADECIMENTOS

A Deus o grande criador que oferece o ar que eu respiro e a minha saúde perfeita para suportar as adversidades da vida. Aos meus familiares, especialmente aos meus pais Tereza Lenira de Souza Pereira e Manoel Sebastião Soares dos Santos pelo apoio dado durante este trabalho e por acreditarem em meu potencial. A todos os meus amigos que torcem por mim. Aos meus colegas dos cursos de Engenharia de Software, Sistemas de Informação, Engenharia de Produção e os demais cursos do ICET-UFAM especialmente a turma do laboratório 303 PIXGO e 301 PCTIS, vocês têm meu apreço e consideração. A todos os professores e coordenações acadêmicas por contribuírem direta e indiretamente para minha formação acadêmica. Ao professor Adilson Tavares, pelo apoio dado durante o trabalho. Aos meus amigos e irmãos Manoel Neto, Madson Lemos, Jorge Luiz Almeida, Lucas Farias e Arthur Lima pela ajuda e apoio moral. Ao meu orientador, professor Vandermi João da Silva, por todo suporte durante a vida acadêmica, principalmente pelas cobranças dos artigos científicos, que contribuíram para minha formação acadêmica.

RESUMO

A revolução da indústria 4.0 trouxe um novo paradigma para a esfera industrial, ela integra tecnologias como Sistemas *Cyber* Físicos, Internet das Coisas acrescentado a Internet das Coisas Industriais, dentre outras. Com essa revolução os conceitos de processos na indústria evoluíram, dentre eles a manutenção necessita de atenção especial, pois é por meio dela que a fábrica assegura sua produtividade. Entre os tipos de manutenção existentes, a manutenção preditiva é uma das soluções mais eficientes no cenário da indústria 4.0, já que trabalha com a análise de dados provenientes dos equipamentos para prever falhas e evitar prejuízos. Neste trabalho foi utilizada a técnica de pesquisa Mapeamento Sistemático para identificar os métodos utilizados para implantação da manutenção preditiva na indústria, e no caso deste trabalho, focado no cenário de uma fábrica de televisores em equipamentos de soldas industriais com objetivo de criar uma aplicação para coletar dados em tempo real de uma máquina e criar previsões acerca de possíveis falhas futuras. Neste trabalho é apresentado uma arquitetura que atende aos requisitos de indústria 4.0 e uma aplicação que possua uma taxa de acerto relevante para que possa agregar valor à fábrica.

Palavras-Chave: Indústria 4.0. Internet das Coisas. Internet das Coisas Industriais. Manutenção Preditiva.

LISTA DE TABELAS

Tabela 1 Expressão de Busca para Identificar Publicações.....	17
Tabela 2 Configurações para o Ping.....	18
Tabela 3 Configurações para Tracert.....	19
Tabela 4 Configurações para Route.....	19
Tabela 5 Configurações para Netstat.....	19
Tabela 6 Parâmetros dos Experimentos.....	42
Tabela 7 Comparativo entre os trabalhos relacionados.....	44
Tabela 8 Artigos encontrados na busca preliminar.....	46
Tabela 9 Artigos selecionados pela leitura do título.....	46
Tabela 10 Artigos selecionados no primeiro filtro.....	47
Tabela 11 Artigos selecionados no segundo filtro.....	47
Tabela 12 Artigos selecionados no terceiro filtro.....	47
Tabela 13 Métodos de implementação para manutenção preditiva.....	49
Tabela 14 Parâmetros da Máquina de Solda.....	50
Tabela 15 Métodos de Análise de Dados.....	54
Tabela 16 - Algoritmos utilizados nos Testes.....	54
Tabela 17 - Resultados dos Testes nos Modelos de Árvore (50% -50%).....	60
Tabela 18 - Resultados dos Testes nos Modelos de Árvore (70% -30%).....	60
Tabela 19 - Resultados dos Testes nos Modelos de Árvore (80% -20%).....	60
Tabela 20 - Porcentagem de Acerto dos Splits.....	60
Tabela 21 - Resultados Percentagem Split 70% - 30%.....	61
Tabela 22 - Resultados dos Testes nos Modelos de NaiveBayes (50% -50%).....	62
Tabela 23 - Resultados dos Testes nos Modelos de NaiveBayes (70% -30%).....	62
Tabela 24 - Resultados dos Testes nos Modelos de NaiveBayes (80% -20%).....	62
Tabela 25 - Resultados dos Testes de Split com Classificação Bayesiana.....	62
Tabela 26 - Comparação entre os melhores algoritmos.....	63
Tabela 27 - Análise Comparativa.....	64

LISTA DE FIGURAS

Figura 1 Fluxograma do Método Adotado	16
Figura 2 Arquitetura genérica da IOT	21
Figura 3 Arquitetura IIOT	23
Figura 4 Visão Geral CPS	24
Figura 5 Evoluções da Indústria	25
Figura 6 Composição de uma Linha de Montagem SMT	27
Figura 7 - Arquitetura da Aplicação	30
Figura 8 - Diagrama do Gerador de Modelos Preditivos.....	30
Figura 9 - Agente de Monitoramento	31
Figura 10 - Interface da Aplicação	31
Figura 11 - Testes da aplicação nas turbinas	32
Figura 12 - Fases da metodologia CRISP-DM.....	33
Figura 13 - Modelo de descoberta de conhecimento.....	34
Figura 14 - Gráfico de dispersão de falhas	35
Figura 15 - Arquitetura de um CPA	36
Figura 16 - Arquitetura do Sistema	37
Figura 17 - Interface da aplicação	37
Figura 18 - Arquitetura de centros de usinagem.....	38
Figura 19 - Modelo para manutenção preditiva em centros de maquinas	39
Figura 20 - Resultados dos testes teóricos.....	40
Figura 21 - Arquitetura da aplicação	41
Figura 22 - Modelo de peça.....	42
Figura 23 Experimento 1	42
Figura 24 Experimento 2	43
Figura 25 Experimento 3	43
Figura 26 Arquitetura proposta para a aplicação.....	45
Figura 27 Quantidade de artigos selecionados em cada base.....	48
Figura 28 Artigos selecionados no final do processo.....	48
Figura 29 Ficha de Manutenção	50
Figura 30 Arquitetura do Módulo Controlador	51
Figura 31 Conexão I2C Raspberry e Arduino Uno	52
Figura 32 Instalação dos Sensores na Máquina de Solda.....	55
Figura 34 - PING.....	57
Figura 35 - TRACERT	57
Figura 36 - ROUTE	57
Figura 37 - NETSTAT.....	57
Figura 38 - Arquivo Arff Base de Dados	58
Figura 39 - Interface Inicial da Ferramenta de Mineração	59
Figura 40 - Gráfico de ROC 70% - 30%	61
Figura 41 Gráfico de ROC dos melhores algoritmos 70% - 30%	64
Figura 42 - Nível 1 Árvore Binária	65
Figura 43 - Nível 2 Árvore Binária	65
Figura 44 - Nível 3 Árvore Binária	65
Figura 45 - Pseudocódigo gerado pelo WEKA	66
Figura 46 - Tela de Login	67
Figura 47 - Dashboard	67
Figura 48 - Informações da Máquina	68
Figura 49 - Notificações	69

LISTA DE ABREVIATURAS E SIGLAS

CPS	Sistemas cyber Físicos (<i>Cyber Físical System</i>)
IIoT	Internet das Coisas Industriais (<i>Internet of Industrial Things</i>)
IoT	Internet das Coisas (<i>Internet of Things</i>)
MS	Mapeamento Sistemático
SMT	Tecnologia de Montagem em Superfície (<i>Surface Mount Technology</i>)

SUMÁRIO

1	INTRODUÇÃO.....	11
1.1	Contextualização	11
1.2	Justificativa.....	14
1.3	Objetivos.....	15
1.4	Metodologia.....	15
1.5	Organização do Projeto	20
2	FUNDAMENTAÇÃO TEÓRICA	21
2.1	Conceitos Relacionados.....	21
2.1.1	Internet das Coisas.....	21
2.1.2	Internet das Coisas Industriais	22
2.1.3	Sistemas <i>cyber</i> Físicos.....	23
2.1.4	Indústria 4.0	25
2.1.5	Surface Mount Technology (SMT)	26
2.1.6	Manutenção Preditiva	28
2.2	Trabalhos Relacionados.....	29
2.2.1	Canizo, Onieva, Conde, Charramendieta e Trujilo (2017).....	29
2.2.2	Spendla, Kebisek, Tanuska e Hrcka (2017)	32
2.2.3	Chiu, Cheng e Huang (2017).....	36
2.2.4	Li, Wang e Wang (2017)	38
2.2.5	Sezer, Romero, Macchi, Milano e Emmanouilidis (2018).....	41
2.2.6	Contribuições dos trabalhos para a monografia	44
3	RESULTADOS E DISCUSSÕES.....	45
3.1	Definições da Arquitetura.....	45
3.2	Resultados do Mapeamento Sistemático	46
3.2	Modelo de Análise.....	49
3.3	Configuração do Ambiente de Testes.....	54
3.4	Testes de Comunicação	56
3.6	Testes na Ferramenta de Mineração	58
3.7	Telas do Sistema.....	66
4	CONCLUSÃO E PERSPECTIVAS FUTURAS.....	70
4.1	Considerações Finais	70
4.2	Limitações	70
4.3	Trabalhos Futuros	70
	REFERÊNCIAS	71

1 INTRODUÇÃO

Neste capítulo serão abordados os assuntos a serem tratados durante o desenvolvimento do trabalho, incluindo conceitos, objetivos, justificativa, metodologia e cronograma de desenvolvimento com objetivo de inserir o leitor ao contexto do trabalho.

1.1 Contextualização

Com o surgimento da internet na década de 90, a evolução tecnológica foi exponencial. Ao longo dos anos os dispositivos foram ganhando maior capacidade de processamento e as mais diversas funcionalidades, oferecendo praticidade e conforto para os usuários. Exemplos desses dispositivos são sensores, *smartphones*, carros, eletrodomésticos, sistemas de saúde dentre outros, fazendo com que tanto seres humanos quanto dispositivos estejam cada vez mais sendo conectados na internet (BELLO, 2016).

Segundo a Firjan (2016) a previsão é que cerca de 100 bilhões de dispositivos estarão conectados na internet até 2020, esta grande quantidade de dados impulsionam a indústria na tomada de decisões, melhoria dos produtos e aperfeiçoamento dos processos tornando-se uma grande rede de dispositivos e produtos integrados gerando informação valiosa para o setor industrial.

Para McAfee (2012), com o tratamento das grandes massas de dados os gerentes podem conhecer seus negócios profundamente, prever tendências do mercado e realizar tomadas de decisões com base no desempenho e *feedback* dos usuários. Essa revolução se tornou possível devido ao avanço das tecnologias de sistemas embarcados que atualmente podem ser encontrados nos objetos mais comuns do dia a dia.

Muitos desses sistemas embarcados como os *smarthphones* e eletrodomésticos já se tornaram parte do cotidiano das pessoas, porém é possível controlar apenas uma pequena parte dessa gama de equipamentos e controlar máquinas de qualquer lugar é um objetivo a ser alcançado, pois o acesso remoto aumenta a eficiência e pode até mesmo ser utilizado para manutenção autossuficiente dos equipamentos (JAZDI, 2014).

A evolução dos sistemas embarcados propiciou também o surgimento do termo Internet das Coisas do termo em inglês *Internet of Things* (IoT), entendida como uma rede de objetos físicos, sistemas e plataformas que se comunicam e interagem entre si, com ambientes internos e externos gerando um grande volume de dados e comandos para controle de coisas

conectadas na rede (FIRJAN, 2016). Segundo Tsai *et al* (2014), as empresas começaram a introduzir produtos e serviços baseados em IoT e a previsão de crescimento de valor no mercado é de US\$ 7,1 trilhões até 2020.

O impacto das tecnologias IoT não se limita ao indivíduo conectado aos produtos, as funções do produto são aperfeiçoadas e incorporadas em sistemas de objetos que por sua vez podem ser incorporados em uma plataforma interligando diferentes sistemas, e assim, expandindo os limites da indústria e revolucionando a dinâmica competitiva do mercado (PORTER e HEPPELMANN, 2014).

A integração de sistemas embarcados conectados e interagindo no mundo da IoT dá origem ao conceito de Sistemas *Cyber* Físicos do inglês *Cyber Physical System* (CPS). Os CPS são sistemas que interagem entre si e elevam os limites do mundo físico por meio da computação, comunicação e controle, tornando-se a chave para o desenvolvimento de futuras tecnologias (JAZDI, 2014).

Segundo Drath (2014), um CPS pode ser entendido em três níveis:

- Infraestrutura de sistemas de produção acessível à população, podendo ser inserida em qualquer lugar.
- Dispositivos do campo, máquinas e mesmo fábricas conectadas e enviando dados em tempo real através da IoT. Tornando seus dados disponíveis para análise em qualquer lugar do mundo.
- Dispositivos conectados nas redes possuirão então sua representação virtual que pode ser atualizada em tempo real, formando uma base conhecimento para várias aplicações.

Apesar de um CPS aparentar ser necessariamente complexo, estes devem ser tão fáceis de usar quanto possível, usando dispositivos intuitivos como *smartphones*, *tablets* dentre outros (CRISTALLI *et al.*, 2016). As evoluções dos CPS's juntamente com outras tecnologias formam a base para a indústria 4.0 que vem se tornando uma revolução não apenas na esfera industrial, mas no cotidiano das pessoas.

O termo “Indústria 4.0” ou fábrica inteligente ficou conhecido em 2011 por meio de uma iniciativa de representantes de empresas, políticos e acadêmicos, sendo promovida como uma abordagem para o aumento da competitividade do mercado de manufatura alemão (HERMANN *et al.*, 2016). O contexto de indústria 4.0 pode ser entendido como um conjunto de sistemas, sensores, máquinas e equipamentos capazes de se comunicar por meio de protocolos da IoT, enviando e analisando dados recebidos com o objetivo de prever falhas e adaptar-se a mudanças automaticamente. Esse cenário proporciona o aumento da

produtividade, eficiência dos processos, redução de custos e conseqüentemente competitividade entre as empresas e as regiões (RUBMANN *et al.*, 2015).

O crescimento das fábricas inteligentes aliados à evolução dos CPS trouxeram grandes benefícios para os sistemas industriais. Trnka (2014) afirma que a tendência das empresas na Indústria 4.0 é utilizar os conceitos de *Big Data* e IoT para utilizar as técnicas de manutenção preditiva na previsão de falhas em equipamentos industriais.

A manutenção preditiva pode utilizar as grandes massas de dados para prever falhas e agendar manutenções em máquinas industriais, porém a manipulação dessas informações apresentam desafios tanto técnicos quanto organizacionais (FERREIRA *et al.*, 2017).

Para Henriques (2014), a previsão antecipada impede que falhas se tornem prejuízos financeiros para as empresas além de reduzir custos com manutenção e aumentar a vida útil das máquinas industriais. Nos últimos anos houve um crescimento da indústria moderna a respeito do monitoramento das condições e diagnósticos de falhas (ZHAO, 2014).

A manutenção preditiva utiliza operações reais, condições de equipamentos, bases de dados e sistemas para agendar todos os processos de manutenção, aumentando a disponibilidade das máquinas e a qualidade de produção. Grandes empresas de manufatura estão atualmente analisando grandes quantidades de dados em níveis hierárquicos mais altos que os processos de fabricação formando assim um cenário ideal para a implementação da manutenção preditiva (SPENDLA *et al.*, 2017).

Apesar de um cenário favorável estar se formando, a problemática sobre a implantação da manutenção preditiva ainda é um desafio devido aos métodos de comunicação, meios de transporte e aplicações de controle estar em fase de desenvolvimento inicial. A análise do contexto atual e das previsões dos estudos na área de Indústria 4.0 e manutenção preditiva demonstram que à demanda das indústrias por aplicações que possam aliar sistemas de equipamentos industriais aos métodos de manutenção preditiva, com o propósito de melhorar os processos e aumentar a produtividade no ambiente de fábricas inteligentes.

Neste contexto este trabalho desenvolveu uma aplicação inteligente baseada no método de manutenção preditiva aplicada em máquinas de solda industriais, utilizando os conceitos de Indústria 4.0, CPS e análise de dados, dentro de um cenário real de operações em uma fábrica de televisores.

1.2 Justificativa

Com avanço das tecnologias de sistemas embarcados e a propagação da internet, a indústria atual tem agora a missão de manter seus sistemas críticos, aplicações e equipamentos disponíveis e seguros para garantir a qualidade esperada de seus produtos. Nesse cenário, a manutenção preditiva está se tornando essencial para reduzir os custos com a paralização e produtos defeituosos (SUSTO *et al*, 2015).

Segundo a MarketsandMarkets (2017), a manutenção preditiva terá um aumento global de U\$ 1.404,3 milhões em 2016 para um tamanho de U\$ 4.904,0 milhões em 2021, uma taxa de crescimento anual de cerca de 28,4%. Este crescimento é possível graças ao desenvolvimento da IoT, onde dispositivos permitem a detecção e transmissão de grandes fluxos de dados em tempo real, aumentando a precisão dos sistemas de manutenção preditiva. Globalmente, pode-se observar a crescente adoção das tecnologias digitais nas indústrias de manufatura, conceituada de Indústria 4.0 (REISCHAUER, 2018).

A indústria 4.0 é impulsionada pela (IoT) e pela internet das coisas industriais (IIoT), com a fabricação inteligente baseada em nuvem tornando o processo totalmente digitalizado com máquinas controladas e unidades de produção autônomas e ininterruptas (VAIDYAA *et al*, 2018). De acordo com Sondagem Especial (2016), o sensoriamento de máquinas e produtos torna a linha de produção flexível, possibilitando a customização de produtos e aumentando a competitividade da organização.

Devido à sua popularidade na indústria, diversos dos métodos de manutenção preditiva estão sendo investigados pelos acadêmicos, um deles é modelo de controle preditivo robusto que é amplamente estudado na literatura. No entanto, devido às dificuldades envolvidas na manutenção e operação desses sistemas extremamente grandes, eles são geralmente divididos em subsistemas menores instalados em subprocessos do processo original. Esta abordagem é promissora, mas até agora poucas aplicações foram relatadas (MESBAH *et al*, 2014).

A manutenção preditiva tem o potencial de manter o desempenho dos equipamentos enquanto satisfaz as condições de funcionamento dos sistemas industriais na maioria das ocasiões. Porém, ainda é uma ideia recente que ainda não foi tentada em aplicações comerciais. Essas áreas emergentes oferecem novas oportunidades para melhorar o desempenho, robustez e confiabilidade de sistemas industriais (FORBES *et al*, 2016).

Portanto, apesar da tendência do mercado ser favorável ainda a poucas aplicações disponíveis e, é desejável que novas aplicações baseadas em manutenção preditiva sejam criadas e adaptadas em sistemas industriais.

1.3 Objetivos

- **Geral**

Desenvolver um sistema de manutenção preditiva baseado na Indústria 4.0 que atenda ao processo de *Surface Mount Technology* de uma fábrica de televisores.

- **Específicos**

- Realizar uma revisão sistemática dentro da literatura para identificar os principais trabalhos publicados na área de manutenção preditiva em setores industriais.
- Implementar uma aplicação inteligente baseada no método de manutenção preditiva aplicada no contexto de uma fábrica de televisores.
- Realizar testes de comunicação e testes de desempenho da aplicação embarcada para identificar a viabilidade da implantação do projeto dentro de um ambiente industrial.

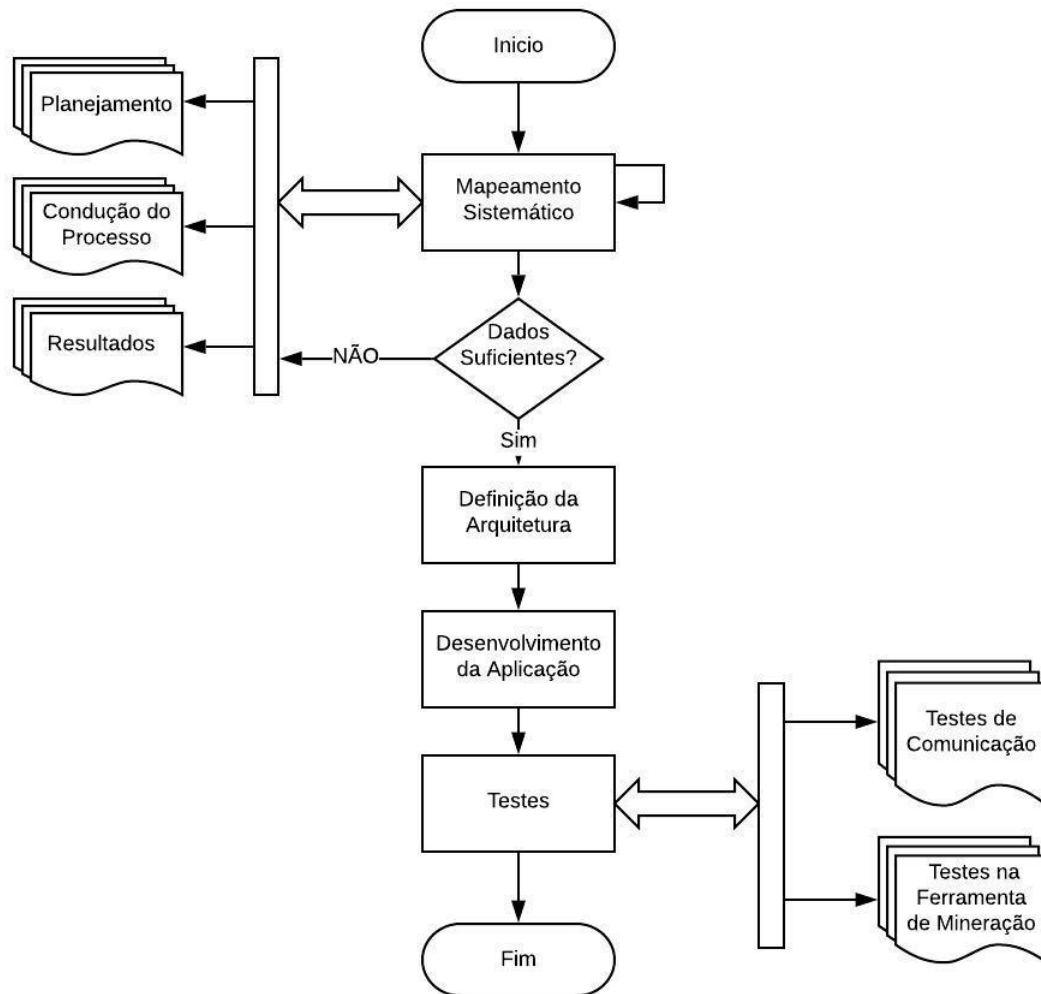
1.4 Metodologia

A metodologia de pesquisa adotada neste trabalho se baseia na condução de um estudo secundário: Mapeamento Sistemático (MS). O MS fornece uma visão geral de uma área de pesquisa, identificando a quantidade, os tipos de pesquisas realizadas, os resultados disponíveis, além das frequências de publicações ao longo do tempo para identificar tendências (PETERSEN *et al.*, 2008).

Kitchenham e Charters (2009), afirmam que estudos de MS em engenharia de software têm sido recomendados, sobretudo em áreas de pesquisa onde é difícil visualizar a gama de materiais relevantes e de alta qualidade que possam estar disponíveis. MS é um método formal e que necessita de planejamento. O MS inicia com a pesquisa preliminar a fim de encontrar trabalhos relevantes para fundamentar o mapeamento da bibliografia, é um meio confiável para se iniciar uma pesquisa científica por meio de um processo de investigação rigoroso (MALCHER *et al.*, 2015).

Assim sendo, a escolha do MS como proposta para a condução desta pesquisa justifica-se pelo fato do objetivo da pesquisa ser identificar e utilizar os resultados obtidos para desenvolvimento da aplicação e, nesse âmbito a confiabilidade dos dados gerados é garantida pela rigidez deste método de pesquisa. A Figura 1 descreve as quatro etapas executadas no trabalho.

Figura 1 Fluxograma do Método Adotado



Fonte: O autor (2019).

Primeira etapa: revisão sistemática, que se deu nos meses de agosto até outubro de 2018. O MS foi dividido em três fases:

1. **Planejamento:** nesta fase foram definidos os objetivos e também o protocolo do mapeamento. O objetivo do MS foi definido da seguinte forma:
 - Identificar as técnicas, aplicações e ferramentas utilizadas para manutenção preditiva em máquinas industriais aplicando conceitos de Indústria 4.0.

A partir da definição do objetivo, foi criada a questão de pesquisa: **QP:** Quais as técnicas utilizadas para implementar manutenção preditiva no contexto da Indústria 4.0?. Os locais de busca definidos foram às bibliotecas digitais IEEE, *SPRINGERLINKER* e ACM, sendo que os trabalhos foram coletados a partir da busca automática por meio de investigação

nas bibliotecas onde foram considerados somente os artigos científicos de publicações recentes dentre os anos de 2010 a 2018.

Os idiomas escolhidos foram o Inglês e Português. A busca foi restringida usando palavras-chave específicas para encontrar as publicações de interesse. A expressão de busca foi definida de acordo com dois dos quatro aspectos indicados em (Peterson *et al*, 2008): População e Intervenção, conforme a Tabela 1.

Tabela 1 Expressão de Busca para Identificar Publicações

<p>Para investigação por expressão de busca (nos idiomas Inglês e Português):</p> <p>População: publicações que fazem referências a aplicações IIOT ou IOT em ambientes Industriais (e sinônimos) com Manutenção Preditiva:</p> <p><i>Palavras-chave:</i> “IIoT” OR “Smart Factory” OR “Predictive Maintenance” OR “IIoT And Smart Factory” OR “Predictive Maintenance with IIoT”, “Internet das Coisas”, “Manutenção Preditiva”, “Fábricas Inteligentes”, “Internet das Coisas Industriais”.</p> <p>Intervenção: publicações que fazem referências a ferramentas desenvolvidas com IIoT e manutenção preditiva para ambientes industriais (e sinônimos)</p> <p><i>Palavras-chave:</i> “IIoT” OR “Internet of Industrial Things” OR “Tool” OR “Product” OR “Development” OR “Application”, “Ferramentas”, “Aplicações”, “Produto”.</p>
--

Fonte: O autor (2018)

Esta pesquisa se restringe à análise de publicações disponíveis até a data presente da execução do estudo. A seleção das publicações foi realizada em quatro etapas:

Na primeira etapa temos a busca preliminar das publicações coletadas nas bibliotecas digitais, por conseguinte na segunda etapa aplicou-se o Primeiro Filtro de Seleção por meio da análise do título, o resumo e as palavras-chave e aplicando o critério de seleção “CS1: possuir informações sobre aplicações de manutenção com IIoT em ambientes Industriais”.

Na terceira etapa utilizou-se o Segundo Filtro de Seleção por meio da leitura completa das publicações e aplicando o critério de seleção “CS2: possuir aplicações de manutenção com IIoT baseado em manutenção preditiva”.

Por fim através da leitura completa das publicações restantes após o CS2 aplicando o critério de seleção “CS3: possuir informações sobre testes das aplicações de manutenção preditiva em cenários de Indústria 4.0”.

2. **Condução do processo:** é a fase em que foi realizado o processo de buscas nas bases e os critérios de seleção são aplicados de acordo com o protocolo criado durante a primeira fase;
3. **Resultados:** na terceira fase é realizada a extração dos dados a serem utilizados. Para encontrar artigos relevantes, as buscas se deram em bases de bibliotecas digitais. O **Capítulo 3** apresentará mais detalhes sobre os resultados encontrados durante o MS.

Na segunda etapa foi desenvolvida uma arquitetura que melhor se adaptasse ao cenário estudado e ao conceito de indústria 4.0, levando em consideração os artigos selecionados durante o MS. Na terceira etapa será desenvolvida uma aplicação inteligente baseada no método de manutenção preditiva aplicando os conceitos de indústria 4.0, esta aplicação estará adaptada a um cenário de um fábrica de televisores com o objetivo de prever falhas em máquinas de solda industriais da linha de produção, assim como permitir o controle e gerenciamento a distância dos equipamentos por meio de dispositivos móveis.

Quarta etapa: nesta etapa serão realizados os testes utilizando métricas a fim de verificar desempenho do método de análise e a comunicação dos dispositivos da aplicação dentro de um cenário industrial e assim, avaliar a viabilidade da implantação do projeto dentro de uma fábrica.

Para avaliar a qualidade de comunicação serão utilizados neste projeto os testes Ping, Tracert, Route e Netstat segundo as recomendações de Carmona (2006) estão descritos na Tabela 2, Tabela 3, Tabela 4, e Tabela 5 respectivamente:

Tabela 2 Configurações para o Ping

PING
<p>Esse comando de diagnóstico verifica as conexões para um ou mais computadores remotos. Sintaxe: ping [-t] [a] [-n num] [-I tamanho] [-f] [-i tti] [-w tempo de resposta] endereço de destino</p> <ul style="list-style-type: none"> -t – Utiliza o ping no host especificado até ser interrompido. -a – Resolve os endereços dos nomes de host. -n num – Envia o número de pacotes ECHO especificado por num. O padrão é de 64 bytes. -I tamanho – Envia o pacote ECHO especificado por num. O padrão é de 64 bytes. -f – Envia o flag DO NOT. -i Define o Tempo máximo de vida do pacote IP. -w – Define o número do tempo de espera endereço de destino – Endereço IP para teste.

Fonte: O autor (2018).

Tabela 3 Configurações para Tracert

TRACERT
<p>Este utilitário de diagnóstico determina a rota tomada para um destino enviando pacotes de echo Protocolo de Controles de Mensagens da Internet (ICMP) com vários valores TTL para o destino. Sintaxe:</p> <p>tracert [-d] [-h saltos máximos] [-w tempo de resposta] endereço IP remoto</p> <ul style="list-style-type: none"> -d – Especifica os endereços não resolvidos para os nomes do host. -h saltos máximos – Especifica o número máximo de saltos a pesquisar até o destino. -w tempo de resposta – Espera o número de milissegundos especificado pelo tempo para cada resposta. <p>Endereço IP remoto – Nome do host de destino.</p>

Fonte: O autor (2018).

Tabela 4 Configurações para Route

ROUTE
<p>Esse comando de diagnóstico manipula as tabelas de roteamento de rede.</p> <p>Sintaxe: route [-f] [-p] comando [destino] [MASK máscara] [gateway] [METRIC metric]</p> <ul style="list-style-type: none"> -f – Limpa as tabelas de roteamento de todas as entradas de gateway. -p – Quando usado com o comando route add, cria uma rota persistente através das reinicializações do computador. <p>Comando – Especifica um dos quatro comandos.</p>

Fonte: O autor (2018).

Tabela 5 Configurações para Netstat

NETSTAT
<p>Este comando de diagnóstico exibe as mensagens do protocolo e as conexões da rede TCP/IP atuais.</p> <p>Sintaxe: netstat [-a] [-e] [-n] [-s] [-p protocolo] [-r] [intervalo]</p> <ul style="list-style-type: none"> -a – Exibe todas as conexões e portas de escuta, as conexões do servidor normalmente não são mostradas. -e – exibe as estatísticas Ethernet. -n – Exibe endereços e números de portas em forma numérica. -s – Exibe as estatísticas por protocolo. Por padrão, as estatísticas são mostradas para TCP, UDP, ICMP e IP. -p – Mostra as conexões para o protocolo especificado por protocolo; pode ser tcp ou udp. -r – Exibe o conteúdo da tabela de roteamento. <p>Intervalo – Reexibe as estatísticas selecionadas, fazendo uma pausa de intervalos de segundos entre cada exibição.</p>

Fonte: O autor (2018).

Os testes de desempenho serão descritos no **capítulo 3**, após a realização dos testes de desempenho e comunicação, o sistema será disponibilizado no cenário real de uma fábrica de televisores com as mesmas medições dos testes iniciais.

1.5 Organização do Projeto

O presente trabalho foi dividido em 4 capítulos e está organizado da seguinte forma:

O Capítulo 1, “Introdução”: expõe os principais aspectos deste trabalho, descrevendo seu contexto, justificativa, objetivos, metodologia adotada e a organização do trabalho.

O Capítulo 2, “Fundamentação Teórica”: apresenta os principais assuntos relevantes para esta pesquisa como: os conceitos relacionados à Indústria 4.0, Internet das Coisas, Manutenção preditiva, Internet das Coisas Industriais, *Surface Mount Technology*, Sistemas *Cyber* Físicos, e os trabalhos relacionados. Apresenta as tecnologias adotadas e os trabalhos desenvolvidos com aplicações na área de manutenção preditiva.

O Capítulo 3, “Resultados e Discussões”: apresenta os resultados encontrados pelo MS, a apresentação da arquitetura proposta, configurações do ambiente e resultados dos testes na aplicação e descrição do fluxo das telas desenvolvidas durante o projeto.

O Capítulo 4, “Conclusão e Perspectivas Futuras”: apresenta a conclusão do trabalho, descrevendo as considerações finais, limitações encontradas e trabalhos futuros da monografia.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo serão abordados os conceitos mais importantes que foram utilizados durante a pesquisa e os trabalhos relacionados que possuem contribuições, propostas ou resultados que possam ser adaptados ou servir de base para o desenvolvimento do trabalho em questão.

2.1 Conceitos Relacionados

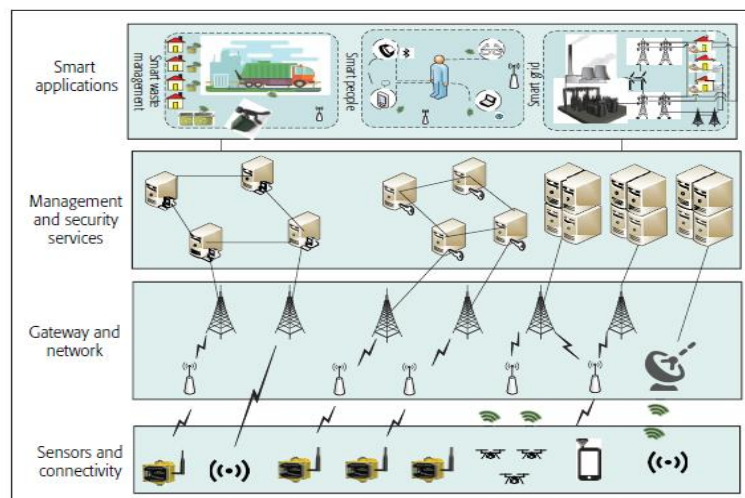
2.1.1 Internet das Coisas

A Internet das Coisas do termo em inglês *Internet of Things* (IoT) pode ser entendida como a conexão entre humanos, computadores e coisas. Todos os equipamentos são usados no nosso dia a dia podem ser controlados e monitorados usando essa tecnologia. A maior parte do processo é feito com o ajuda de sensores implantados em todos os lugares capturando e convertendo dados físicos brutos em sinais digitais e transmitindo ao seu centro de controle. (SURESH *et al*, 2014).

Para Kang *et al* (2016) a IoT pode ser definida como uma rede ampla que integra software, sensores, dispositivos de rádio frequência e coisas embutidas ou objetos físicos, permitindo que esses dispositivos sejam controlados por meio de infraestrutura de rede.

Em Yaqoob *et al* (2017) define a arquitetura genérica da IoT em três camadas principais, de acordo com a Figura 2 são elas:

Figura 2 Arquitetura genérica da IOT



Fonte: Yakoob (2017).

A arquitetura consiste nas camadas de aplicação, transporte e detecção. Sendo a camada de aplicação responsável por interagir com o usuário e aplicar técnicas de computação inteligente (mineração de dados, computação em nuvem, dentre outros), por sua vez a camada de transporte lida com as operações de rede e pôr fim a camada de sensores é responsável pela coleta de informações.

Segundo a Firjan (2016), a grande quantidade de dados gerados impulsiona a indústria na tomada de decisões, melhoria dos produtos e aperfeiçoamento dos processos. Com isso os mais diversos dispositivos estão sendo inseridos em objetos com o objetivo de coletar informações para melhorar produtos e processos, essas informações podem ser utilizadas pelas empresas para garantir uma melhor experiência do usuário.

2.1.2 Internet das Coisas Industriais

O conceito de Internet das Coisas Industriais do termo em inglês *Internet of Industrial Things* (IIoT) é uma das bases para a indústria 4.0, sua capacidade de integrar, obter informações e encaminhar com segurança dados de sensores continuamente para sistemas de computação em nuvem permite diversas aplicações nos setores da indústria. (WAN *et al*, 2016).

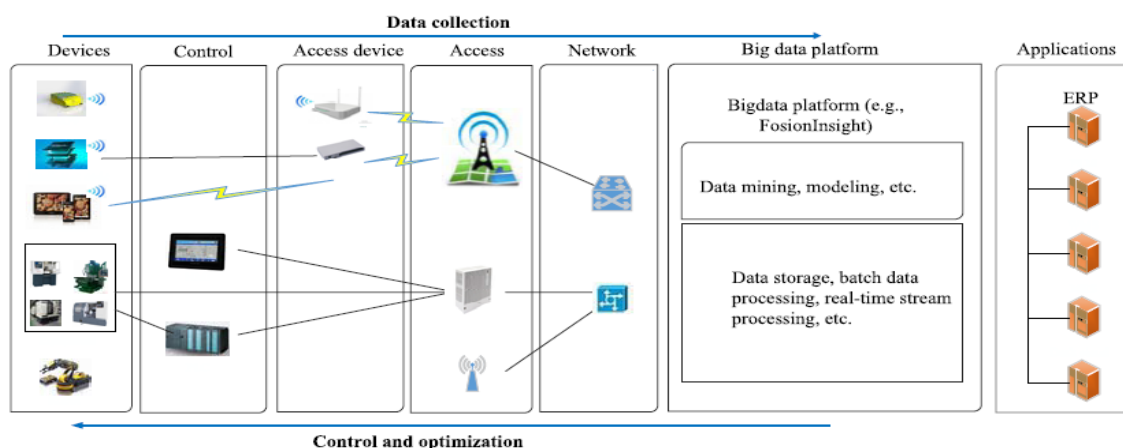
O objetivo da IIoT é que o processo de produção tenha a capacidade de se reconfigurar dinamicamente e remotamente, um sistema de manufatura com custo e tempo de inatividade mínimo, e ao mesmo tempo fornecer a máxima diversidade de produtos para os consumidores, permitindo que o consumidor em qualquer lugar consiga o produto que deseja. (PACKWOOD *et al*, 2015).

Para Wan (2016), a utilização da IIoT na indústria 4.0 ainda enfrenta desafios, dentre eles:

- Na Indústria 4.0 os dispositivos de uma fábrica estarão todos conectados. Portanto é necessário redefinir os protocolos de comunicação destes dispositivos um a um.
- Ainda é desafiador analisar a informação gerada por dispositivos heterogêneos de uma forma homogênea devido à falta de padronização nos dados.

A Figura 3 descreve a arquitetura geral da abordagem IIoT:

Figura 3 Arquitetura IIOT



Fonte: Wan (2016).

Na arquitetura acima é demonstrado que no cenário IIoT estarão interligados os mais diversos dispositivos. Esses equipamentos estarão constantemente enviando e recebendo dados, gerando uma plataforma de *Big Data* na qual serão aplicados algoritmos de processamento, mineração de dados, dentre outros. Por fim as aplicações industriais serão adaptadas a partir dos resultados da análise dos algoritmos criando fábricas personalizadas, baseadas nas informações do cliente, ou seja, mais eficientes e produtivas.

O crescimento da IIoT esperado nos EUA é de \$ 151,01 bilhões até 2020, uma taxa de crescimento anual composto de 8,03% entre 2015 e 2020. Essa evolução popularizará o monitoramento contínuo de condições e a manutenção preditiva com o decorrer dos anos (SHETTY, 2018).

2.1.3 Sistemas *cyber* Físicos

Sistemas *cyber* Físicos do inglês *Cyber Physical Systems* (CPS) podem ser entendidos como sistemas automatizados que possibilitam a conexão entre a realidade física e as infraestruturas de computação e comunicação. O foco dos CPS está na criação de uma rede de diversos dispositivos, esses sistemas estão acompanhando a tendência da indústria 4.0 de possuir serviços de todos os lugares na palma da mão e são inevitáveis para o mundo atual. (JAZDI, 2014).

As principais características de um CPS são flexibilidade e adaptabilidade, modularidade, autonomia e confiabilidade, segurança e eficiência. CPS devem ser capazes de se reconfigurar de forma automática e auto-organização para mudar de tarefa quando necessário, trocando informações para realizar a tarefa solicitada. (CRISTALLI *et al.*, 2016).

Na Indústria 4.0 os mundos físico e virtual crescem juntos. Os CPS são compostos por sistemas inteligentes conectados por meio da IoT e serviços. Isso resulta em novos requisitos e áreas de aplicação para tecnologia de simulação por meio dos Gêmeos digitais do inglês *Digital Twins* que representam objetos reais com seus dados, funções e capacidades de comunicação no mundo digital (SCHLUSE *et al.*, 2018).

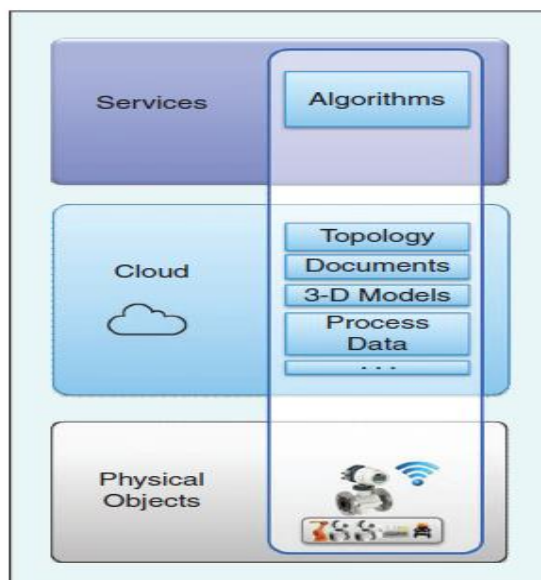
Imagine um semáforo comandado por um sistema de controle central, dentro de um cenário CPS ele se tornaria um objeto na rede contendo os dados de cor atual e cronograma que possibilitaria que carros analisem os dados do semáforo e tracem então a melhor rota de navegação. Indo além os carros também enviam seus dados para a rede, que sincronizados aos dados dos semáforos aperfeiçoam o fluxo de tráfego em uma cidade.

Esse fluxo de operações pode ser estendido para outros sistemas como clima, geolocalização entre outros, formando uma grande massa de dados e infinitas possibilidades de negócios.

A Figura 4 apresenta a visão geral de um CPS, dividida em três níveis:

1. No primeiro nível temos os objetos conectados na rede, enviando e recebendo dados em tempo real.
2. No segundo nível temos a “nuvem”, que guarda todas as informações enviadas pelos objetos, bem como suas representações virtuais, modelos, topologia e etc.
3. Por fim temos o nível dos serviços, responsável pelos algoritmos que irão executar os procedimentos dos dados e realização das ações.

Figura 4 Visão Geral CPS



Fonte: Cristalli (2016).

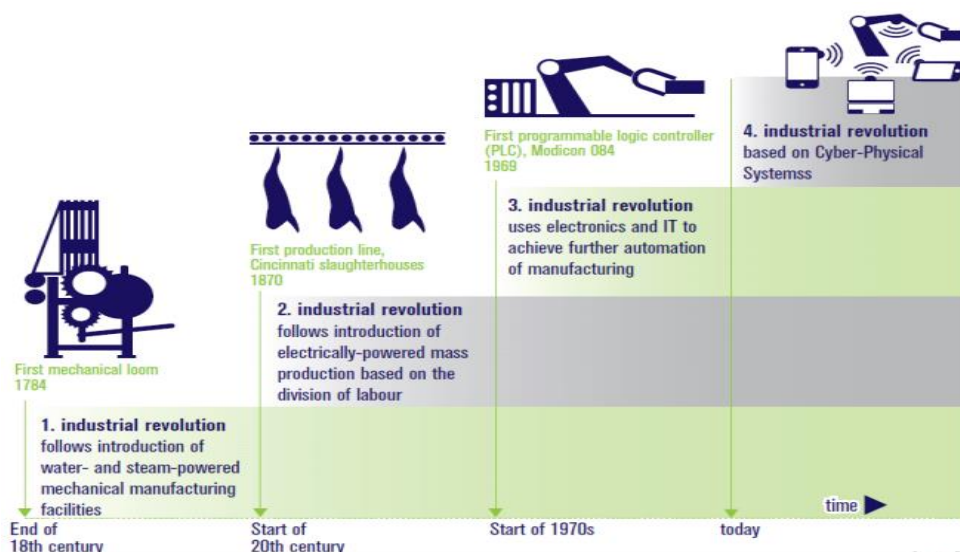
Para Toro *et al* (2015) CPS é a união do mundo real com sistema computacional chamado de ciberespaço do inglês *cyberspace*. Aplicando à fábrica inteligente e integrado com sensores e atuadores pode ajudar na tomada de decisão. Integrando os CPS nas práticas industriais atuais aplicaria nas fábricas o contexto da Indústria 4.0 e aumentaria o potencial econômico significativamente (LEE *et al.*, 2015).

2.1.4 Indústria 4.0

Desde a primeira Revolução Industrial, revoluções subsequentes resultaram em mudanças e alterações nos modos fabricação, desde a inserção da água e máquinas movidas a vapor para automação elétrica e produção automatizada. Os processos de fabricação tornaram-se cada vez mais complexos, automáticos e sustentáveis, ou seja, as pessoas podem operar máquinas de forma simples, eficiente e persistente criando um novo conceito: a Indústria 4.0. (QIN *et al.*, 2016).

O termo indústria 4.0 é o resultado de vários estágios da evolução industrial (BALASINGHAM, 2016). A primeira revolução industrial melhorou eficiência por meio do uso da energia a vapor e desenvolvimento de máquinas-ferramentas, a segunda revolução industrial trouxe eletricidade e produção em massa (linhas de montagem), e por fim, a terceira revolução industrial desenvolveu a automação, com eletrônica e tecnologia da informação. No momento atual a quarta revolução industrial é emergente que é liderada pela tecnologia dos CPS para integrar o real mundo com a era da informação. (ZHOU, 2015). A Figura 5 descreve as evoluções da indústria.

Figura 5 Evoluções da Indústria



Fonte: Centro alemão de pesquisa e inteligência (2014)

Para Gorecky (2014) a indústria 4.0 vem para conectar e integrar indústrias tradicionais com intuito de aumentar a flexibilidade, adaptabilidade e eficiência na interação de produtores e consumidores. Segundo Drath (2014) a indústria 4.0 é um fenômeno que virá inevitavelmente, semelhante ao lançamento da internet no início dos anos 90 que possibilitou o nascimento do entretenimento e mercado on-line ela se torna uma tríade dos objetos físicos desde sua representação virtual, serviços e aplicações na indústria.

Jazdi (2014) afirma que a integração das áreas aumenta a customização do processo de produção e do produto final e diminui o tempo entre o desenvolvimento do produto até sua disponibilização para o comércio. Assim, o novo papel dos trabalhadores dentro da indústria 4.0 deve estar acompanhado de métodos organizacionais e tecnológicos, aliados a técnicas de qualificação e necessariamente habilidades de manuseio de informações geradas pela produção de CPS. (GORECKY, 2014).

Segundo Rubmann *et al* (2015), em um contexto de indústria 4.0 a avaliação dos dados de equipamentos e sistemas de produção agregado com o gerenciamento de empresas e clientes se tornará um padrão para tomada de decisões em tempo real dos empresários.

2.1.5 Surface Mount Technology (SMT)

Segundo Prasad (2013), o *Surface Mount Technology* (SMT) pode ter surgido na década de 50, nos Estados Unidos com a utilização dos dispositivos *flat packs*. Porém, tais dispositivos eram utilizados apenas em algumas aplicações militares devido a seu custo, ainda, inviabilizados.

O processo de montagem SMT se baseia no processo de montagem de componentes na superfície *Printed Circuit Board* (PCB) realizado exclusivamente pela máquina. Para isso o componente precisa estar na arquitetura *Surface Mount Device* (SMD). (PANGARTTE, 2014).

Segundo Pereira (2017), SMDs são componentes eletrônicos no qual a montagem é feita diretamente na superfície da PCB. Devido sua característica de miniaturização possibilita a produção de equipamentos pequenos com alta densidade de componentes. O autor Sandrini (2014) define os equipamentos que compõem a linha de produção SMT. De acordo com a Figura 6 são eles:

Figura 6 Composição de uma Linha de Montagem SMT



Fonte: Sandrini, (2014).

- 1 - *Loader*- Dispositivo responsável por colocar os magazines com as placas a serem montadas;
- 2 - *Bare Board Unit (BBU)*- Utilizado para colocar apenas as placas a serem montadas;
- 3 - *Printer*- Equipamento utilizado para aplicação da pasta de solda;
- 4 - *Solder Paste Inspection (SPI)*- Equipamento responsável a inspecionar automaticamente a pasta de solda aplicada;
- 5 - *Conveyor*- Dispositivo que serve de ligação entre os equipamentos;
- 6 - *Pick and Place*- Equipamento de alta capacidade produtiva, utilizado para montagens de componentes menores e mais simples como resistores, capacitores e diodos;
- 7 - *Pick and Place-Fine Pitch*- Equipamento utilizado para a montagem de componentes maiores e mais complexos, tais como, circuitos integrados e conectores;
- 8 - Forno de Refusão- Equipamento utilizado para realizar a soldagem;
- 9 - *Buffer*- Dispositivo responsável a armazenar as placas que sairão do forno, antes de entrar na AOI;
- 10 - *Automated Optical Inspection (AOI)*- Responsável por inspecionar automaticamente os componentes montados;
- 11 - *Unloader*- Dispositivo utilizado para colocar os magazines com as placas montadas.

A tecnologia de ponta SMT vem se tornando tendência devida sua grande variedade de componentes, circuitos integrados, semicondutores, entre outros, que oferece às indústrias diversas alternativas de substituição dos componentes convencionais. Outro fator é que a maioria dos componentes de tecnologia mais moderna está somente no formato SMD, o que forçou muitos fabricantes a adotarem esta tecnologia (PEREIRA, 2017).

2.1.6 Manutenção Preditiva

Manutenção é definida como uma ação para manter em um estado existente e prevenir o fracasso ou inatividade, esta definição implica que a manutenção envolve tarefas venham a prevenir a degradação ou o defeito iminente de equipamentos. Um estudo do Departamento dos EUA de Energia em Agosto 2010 indicou que mais de 55% dos recursos de manutenção e atividades de uma instalação média ainda estão reativas, 31% estão focados na manutenção preventiva e apenas 12% na manutenção preditiva. (SHETTY, 2015).

Os Custos com manutenção são uma parte importante dos custos de operacionais de uma fábrica. Dependendo da indústria podem variar de 15% até 60% dos custos com produção. (MOBLEY, 2002).

A manutenção é considerada um importante processo em todos os setores, independentemente do seu tamanho. Sem a devida manutenção, nenhuma indústria poderia esperar funcionar em máxima eficiência e a um custo mínimo e também evitar o risco de ter avarias frequentes. Mesmo que o processo de manutenção seja muito importante, a maioria das indústrias ainda não possui uma solução para o agendamento e gerenciamento geral de tarefas diferentes. (AMITH *et al.*, 2016).

A Manutenção preditiva detecta falhas dos equipamentos com antecedência e permite intervenções antecipadas. As previsões são baseadas em métodos de inferência estatística e abordagens de engenharia, que são construídos sobre dados históricos e a definição de funcionamento dos equipamentos. Manutenção preditiva funciona bem no contexto de a IoT, onde os sensores permitem a determinação de diversas variáveis e a continuidade dos dados, o que permite previsões mais precisas e reduz o tempo de inatividade em máquina e perdas de produção. (ZOLL, JACK e VOGT, 2018).

De acordo com Spendla (2017), a manutenção preditiva pode ser subdivida em duas categorias:

- Manutenção Preditiva Baseada em Estatística: os dados coletados pelo sistema de sensores são analisados através de modelos estatísticos para criar políticas de manutenção preditiva.
- Manutenção Preditiva Baseada em Condições: está relacionado aos exames dos processos de desgastes dos equipamentos. O equipamento é analisado constantemente a fim de se detectar mudanças no comportamento da máquina e prever falhas à longo prazo, neste trabalho será utilizado esta categoria devido as características do ambiente onde o software será testado.

Com o avanço da IoT e a quantidade de dados crescente na fabricação apresentam grandes benefícios para a área de manutenção preditiva, porém também aumentam a demanda por métodos de análise de grandes massas de dados.

2.2 Trabalhos Relacionados

2.2.1 Canizo, Onieva, Conde, Charramendieta e Trujilo (2017)

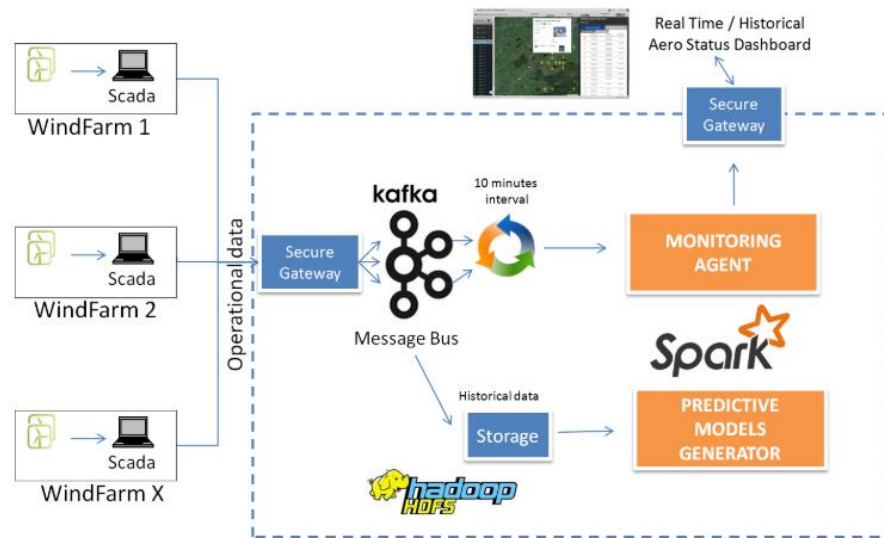
No trabalho dos autores é apresentada uma abordagem de *Big Data* para adaptar um método de manutenção preditiva para turbinas eólicas, com o objetivo de ser executado em um ambiente de computação em nuvem escalável. Para o desenvolvimento do trabalho, os autores se basearam nas seguintes problemáticas:

- A maioria das empresas do ramo da indústria eólica não trabalha com dados centralizados, fazendo com que fosse preciso um sistema para cada parque eólico.
- Caso os dados fossem centralizados, seria necessário um enorme poder computacional para processar a grande quantidade de dados gerada. Esse problema foi tratado como escalabilidade limitado por parte da tecnologia atual.

Neste contexto, foi proposta uma aplicação utilizando computação em nuvem e tratamento de *Big Data* com método de escalabilidade horizontal proporcionando uma forma eficiente de gerenciar todas as turbinas eólicas de uma empresa a partir de um sistema central de manutenção. A aplicação utilizou dados de turbinas eólicas coletados por dois anos, os quais foram divididos em 2 grupos: 448 tipos de dados de status (ativações de alarmes e desativações) e 104 tipos de dados operacionais, que representam o desempenho das turbinas eólicas sendo recebidos a cada 10 minutos.

A Figura 7 descreve a arquitetura proposta pelos autores, levando em consideração obtenção de dados, persistência e processamento.


Figura 7 - Arquitetura da Aplicação



Fonte: Canizo (2017).

O método de manutenção preditiva utilizado no trabalho foi dividido em três partes: um gerador de modelos preditivos que se baseia nos dados históricos das turbinas eólicas, um agente de monitoramento que faz as previsões quando os dados são recebidos das turbinas eólicas (a cada 10 minutos) e um *front-end* onde as turbinas eólicas podem ser visualizadas geograficamente localizadas em um mapa, bem como suas notificações sobre as previsões e as informações de status. A Figura 8 descreve a primeira parte da implementação do método.


Figura 8 - Diagrama do Gerador de Modelos Preditivos



Fonte: Canizo (2017).

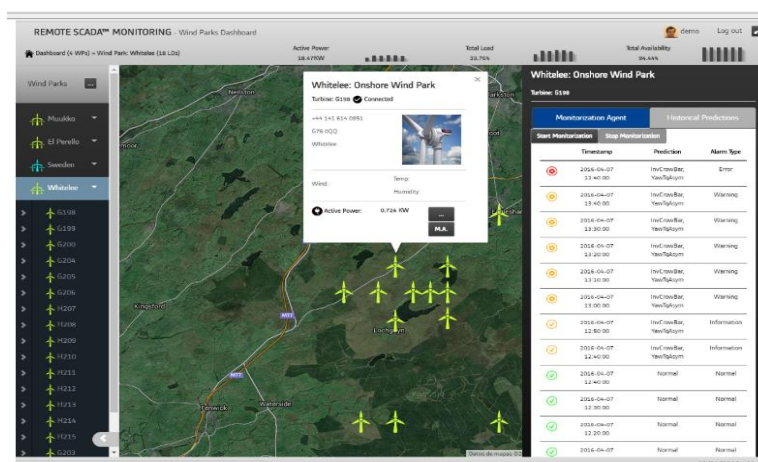
Na segunda parte o agente de monitoramento carrega todos os modelos preditivos na memória para que o agente possa começar a monitorar o estado das turbinas eólicas. Quando novos dados são recebidos, uma previsão é feita por meio dos modelos preditivos correspondentes. Dados operacionais são coletados a cada 10 minutos e previsão é sempre feita para prever o que vai acontecer uma hora depois, por fim cada previsão é enviada via websockets para o *front-end* para sua visualização. A Figura 9 e a Figura 10 apresentam o diagrama do agente de monitoramento e o *front-end* básico da aplicação do usuário respectivamente.

Figura 9 - Agente de Monitoramento



Fonte: Canizo (2017).

Figura 10 - Interface da Aplicação



Fonte: Canizo (2017).

Ao aplicar os testes na aplicação os autores avaliaram que as precisões da maioria dos modelos obtiveram uma taxa de sucesso de 81% -85%. No entanto, a precisão dos modelos preditivos para duas das 17 turbinas eólicas diminuiu para 70% -75%. Ao analisar a discrepância ocorrida os autores avaliaram que nas duas turbinas eólicas tinham mais de um número de classes do que as outras concluindo que quanto mais classes houver, pior será a precisão dos modelos. A Figura 11 apresenta alguns dos resultados dos testes aplicados nas turbinas eólicas.

Figura 11 - Testes da aplicação nas turbinas

Accuracy type	Accuracy individualized by class					Accuracy error/no error		Accuracy	Sensitivity	Specificity
Models \ Class	Class 1 (11.74%)	Class 2 (50.01%)	Class 3 (0.75%)	Class 4 (37.24%)	Class 5 (0.26%)	Error (62.76%)	No error (37.24%)	Global	Global	Global
Model 1	62.60%	92.56%	18.52%	82.35%	6.12%	85.52%	82.35%	84.34%	91.54%	74.11%
Model 2	64.50%	92.76%	9.96%	81.93%	9.09%	86.08%	81.93%	84.54%	92.10%	73.80%
Model 3	60.69%	92.59%	12.88%	82.13%	4.49%	85.63%	82.63%	84.32%	91.61%	74.04%
Model 4	65.85%	92.40%	15.87%	82.32%	5.95%	86.18%	82.32%	84.74%	92.15%	74.24%
Model 5	63.43%	92.51%	24.27%	82.01%	4.30%	85.91%	82.01%	84.45%	92.15%	73.69%
Model 6	64.95%	92.47%	16.12%	82.58%	8.82%	85.90%	82.58%	84.67%	91.98%	74.30%

Accuracy type	Accuracy individualized by class		Accuracy error/no error		Accuracy	Sensitivity	Specificity
Models \ Class	Class 1 (47.44%)	Class 2 (52.56%)	Error (52.56%)	No error (47.44%)	Global	Global	Global
Model 1	77.94%	89.04%	89.04%	77.94%	83.78%	89.04%	77.94%
Model 2	78.15%	89.44%	89.44%	78.15%	84.07%	89.44%	78.15%
Model 3	77.14%	89.58%	89.58%	77.14%	83.68%	89.58%	77.14%
Model 4	77.44%	89.18%	89.18%	77.44%	83.59%	89.18%	77.44%
Model 5	77.49%	89.43%	77.49%	89.43%	83.77%	89.43%	77.49%
Model 6	77.29%	89.20%	77.29%	89.20%	83.56%	89.20%	77.29%

Fonte: Canizo (2017).

Os testes da aplicação obtiveram bons resultados, porém o método desenvolvido pelos autores se aplica somente no cenário em questão. Outro fato importante de se ressaltar é que a aplicação diminui a taxa de sucesso se os dados trabalhados forem desbalanceados, bem como não foram realizados testes de escalabilidade da aplicação na nuvem.

A principal diferença deste trabalho para a esta monografia, é que a monografia possuirá a utilização de tecnologias de baixo custo e a aplicação de protocolos baseados em IoT e Industria 4.0. O que leva a aplicação final deste trabalho possuir a capacidade de adaptação a diversos cenários industriais.

2.2.2 Spendla, Kebisek, Tanuska e Hrcka (2017)

O trabalho dos autores teve por objetivo a construção de uma plataforma de descoberta de conhecimento baseada no *Hadoop* concentrada na manutenção preditiva de sistemas de produção. O trabalho parte da premissa que para o controle e gerenciamento efetivos do processo, não apenas dados de produção são necessários, como também dados, incluindo informações de clientes, recursos e fornecedores, dos níveis de controle da hierarquia superior também são imprescindíveis.

As áreas de manufatura abordadas no trabalho são divididas em cinco áreas principais:


- Análise de qualidade de produtos para correlacionar a qualidade de saída e os parâmetros do sistema.
- Análise de falha de recursos de produção

- Análise de manutenção para aumentar a disponibilidade de recursos de produção
- Planejamento de produção e análise de cronograma para melhorar a qualidade do planejamento
- Planejamento estratégico e análise de programação para melhorar o relacionamento com o cliente e aumentar as vendas

Para o desenvolvimento da aplicação foi utilizada a metodologia CRISP-DM, que possui seis estágios predefinidos descritos na Figura 12:

- *Business understanding* fase de compreensão dos objetivos e requisitos do projeto
- *Data understanding* fase de estudos sobre os dados para identificar problemas e formar hipóteses.
- *Data preparation* construção dos dados finais a partir dos dados brutos iniciais
- *Modelling* seleção e aplicação de várias técnicas de modelagem para calibrar valores ideais.
- *Evaluation* revisão dos modelos para verificar se os objetivos foram atingidos
- *Deployment* apresentação dos resultados para o cliente

Figura 12 - Fases da metodologia CRISP-DM

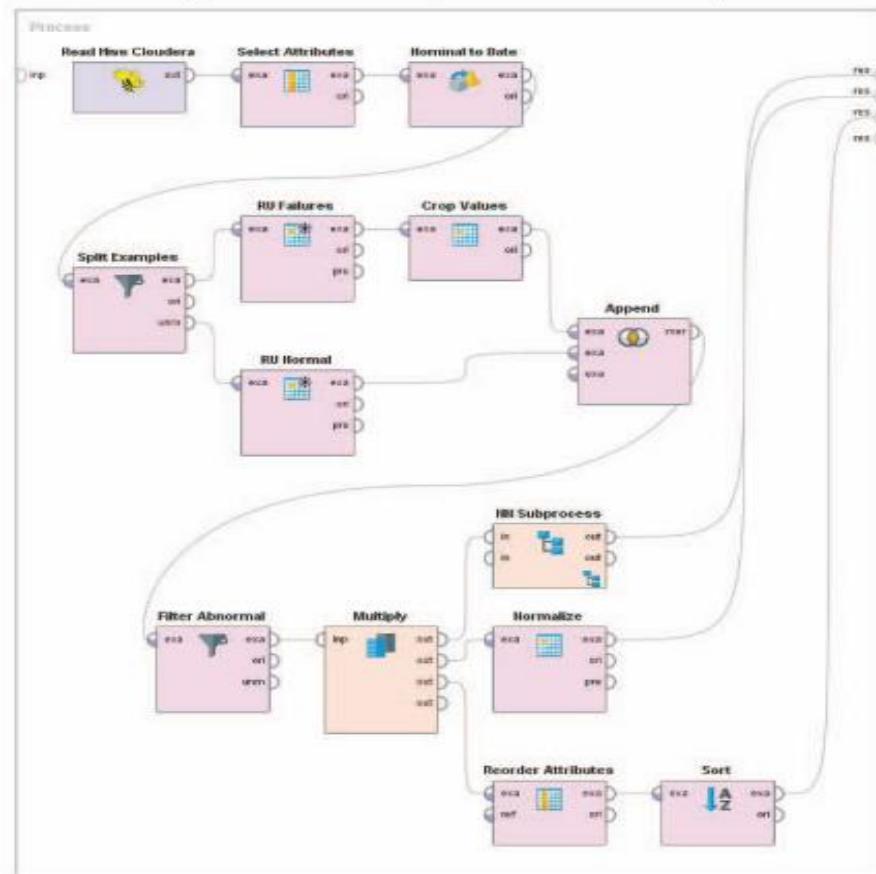


Fonte: Spendla (2017).

A execução do trabalho constrói uma ferramenta de descoberta de conhecimento com dados integrados no *Data Lake* utilizando cluster do *Hadoop*, que possui como vantagem a disponibilidade de dados brutos da fabricação. Os dados utilizados nos testes pelos autores foram coletados no período de 10 meses, o que gerou 148124 registros com 340 atributos regulares.

Os dados foram processados por meio de modelos de descoberta de conhecimento, com foco no impacto das operações ao longo do tempo na vida útil da máquina e na qualidade de produção. O modelo de descoberta de conhecimento utilizou redes neurais para classificar as falhas utilizadas durante a manutenção preditiva de acordo com a Figura 13.

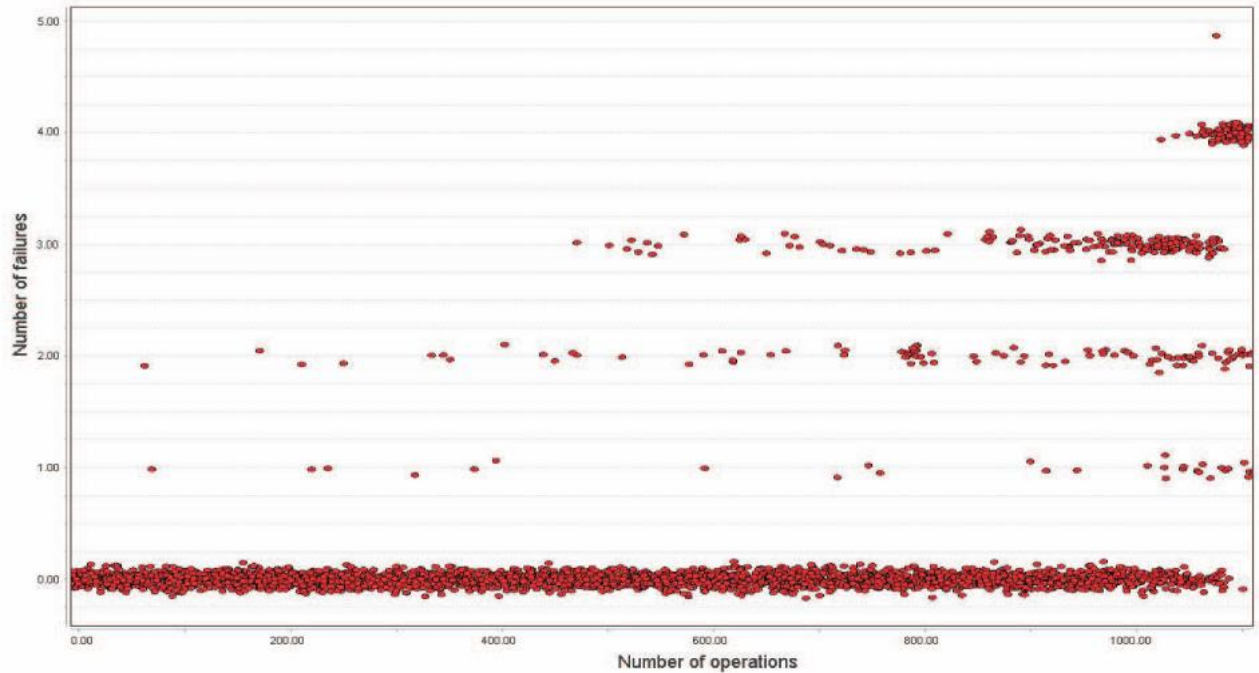
Figura 13 - Modelo de descoberta de conhecimento



Fonte: Spendla (2017).

O estudo aplicado no trabalho gerou um gráfico de dispersão relacionando falhas no processo de fabricação usando os mesmos tipos de ferramentas e esta descrito na Figura 14:

Figura 14 - Gráfico de dispersão de falhas



Fonte: Spendla (2017).

O gráfico apresenta onde às falhas no processo de fabricação começaram a aumentar, à medida que o número de falhas aumenta com o número de operações. O eixo horizontal mostra o número de vezes que a ferramenta foi usada. Os números no eixo vertical mostram o número de falhas que são normalizadas na faixa de 0 a 5, onde 0 significa ausência de falhas e 5 é o número máximo de falhas.

Com base nos resultados os autores concluíram que o estudo de caso de descoberta de conhecimento proposto pode ser aplicado para a manutenção preditiva de ferramentas e por meio dele é possível aperfeiçoar os intervalos de manutenção que afetarão a eficiência da produção, a qualidade, reduz as paradas de produção e os custos de manutenção.

A grande desvantagem do trabalho de *Spendla* é a exigência de dados dos níveis inferiores de controle hierárquico que devem ser coletados e armazenados em um armazenamento de dados adequado assim como os problemas relacionados à segurança de dados e permissões de acesso que não foram tratados durante o trabalho.

A diferença deste trabalho para a esta monografia é que a aplicação proposta não dependerá de dados de níveis inferiores relacionados aos equipamentos, bem como aplica conceitos de CPS que permite o monitoramento em um contexto mais abrangente de uma fábrica inteligente.

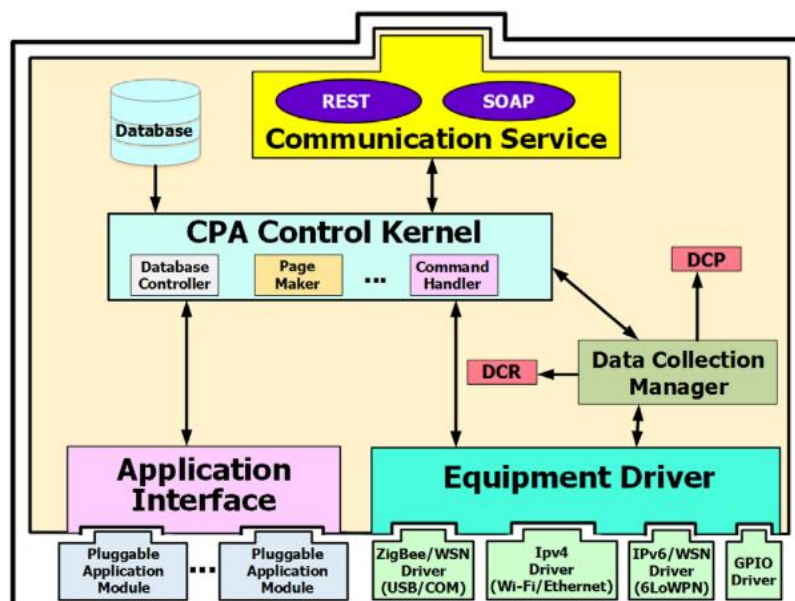
2.2.3 Chiu, Cheng e Huang (2017)

Neste trabalho os autores desenvolveram um sistema de manutenção preditiva inteligente em toda uma fábrica, aplicando agentes *cybers* físicos do inglês *cyber physical agent* (CPA) e nuvem de fabricação avançada do inglês *advanced manufacturing cloud of Things* (AMCOT) para atender aos requisitos da Indústria 4.0. Para a construção da aplicação foram definidos três objetivos a serem atendidos pela manutenção preditiva.

- Infraestrutura Poderosa e plataforma de comunicação e processamento de dados veloz
- Mecanismo eficaz de diagnóstico e prognóstico de falhas
- Hierarquia Gerenciável

O trabalho utiliza CPA's para coleta de dados e comunicação entre os objetos físicos, os agentes são descritos conforme a arquitetura descrita na Figura 15.

Figura 15 - Arquitetura de um CPA



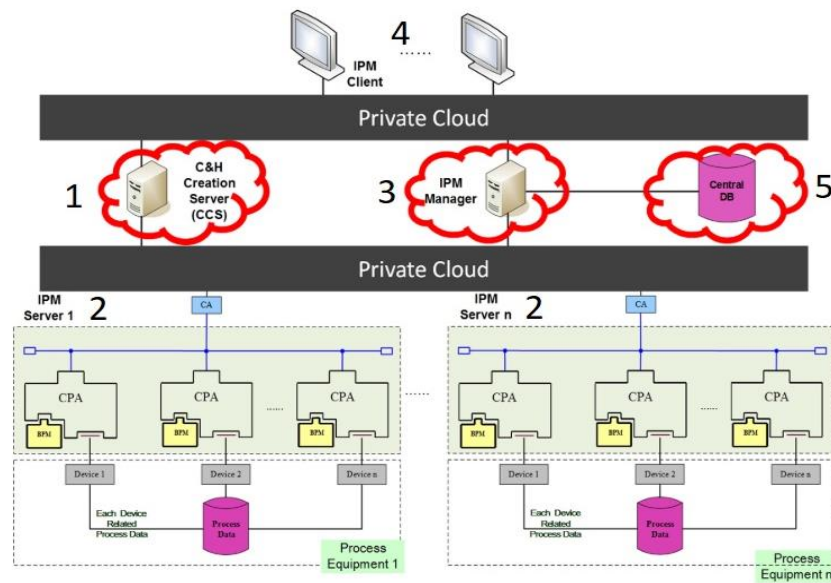
Fonte: Chiu (2017).

De acordo com a Figura acima, os CPA's são compostos de kernel de controle CPA, serviço de comunicação, gerenciador de coleta de dados (DCM), plano de coleta de dados (DCP), relatório de coleta de dados (DCR), driver de equipamento (ED), interface de aplicativo (AI) e banco de dados.

Junto com o CPA, a aplicação utiliza o AMCOT que fornece uma plataforma baseada em nuvem para conectar e compartilhar todas as informações das coisas entre os fornecedores, clientes e ferramentas de manufatura. Os autores utilizaram a metodologia

baseada em metrologia onde utilizam um modelo de linha base para referência na detecção de falhas e hierarquia de índices de saúde (HIH) para supervisionar a manutenção de equipamentos em toda a fábrica. A arquitetura do sistema é apresentada na Figura 16. O sistema é composto de cinco partes principais: (1) servidor de criação consciente e saudável (CCS), (2) servidor de Manutenção Preditiva (IPM), (3) gerente de IPM, (4) cliente Manutenção Preditiva, e (5) banco de dados central.

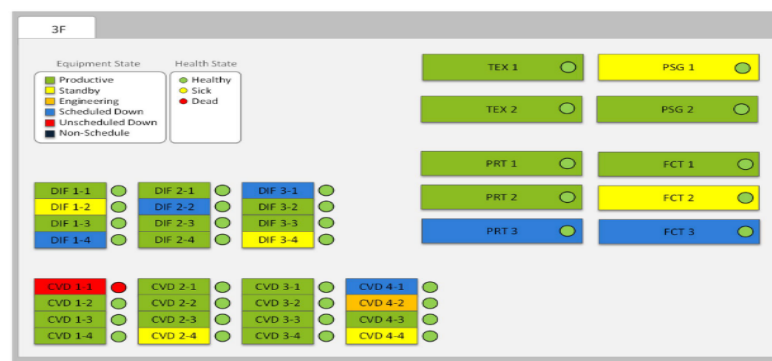
Figura 16 - Arquitetura do Sistema



Fonte: Chiu (2017).

A aplicação dos autores foi implantada em um linha de produção real onde foi desenvolvida a interface para permitir aos gerentes manipularem os índices de integridade das máquinas da fábrica. Os *status* de integridade são exibidos em verde (saudável), amarelo (doente) e vermelho (morto) e cada ferramenta pode ser analisada independentemente conforme apresentado na Figura 17.

Figura 17 - Interface da aplicação



Fonte: Chiu (2017).


No trabalho desenvolvido pelos autores não foram divulgados resultados dos testes na linha de produção porém, a principal característica desse trabalho é que os autores utilizam servidores de manutenção preditiva em cada equipamento se comunicando com um gerente de manutenção central através de CPA's que tornam a implantação do sistema muito custosa para a fábrica.

Nesta monografia será apresentada posteriormente uma arquitetura baseada em CPS com redes de sensores se comunicando com apenas um servidor de dados para tomada de decisão, por meio dessa arquitetura é possível reduzir a complexidade e custo de implantação em uma fábrica inteligente.

2.2.4 Li, Wang e Wang (2017)

Neste trabalho os autores desenvolvem uma investigação para o diagnóstico e prognóstico de falhas em centros de usinagem baseados em abordagens de mineração de dados com objetivo de formular abordagens e criar bases de conhecimento sobre manutenção preditiva na era da Indústria 4.0. Os centros foram definidos de acordo com a Figura 18.

Figura 18 - Arquitetura de centros de usinagem

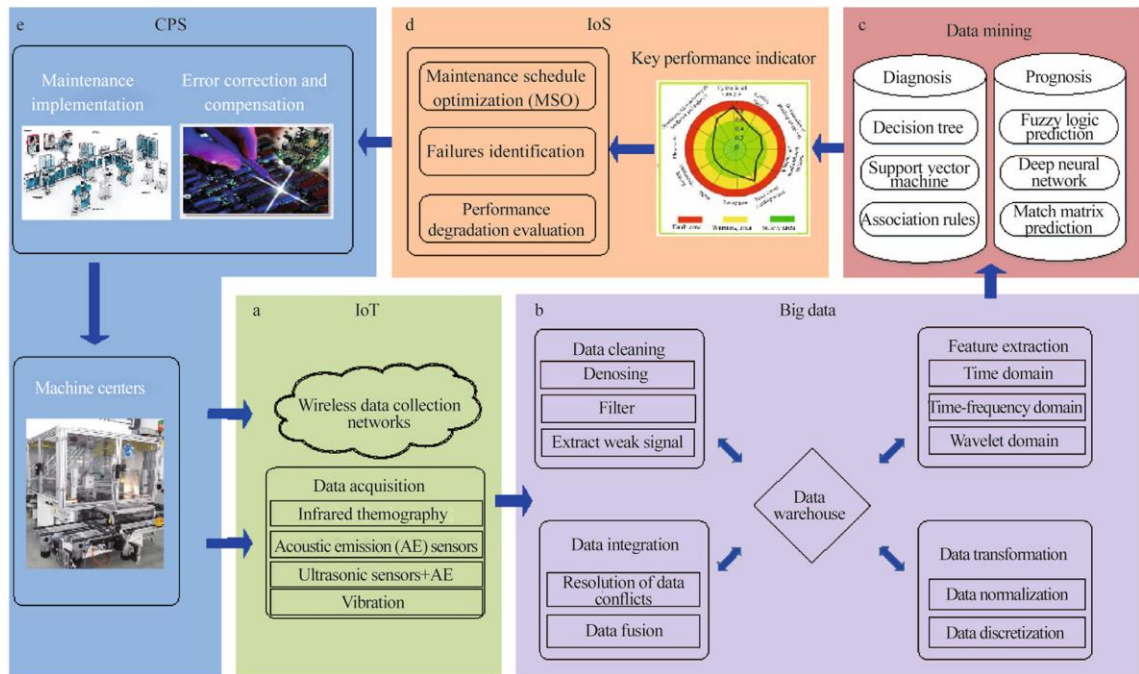


Fonte: Li (2017).

Para o diagnóstico e prognóstico de falhas nos centros foram utilizados como base sete grupos de conhecimento: análise de medição geométrica, análise de vibração, análise de óleo, análise de fluido de corte, análise de consumo de energia, análise de temperatura e emissão acústica, de acordo com os componentes observados, método de monitoramento ou propósito. O modelo proposto foi dividido em cinco módulos: **a)** seleção de sensor e aquisição de dados,

b) pré-processamento de dados, c) Mineração de Dados (DM), d) suporte à decisão, e) módulo de implementação da manutenção, cada qual com características e funções específicas de acordo com a Figura 19.

Figura 19 - Modelo para manutenção preditiva em centros de maquinas



Fonte: Li (2017).

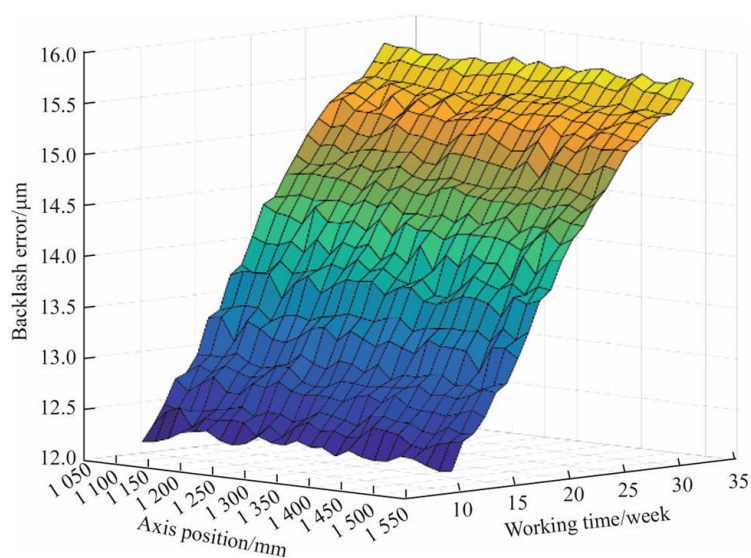
De acordo com este modelo os cinco modelos são divididos por funcionalidades da seguinte forma:

- Módulo para selecionar um sensor adequado e a estratégia de coleta de dados ideal, além conectar os objetos ou permitir que eles interajam uns com os outros.
- Módulo para pré-processar os dados antes da etapa subsequente. Este módulo envolve as etapas envolvidas no pré-processamento de dados como: limpeza de dados, integração de dados, redução de dados e transformação de dados com objetivo de enviar dados organizados para o DM melhorando a eficiência do processamento da aplicação.
- O módulo DM no *framework* proposto pelos autores foca principalmente detecção, classificação e previsão de falhas para manutenção preditiva baseados em técnicas híbridas para reconhecimento de padrões.
- O objetivo deste módulo é visualizar o resultado do DM e fornecer uma estratégia otimizada para implantação de manutenção.

e) O objetivo deste módulo é implementar a manutenção após a escolha da estratégia de manutenção no módulo anterior.

Os autores realizaram testes teóricos no modelo em cenários de centros máquinas para detecção de falhas nas máquinas durante três semanas, e concluíram que os dados dos erros podiam ser usados para prever o erro de folga da semana subsequente de acordo com a Figura 20.

Figura 20 - Resultados dos testes teóricos



Fonte: Li (2017).

A principal característica deste trabalho é a utilização de técnicas DM híbridas para reconhecimento de padrões dos dados para aplicação da manutenção preditiva, porém a precisão destas técnicas depende de grandes quantidades de informações. Os autores deste trabalho definiram o *framework* para coletar dados dos sensores e realizar então DM nos dados recebidos, isso faz com que a aplicação proposta precise ser implantada por um médio a longo prazo de tempo para que contenha dados suficientes para uma DM eficiente.

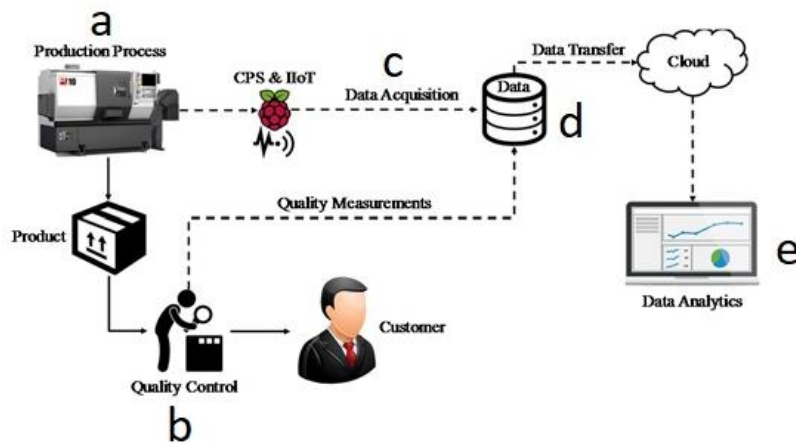
A monografia resolve essa dependência de dados, trabalhando com parâmetros pré estabelecidos da máquina de solda, que foram identificadas e repassadas pela equipe de manutenção por meio do manual de manutenção da máquina. Este processo garante uma base de dados consistente para processos de DM dentre outros, aumentando a precisão dos métodos a serem aplicados na manutenção preditiva.

2.2.5 Sezer, Romero, Macchi, Milano e Emmanouilidis (2018)

Neste trabalho os autores descrevem os conceitos básicos, materiais e métodos usados para desenvolver uma arquitetura Indústria 4.0 focada na manutenção preditiva, contando com princípios de baixo custo para ser aplicado por pequenas empresas de fabricação por meio de técnicas de *Regression Tree* e métricas de qualidade do processo.

A arquitetura proposta pelos autores possui os seguintes elementos: (a) simulação de produção, (b) gestão de qualidade, (c) aquisição de dados, (d) armazenamento de dados, e (e) análise de dados. A Figura 21 apresenta a estrutura geral da proposta para o sistema de manutenção preditiva usando tecnologias de baixo custo aplicados em um centro de torneamento CNC Haas ST 10.

Figura 21 - Arquitetura da aplicação



Fonte: Sezer (2018).

A máquina CNC foi configurada para produzir peças metálicas simples usando um porta ferramentas e uma ferramenta de inserção, e o controle de qualidade foi realizado utilizando as seguintes variáveis de rugosidade: a média de rugosidade (R_a), a rugosidade média quadrada (R_q) e a profundidade média de rugosidade (R_z) que foram medidas manualmente usando um verificador de rugosidade superficial.

Os testes na aplicação foram divididos em quatro etapas principais: (1) simulação de produção, (2) dados aquisição e armazenamento, (3) framework Manutenção Preditiva e (4) resultados. A primeira etapa descreve a simulação de um ambiente de produção da vida real, que requer a seleção de material, porta-ferramentas, inserção de ferramentas e desenvolvimento de um processo de usinagem. A Figura 22 descreve o projeto das peças, onde a posição 1 na peça de trabalho é descrito como o ponto crítico em que a qualidade

precisa ser garantida, por conseguinte a Tabela 6 descreve os parâmetros utilizados durante os testes.

Figura 22 - Modelo de peça



Fonte: Sezer (2018).

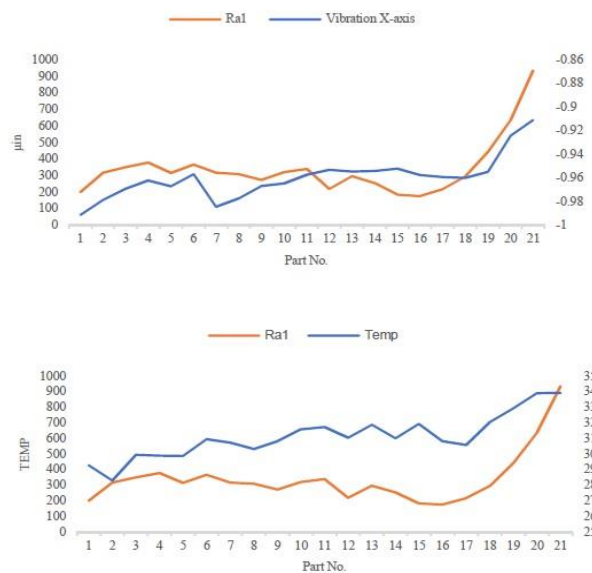
Tabela 6 Parâmetros dos Experimentos

	Experimento 1	Experimento 2	Experimento 3
Velocidade do Fuso	3600	2600	1600
Taxa de Alimentação	0.3	0.2	0.1
Profundidade de Corte	1.954 mm	1.954 mm	1.954 mm
Tempo de Ciclo	80 segundos	113 segundos	segundos

Fonte: Sezer (2018).



Os testes demonstraram que a aplicação obteve 81% de precisão nas previsões utilizando o método de árvore de regressão. As figuras abaixo descrevem os resultados obtidos avaliando **Eixo X de vibração vs média de rugosidade** e **Média de Temperatura vs média de rugosidade**.

Figura 23 Experimento 1




Fonte: Sezer (2018).

Figura 24 Experimento 2



Fonte: Sezer (2018).

Figura 25 Experimento 3



Fonte: Sezer (2018).

A principal característica deste trabalho é a utilização de técnicas de árvore de regressão para aplicação da manutenção preditiva, bem como a utilização de ferramentas de baixo custos ou gratuitas. Porém a aplicação não garante escalabilidade, pois os resultados foram diminuindo a taxa de sucesso de acordo com a quantidade de peças analisada.

A monografia mantém a característica de baixo custo de implantação da aplicação em fábricas inteligentes, porém propõe também uma aplicação intuitiva e com grande praticidade graças a utilização de tecnologias móveis para o controle remoto dos equipamentos.

2.2.6 Contribuições dos trabalhos para a monografia

Os trabalhos relacionados nesta pesquisa serviram para embasamento teórico a respeito do cenário atual da manutenção preditiva na era da indústria 4.0. As principais contribuições de cada trabalho foram:

- Canizo, Onieva, Conde, Charramendieta e Trujilo (2017): Metodologia para geração de modelos preditivos, e técnicas de análise de dados.
- Spendla, Kebisek, Tanuska e Hrcka (2017): Modelo de descoberta de conhecimento para trabalhar com todos os processos hierárquicos de uma fábrica.
- Chiu, Cheng e Huang (2017): Métodos de utilização de Agentes *Cybers* Físicos e redes IOT para manutenção preditiva.
- Li, Wang e Wang (2017): Métodos de mineração de dados e aplicações com *Big Data* em redes IOT.
- Sezer, Romero, Macchi, Milano e Emmanouilidis (2018): Modelo de arquitetura com ferramentas de baixo de custo para implementação de manutenção preditiva.

A Tabela 7 apresenta as comparações entre os trabalhos relacionados e a monografia, pode-se observar que as tecnologias utilizadas são basicamente as mesmas com variações devido as suas aplicações.

Tabela 7 Comparativo entre os trabalhos relacionados

Funcionalidades	Canizo	Spendla	Chiu	Li	Sezer	Monografia
IOT	SIM	SIM	SIM	SIM	SIM	SIM
IIOT	SIM	SIM	SIM	SIM	SIM	SIM
CPS	NÃO	NÃO	SIM	SIM	SIM	SIM
SMT	NÃO	NÃO	NÃO	NAO	NAO	SIM
Manutenção Preditiva	SIM	SIM	SIM	SIM	SIM	SIM

Fonte: O autor (2018).

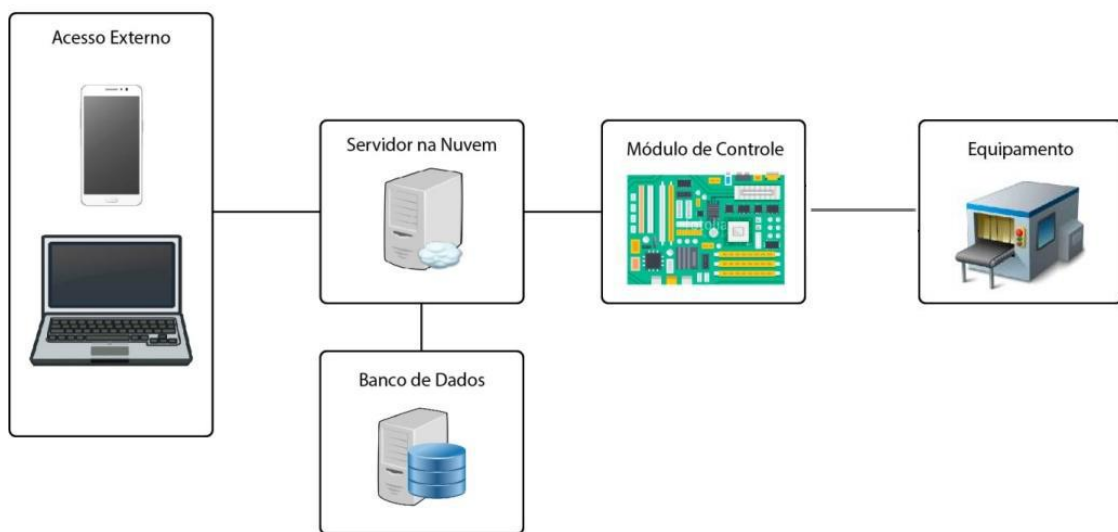
3 RESULTADOS E DISCUSSÕES

Nesta seção são apresentados os resultados finais deste trabalho com base na metodologia. Serão apresentados a arquitetura, resultados dos testes e as próximas etapas a serem realizadas.

3.1 Definições da Arquitetura

A Figura 26 apresenta a arquitetura inicial desenvolvida neste trabalho, ela enfatiza a comunicação entre os módulos do equipamento, módulo de controle, e o cenário de aplicação, bem como o servidor para armazenamento dos dados e os dispositivos conectados aos servidores que permitem acessos externos.

Figura 26 Arquitetura proposta para a aplicação



Fonte: O autor (2018).

Na arquitetura acima o equipamento de solda sendo monitorado por uma placa controladora. Os dados coletados são enviados a um servidor na nuvem e armazenados em um banco de dados para avaliação pelo método baseado em agentes inteligentes que será discutido posteriormente. Os dispositivos externos recebem notificações em tempo real dos últimos eventos ocorridos na máquina e permitem que o usuário mediante senha de acesso controle o equipamento remotamente.

Essa solução aplica os conceitos de indústria 4.0, IOT e CPS nas quais definem o modo de interação *machine to machine* e humano/computador de forma inteligente e automatizada.

3.2 Resultados do Mapeamento Sistemático

O MS foi realizado na literatura para aprofundar o conhecimento sobre a área de indústria 4.0 com o objetivo de entender as tecnologias utilizadas nesse novo cenário de indústria e como é realizada a integração de sistemas embarcados, IOT e CPS. De acordo com o que foi definido previamente no protocolo, foi feita uma *string* de busca utilizada em cada fonte, no total foram obtidos 327 artigos.

Na Tabela 8 é apresentada a quantidade de artigos que foram encontrados em cada base. Na busca inicial foram levados em consideração os anos de publicação entre 2010 e 2018. Pode ser observado que o maior número de referências retornas foi da base da IEEE 156 artigos seguido pela base digital *SpringerLinker* com 93 e ACM com 78.

Tabela 8 Artigos encontrados na busca preliminar

BIBLIOTECA	QUANTIDADE DE ARTIGOS
IEEE	156
<i>SpringerLinker</i>	93
ACM	78
Total	327

Fonte: O autor (2018).

Na Tabela 9 são apresentados os artigos que foram selecionados por título. Nesta etapa a IEEE foi quem teve maior número de publicações excluídas durante este processo de seleção. Das 156 publicações selecionadas no processo preliminar na IEEE restaram somente 72 para o próximo processo de seleção.

Tabela 9 Artigos selecionados pela leitura do título

BIBLIOTECA	QUANTIDADE DE ARTIGOS
IEEE	72
<i>SpringerLinker</i>	68
ACM	61
Total	201

Fonte: O autor (2018).

Na Tabela 10 são apresentados os artigos que foram selecionados acordo com o primeiro critério “CS1: possuir informações sobre aplicações de manutenção com IIOT em ambientes Industriais” do protocolo do MS. Podemos observar que nesta etapa todas as bases pesquisadas tiveram a maioria das publicações excluídas

Tabela 10 Artigos selecionados no primeiro filtro

BIBLIOTECA	QUANTIDADE DE ARTIGOS
IEEE	32
<i>SpringerLinker</i>	27
ACM	19
Total	78

Fonte: O autor (2018).

Na Tabela 11 são apresentados os artigos que foram selecionados no segundo critério “CS2: possuir aplicações de manutenção com IIOT baseado em manutenção preditiva” do MS. Podemos analisar que a ACM foi a base que mais teve publicações excluídas.

Tabela 11 Artigos selecionados no segundo filtro

BIBLIOTECA	QUANTIDADE DE ARTIGOS
IEEE	27
<i>SpringerLinker</i>	16
ACM	12
Total	55

Fonte: O autor (2018).

Na Tabela 12 são apresentados os artigos selecionados no terceiro critério “CS3: possuir informações sobre testes das aplicações de manutenção preditiva em cenários de Indústria 4.0” do MS. Podemos observar que a IEEE e *SpringerLinker* obtiveram a maior quantidade de artigos.

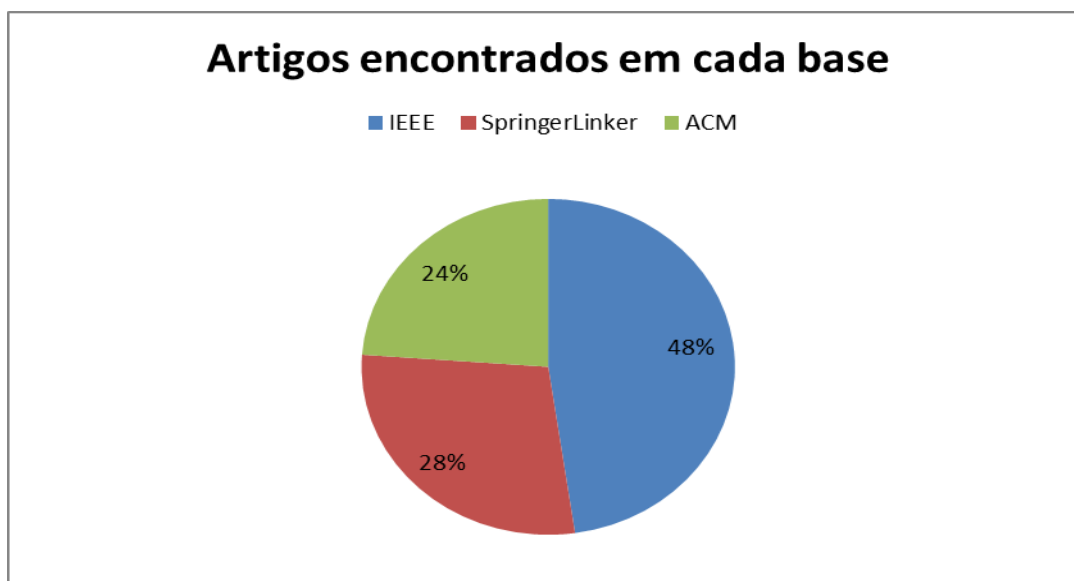
Tabela 12 Artigos selecionados no terceiro filtro

BIBLIOTECA	QUANTIDADE DE ARTIGOS
IEEE	11
<i>SpringerLinker</i>	9
ACM	3
Total	23

Fonte: O autor (2018).

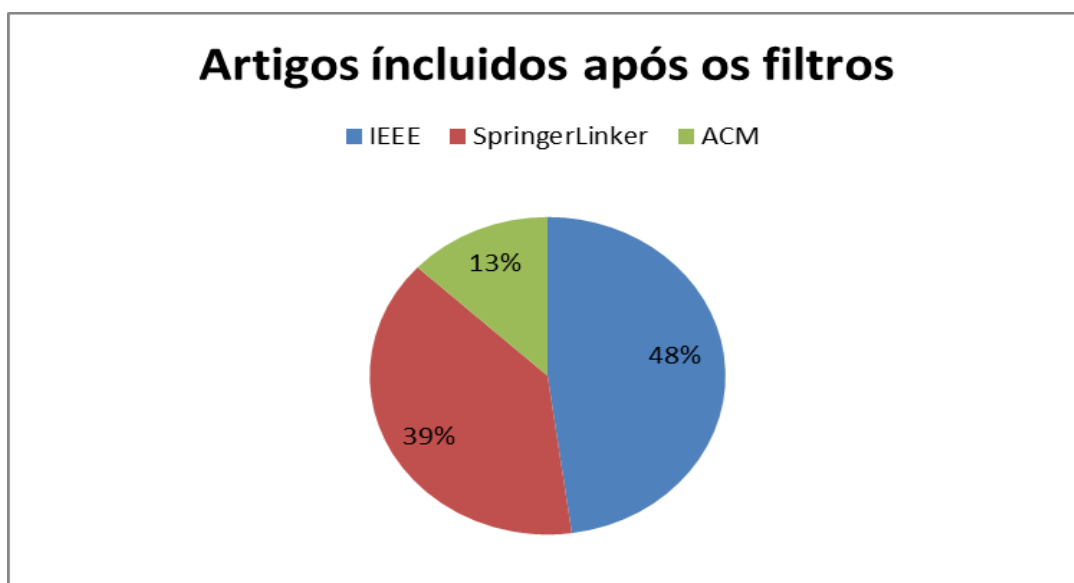
Na Figura 27 é apresentado o gráfico com o percentual das publicações encontradas em cada base das bibliotecas digitais. O menor percentual de publicações obtido foi na ACM e após a aplicação de todos os filtros, os artigos encontrados na base IEEE demonstraram mais relevância para este trabalho como mostra a Figura 28 o gráfico demonstra que 48% dos são da base da IEEE.

Figura 27 Quantidade de artigos selecionados em cada base



Fonte: O autor (2018).

Figura 28 Artigos selecionados no final do processo



Fonte: O autor (2018).

Os artigos selecionados serviram para realizar o embasamento teórico, para entender como as tecnologias de informação e comunicação podem ser utilizadas para integração de indústria inteligente seus principais desafios, ferramentas e técnicas que pudessem auxiliar no desenvolvimento da aplicação.

Com relação à questão de pesquisa proposta durante o protocolo do MS “Quais as técnicas utilizadas para implementar manutenção preditiva no contexto da Indústria 4.0?”, foram identificados dentre os 23 trabalhos resultantes do terceiro filtro 7 métodos de se

aplicar manutenção preditiva em cenários industriais que possuíssem conceitos consistentes, eram mais citados e se adequaram no contexto do trabalho, estes são apresentados na Tabela 13. Estes métodos serão analisados posteriormente com o objetivo de se identificar o mais adequado ao cenário deste trabalho

Tabela 13 Métodos de implementação para manutenção preditiva

MÉTODO	QTD DE CITAÇÕES
Mineração de Dados	12
Arvore de Regressão	4
<i>Machine Learning</i>	16
Modelo de Descoberta de Conhecimento	8
Aplicações com Dados baseados Nuvem	13
Modelo de Floresta Randômica	2
Agentes Inteligentes	11

Fonte: O autor (2018).

Com os dados da Tabela 12 pode se observar que os métodos baseados em *Big Data* como Mineração de Dados, Aplicações em Nuvem e *Machine Learning* ainda prevalecem dentro contexto de manutenção preditiva, pois quanto mais dados sobre os equipamentos estiverem disponíveis mais as aplicações poderão se tornar precisas, e a tomada de decisão poderá ser mais rápida e eficiente.

3.2 Modelo de Análise

Neste trabalho durante o processo de revisão sistemática, foram encontrados diversos métodos de processamento de dados que podem ser utilizados para o desenvolvimento da manutenção preditiva. Para escolher o mais adequado neste trabalho foram verificadas as características do cenário ao qual seria aplicado o software, e neste contexto foi identificado as seguintes definições que motivaram a escolha do método a ser seguido no desenvolvimento do software.

- Parâmetros da Máquina de Solda

Ao realizar visitas para coleta de dados dentro de um ambiente de uma fábrica de televisores, foi possível perceber que o trabalho de manutenção dentro do processo de produção SMT é manual. No caso das máquinas de solda, são designados funcionários que possuam conhecimentos de sua documentação onde são descritos os parâmetros comuns que a máquina precisa ter para que

esteja funcionando de forma correta. A Figura 29 apresenta o formulário atual de verificação diária da máquina de solda utilizados pelos funcionários.

Figura 29 Ficha de Manutenção

FICHA DE MANUTENÇÃO PREVENTIVA			
MÁQ./EQUIPAMENTO: MÁQUINA DE SOLDAR PCIs		Nº: 01	
MARCA: SOLTEC		MODELO: DELTA WAVE 6622 CC	
LOCAL INSTALADO: ÁREA DE INSERÇÃO DE TVs - FÁBRICA I			
ÍTEM A SEREM VERIFICADOS	*	N	E
- TEMPERATURA DA SOLDA (CADIM): 250°C Tolerância ± 10	250°C		
- TEMPERATURA DO PRE-AQUECEDOR ZONA 1: 400°C Tolerância ± 100	280°C		
- TEMPERATURA DO PRE-AQUECEDOR ZONA 2: 400°C Tolerância ± 100	290°C		
- TEMPERATURA DO PRE-AQUECEDOR ZONA 3: 400°C Tolerância ± 100	300°C		
- VELOCIDADE DO TRANSPORTADOR DE PCI'S: Min. 50 Máx.300 Cm /min	160 cm/min		
- ONDA CHIPWAVE: Min. 0 Máx. 450 RPM	362 RPM		
- ONDA SOLDERWAVE Min. 100 Máx. 450 RPM	260 RPM		
- DENSIDADE DO FLUXO Min. 0,797 Máx. 0,803 g/m3	0,803 g/m ³		
- BOCAL ONDA SOLDERWAVE / CHIPWAVE			X
- MOTORES DO CADIM (subida e descida)		X	
- TANQUE DO FLUXADOR			X
- FINGER / BASES		X	
- BOMBAS DO TANQUE DE SOLDA			X
- CORREIAS DAS BOMBAS DO TANQUE DE SOLDA		X	
- EXAUSTORES DE FUMAÇA			X
- VENTILADORES RESFRIADORES DE PCI'S		X	
- SISTEMA INTERNO DE TRANSP. PCIs / ENT E SAI DA SOLDA.		X	
- BOMBA DO TANQUE DE FLUXO / BOMBA LIMPEZA DOS FINGER			X
- MICRO COMPUTADOR		X	
- PEDRA AREADORA		X	
- TERMOPAR / INVERSOR DE FREQUENCIA		X	
- MANUTENÇÃO INTERNA DO CADIM			X
- RELATÓRIO -			
<p>Foi feito a limpeza nos bocais da CHIPWAVE e SOLDER WAVE e limpeza das bombas de solda limpeza do Fluxador e limpeza nos exaustores e troca da bomba de Fluxo e limpeza da bomba de Alcool e retirada da Bateria de solda do Cadim</p>			

Fonte: Adaptado do Formulário de Manutenção da Empresa (2019).

Apesar da ficha de manutenção possuir diversas informações para serem avaliadas, para o cenário da manutenção preditiva é necessário que estes valores possuam formas quantitativas de serem analisadas. Devido a esta restrição, a ficha de manutenção foi filtrada e as informações que foram utilizadas para montar o método de análise da máquina de solda estão descritas na Tabela 14.

Tabela 14 Parâmetros da Máquina de Solda


ITEM	MIN	MAX	PADRÃO	TOLERÂNCIA
Temperatura da Solda	240 ° C	260 ° C	250 ° C	±10 ° C
Temperatura do Pre-Aquecedor Zona 1	300 ° C	500 ° C	400 ° C	±100 ° C
Temperatura do Pre-Aquecedor Zona 2	300 ° C	500 ° C	400 ° C	±100 ° C
Temperatura do Pre-Aquecedor Zona 3	300 ° C	500 ° C	400 ° C	±100 ° C

Fonte: O autor (2019).

- Infraestrutura da Aplicação

O equipamento de análise proposto no módulo microcontrolador foi baseado nos parâmetros vistos anteriormente, a Figura 30 descreve a arquitetura do microcontrolador.

Figura 30 Arquitetura do Módulo Controlador



Fonte: O autor (2019).

No **Desenvolvimento do Software Embarcado e prototipação do hardware**. O sistema embarcado foi desenvolvido usando a linguagem de programação C e foram embutidos na placa controladora Arduino Uno sensores dos tipos:

- **Sensor de Temperatura Termopar:** Termopares são sensores de temperatura simples, robustos, muito confiáveis em suas medições e de baixo custo. Sendo amplamente utilizados nos mais variados processos de medição de temperatura, o termopar é constituído de dois metais distintos unidos em uma das extremidades.
- **Relés de Estado Sólido:** O Módulo Relé 5V de Estado Sólido SSR 1 Canal é um componente eletrônico que tem a mesma função dos relés convencionais (eletromecânicos), ou seja, controlar circuitos externos de grandes correntes a partir de pequenas correntes ou tensões. A grande diferença deste módulo relé para o módulo relé convencional é o fato do primeiro não possuir elementos mecânicos ou qualquer tipo de peça móvel, funcionando a partir de tiristores ao invés de contatos.
- **Sensores de Corrente:** O sensor de corrente SCT-013 é muito versátil e tem como principal vantagem o fato de não precisar de contato elétrico com o circuito para medir a corrente elétrica alternada. Ou seja, não precisamos abrir


o circuito para ligá-lo em série com a carga, basta apenas “abraçar” um dos fios ligados ao equipamento a ser monitorado.

- **Contactoras de 220 V:** O contator é um dispositivo eletromecânico, que é usado para controlar cargas em um circuito de potência a partir de um circuito de comando. Os contatores são os dispositivos de manobra mais utilizados em aplicações industriais e prediais.

O módulo escravo (coletor) foi projetado levando em consideração as características da máquina e podem ser customizados para outros equipamentos de monitoramento.

Dentro do módulo Mestre de Recepção/Transmissão de Dados (Raspberry Pi 3), é onde está configurado a troca de informações com o servidor e o Telegram. A comunicação entre o Arduino e a Raspberry Pi 3 foi feita através do protocolo I2C de acordo com a Figura 31.

Figura 31 Conexão I2C Raspberry e Arduino Uno



Fonte: Adaptado de ArduinoCia (2019).

O I2C é um barramento de transferência serial de dados, é orientado para 8 bits. As duas linhas de sinal são SCL e SDA, onde SDA é o pino que efetivamente transfere e recebe os dados e SCL serve para temporização entre os dispositivos, de modo que a comunicação pelo SDA possa ter confiabilidade entre mestre e escravo (GARCIA, 2017).

No **Arduino Uno**, os pinos **A4(SDA)** e **A5 (SCL)**, que serão conectados em uma **Raspberry Pi 3** nos pinos 3 (**SDA**) e 5 (**SCL**). No barramento I2C foi usado um conversor de nível lógico I2C, pois o nível de sinal dos pinos do Arduino é de 5V, e no Raspberry é de 3.3V.

Para enviar as informações para o servidor, o módulo mestre possui um script escrito em **NodeJS** configurado para disparar ação de acordo com as ações do usuário na interface do App definido com:

- **Socket.io:** É uma biblioteca Javascript feita para construir aplicações real-time, possibilitando uma comunicação bidirecional entre cliente e servidor. O Socket.io roda, no lado do servidor, em **NodeJS**, e, no lado do cliente, ele roda diretamente no browser, permitindo que no cenário deste trabalho a construção de uma aplicação de conversas em tempo real.
- **Telegram:** É um aplicativo para troca de mensagens, uma das suas principais características são os BOTS que são “programas robôs” que fazem determinadas tarefas automatizadas, interagindo com o usuário ou obedecendo a comandos específicos. Outro fator que contribui para a escolha deste meio de comunicação é a disponibilização de uma API (conjunto de rotinas e padrões de programação para acesso a um aplicativo de software ou plataforma baseado na Web) aberta para desenvolvedores.

Com o módulo escravo de coleta de dados e o módulo mestre de transmissão configurados, o último passo feito foi definir o processo de análise das informações que eram enviadas ao servidor. Para isso foi necessário ter em mente os dados da Tabela 14 e o conceito de manutenção preditiva definido neste trabalho, ou seja, as variáveis de análise são conhecidas bem como seus parâmetros e o intuito da aplicação foi realizar um *prognóstico* da máquina a partir da análise dos dados coletados pelos sensores.

Com estas informações o processo de mineração de dados é o que mais se adequa ao cenário deste trabalho. De acordo com Markov (2006) a mineração de dados pode ser dividida por duas grandes categorias:

- **Descritiva:** Analisa os dados e identifica similaridades (**agrupamentos**) ou associações (**regras de associações**).
- **Preditiva:** Analisa os dados que representam eventos passados buscando relações entre estes que permitam prever situações em novos dados futuros, tais como: a **classificação** para predições de valores discretos e a **regressão** para predições de valores contínuos.

Dentro do modelo deste trabalho, a categoria preditiva é a mais adequada. A Tabela 15 descreve os principais métodos de mineração que podem ser utilizados dentro desta categoria:

Tabela 15 Métodos de Análise de Dados

TIPO	MÉTODO
Classificação	Árvores de Decisão Classificação Bayesiana
Regressão	Regressão Linear

Fonte: O autor (2019).

Dentro dos métodos a serem testados, existem diversos algoritmos para análise dos dados. A Tabela 16 descreve os principais algoritmos testados nesta aplicação que podem ser utilizados através da ferramenta *WEKA* (RUSSEL e MARKOV, 2017).

Tabela 16 - Algoritmos utilizados nos Testes

MÉTODO	ALGORITMOS
Árvores de Decisão	RandomTree J48 RepTree RandomForest
Regressão Linear	LinearRegression
Classificação Bayesiana	NaiveBayes BayesNet

Fonte: O autor (2019).

É importante ressaltar que os métodos de regressão linear são utilizados geralmente para avaliar o nível de correlação entre as variáveis da base de dados, portanto no cenário desta monografia que tem por objetivo a classificação dos dados os métodos de regressão linear não se encaixam pois não retorna os dados esperados para o sistema.

A ferramenta de mineração utilizada neste trabalho foi o *WEKA*, este software é livre e do tipo *open source* para mineração de dados, desenvolvido em Java. Seu ponto forte é a tarefa de classificação, mas também é capaz de minerar regras de associação e clusters de dados (ALCALA et al., 2016).

3.3 Configuração do Ambiente de Testes

Para configurar os testes do sistema embarcado e do modelo de análise, o software embarcado foi construído de acordo com a arquitetura descrita na Figura 30. O sistema de sensores foi instalado pelo técnico da máquina devido a sua experiência com o aparelho para evitar possíveis danos ao equipamento, a Figura 32 e a Figura 33 demonstram o processo realizado pelo funcionário da empresa.

Figura 32 Instalação dos Sensores na Máquina de Solda



Fonte: O autor (2019).

Figura 33 Instalação do Relé e Contactora



Fonte: O autor (2019).

Para realizar a transmissão dos dados, a placa Raspberry Pi 3 foi configurada para acessar a rede da própria fábrica através da interface *ETHERNET*.

Na ferramenta *WEKA* inicialmente foi escolhido a metodologia de testes que seria utilizada. Os experimentos foram configurados usando a abordagem de divisão da base de dados (*Percentagem Split*) conforme Hall et al. (2009), onde foram considerando três cenários:

- Considerando 50% para treinamento e 50% para os testes

- Considerando 70% para treinamento e 30% para os testes
- Considerando 80% para treinamento e 20% para os testes

A Percentagem Split consiste em separar a base de dados em subconjuntos de treinamento com o percentual da base definida durante a fase de pré-processamento a fim de treinar o reconhecimento do padrão em busca da melhoria dos resultados estatísticos, fazendo uma comparação de treinamentos diferentes da base (HALL et al., 2009).

Para avaliar a qualidade do método, foram avaliadas as métricas geradas pela própria ferramenta de mineração. No *WEKA*, existe a chamada matriz de confusão que fornece as informações necessários para avaliar a aplicabilidade do método proposto.

A matriz de confusão é dada por uma tabela de contingência onde na **linha** está o valor previsto e na **coluna** está o valor verdadeiro observado. Nesta matriz também é possível obter o cálculo da acurácia ACC, Precisão, Verdadeiro Positivo também chamado de “Recall” VPP e Verdadeiro Negativo, VPN. As equações (1), (2), (3) e (4) apresentam os parâmetros avaliados (CHANDRASEKAR et al., 2017).

$$Acurácia = \frac{Verdadeiros\ Positivos\ (TP) + Verdadeiros\ Negativos\ (VN)}{Total} \quad (1)$$

$$Precisão = \frac{Verdadeiros\ Positivos\ (TP)}{Verdadeiros\ Positivos\ (TP) + Falsos\ Positivos\ (FP)} \quad (2)$$

$$Recall = \frac{Verdadeiros\ Positivos\ (TP)}{Verdadeiros\ Positivos\ (TP) + Falsos\ Negativos\ (FN)} \quad (3)$$

$$F1 = \frac{2 * precisão * recall}{precisão + recall} \quad (4)$$

Os testes realizados serão descritos posteriormente. A base de dados que foi analisada foi construída por meio da coleta de dados realizada pelos sensores implantados no módulo escravo de coleta definido na arquitetura.

3.4 Testes de Comunicação

Para analisar a comunicação dos dispositivos e a transmissão das informações pela rede foram utilizados os testes definidos previamente na metodologia: **PING**, **TRACERT**, **ROUTE** e **NETSTAT**. A Figura 34, Figura 35, Figura 36 e Figura 37 descrevem os resultados dos testes de rede realizados.

Figura 34 - PING

```

Disparando 192.168.2.1 com 32 bytes de dados:
Resposta de 192.168.2.1: bytes=32 tempo=2ms TTL=64
Resposta de 192.168.2.1: bytes=32 tempo=4ms TTL=64
Resposta de 192.168.2.1: bytes=32 tempo=5ms TTL=64
Resposta de 192.168.2.1: bytes=32 tempo=3ms TTL=64

Estatísticas do Ping para 192.168.2.1:
  Pacotes: Enviados = 4, Recebidos = 4, Perdidos = 0 (0% de
  perda),
Aproximar um número redondo de vezes em milissegundos:
  Mínimo = 2ms, Máximo = 5ms, Média = 3ms

```

Fonte: O autor (2019).

Figura 35 - TRACERT

```

 1   3 ms   1 ms   1 ms  192.168.2.1
 2  46 ms   *     *     100.80.0.1
 3   *     11 ms  11 ms 172.31.150.113
 4   8 ms   9 ms   8 ms  172.19.1.5
 5  11 ms   *     *     172.19.1.2
 6  10 ms   7 ms   8 ms  8.8.8.8

Rastreamento concluído.

```

Fonte: O autor (2019).

Figura 36 - ROUTE

```

Rotas ativas:
Endereço de rede      Máscara  Ender. gateway  Interface  Custo
0.0.0.0               0.0.0.0  192.168.2.1    192.168.2.27  55
127.0.0.0            255.0.0.0  No vínculo     127.0.0.1    331
127.0.0.1            255.255.255.255  No vínculo     127.0.0.1    331
127.255.255.255     255.255.255.255  No vínculo     127.0.0.1    331
192.168.2.0         255.255.255.0  No vínculo     192.168.2.27  311
192.168.2.27       255.255.255.255  No vínculo     192.168.2.27  311
192.168.2.255     255.255.255.255  No vínculo     192.168.2.27  311
224.0.0.0           240.0.0.0  No vínculo     127.0.0.1    331
224.0.0.0           240.0.0.0  No vínculo     192.168.2.27  311
255.255.255.255   255.255.255.255  No vínculo     127.0.0.1    331
255.255.255.255   255.255.255.255  No vínculo     192.168.2.27  311
=====

```

Fonte: O autor (2019).

Figura 37 - NETSTAT

```

Conexões ativas

Proto  Endereço local      Endereço externo  Estado
TCP    192.168.2.27:54939   mia04-012:http    ESTABLISHED
TCP    192.168.2.27:55099   52.177.166.224:https ESTABLISHED
TCP    192.168.2.27:55100   52.177.166.224:https ESTABLISHED
TCP    192.168.2.27:55103   ce:5228           ESTABLISHED
TCP    192.168.2.27:55241   a2-16-188-43:https CLOSE_WAIT
TCP    192.168.2.27:55258   ec2-54-187-216-46:https ESTABLISHED
TCP    192.168.2.27:55265   104.20.184.68:https ESTABLISHED
TCP    192.168.2.27:55266   cae-xprp-alln-vip:https ESTABLISHED
TCP    192.168.2.27:55269   cae-xprp-rcdn-vip:https ESTABLISHED
TCP    192.168.2.27:55273   cae-xprp-alln-vip:https ESTABLISHED
TCP    192.168.2.27:55274   cae-xprp-alln-vip:https ESTABLISHED

```

Fonte: O autor (2019).

Devido a infraestrutura de rede já estar construída na empresa, o roteador foi configurado com o endereço DHCP e os testes obtiveram ótimos resultados. Os comandos *TRACERT*, *ROUTE* e *NETSTAT* foram bem-sucedidos e no comando *PING* a maior taxa de perda nos testes foi de 8%. Portanto a comunicação e transmissão dos dados conseguiu atingir a característica de *real time* da aplicação.

3.6 Testes na Ferramenta de Mineração

A ferramenta de mineração de dados *WEKA* foi utilizada nessa fase para a geração do modelo de decisão a ser aplicada na arquitetura da aplicação. A Figura 38 mostra a estrutura de dados em arquivo texto com extensão **ARFF** (*Attribute-Relation File Format*), utilizado pela ferramenta de mineração para extração das características.

Figura 38 - Arquivo Arff Base de Dados

```

1 @relation machine_data
2
3 @attribute Temp_Solda numeric
4 @attribute Temp_Z1 numeric
5 @attribute Temp_Z2 numeric
6 @attribute Temp_Z3 numeric
7 @attribute Corrente numeric
8 @attribute classification {'Normal', 'Solda_Fria', 'Solda_Superaquecida',
9   'Baixa Temperatura', 'Alta Temperatura', 'Maquina Desligada', 'Z1 Alta Temperatura',
10  'Z1 Baixa Temperatura', 'Z2 Alta Temperatura', 'Z2 Baixa Temperatura', 'Z3 Alta Temperatura',
11  'Z3 Baixa Temperatura'}
12
13 @data
14
15 240,305,410,300,1,'Normal'
16 240,305,410,300,1,'Normal'
17 240,305,410,300,1,'Normal'
18 240,305,410,300,1,'Normal'
19 240,305,410,300,1,'Normal'
20 240,305,410,300,1,'Normal'
21 240,305,410,300,1,'Normal'

```

Fonte: O autor (2019).

O arquivo **ARFF** utilizado pelo *WEKA* possui uma estrutura com anotações. O caractere “@” indica o início da declaração dos atributos. Na linha 8 o atributo *classification* (classificação) determina, os estados pré-classificados da máquina. Neste trabalho foram definidos 12 estados que dependem dos dados que forem coletados da máquina e dos parâmetros definidos na ficha de manutenção, eles são:

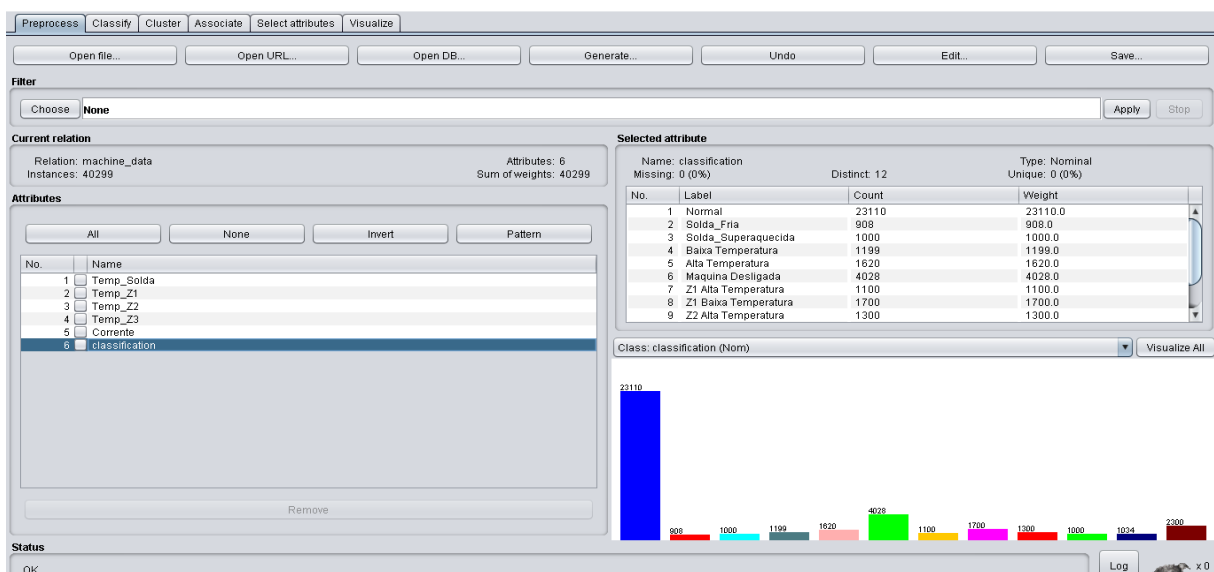
- Estado ‘*Normal*’ - **NM**: Se a máquina estiver funcionando corretamente
- Estado ‘*Solda Fria*’ - **SF**: Se a solda não estiver na temperatura definida nos parâmetros.
- Estado ‘*Solda Superaquecida*’ - **SSA**: Se a solda estiver acima da temperatura definida.
- Estado ‘*Baixa Temperatura*’ - **BT**: Se as zonas da máquina estiverem com a temperatura inferior ao parâmetro mínimo estabelecido.
- Estado ‘*Alta Temperatura*’ - **AT**: Se as zonas da máquina estiverem com a temperatura superior ao parâmetro máximo estabelecido.

- Estado ‘*Máquina Desligada*’ - **MD**: Se não houver dados sendo transmitidos pela máquina, neste cenário.
- Estado ‘*Z1 Alta Temperatura*’ – **Z1AT**: Se a zona 1 da máquina estiver com a temperatura superior ao parâmetro máximo estabelecido.
- Estado ‘*Z1 Baixa Temperatura*’ – **Z1BT**: Se a zona 1 da máquina estiver com a temperatura inferior ao parâmetro mínimo estabelecido.
- Estado ‘*Z2 Alta Temperatura*’ – **Z2AT**: Se a zona 2 da máquina estiver com a temperatura superior ao parâmetro máximo estabelecido.
- Estado ‘*Z2 Baixa Temperatura*’ – **Z2BT**: Se a zona 2 da máquina estiver com a temperatura inferior ao parâmetro mínimo estabelecido.
- Estado ‘*Z3 Alta Temperatura*’ – **Z3AT**: Se a zona 3 da máquina estiver com a temperatura superior ao parâmetro máximo estabelecido.
- Estado ‘*Z3 Baixa Temperatura*’ – **Z3BT**: Se a zona 3 da máquina estiver com a temperatura inferior ao parâmetro mínimo estabelecido.

Cada linha marcada a partir da anotação @data, linha 13, corresponde a uma instância passada para o classificador treinar e gerar os modelos de árvore de decisão e regras. O exemplo da linha 15 treina o algoritmo para identificar o estado *Normal* da máquina.

A ferramenta de mineração de dados permite que sejam aplicados filtros para melhorar o poder do classificador e durante os experimentos eles foram aplicados para omitir dados da base que não possuem ganho de informação considerável. A Figura 39 apresenta a interface inicial do software ao inserir o arquivo **ARFF** da base de dados.

Figura 39 - Interface Inicial da Ferramenta de Mineração



Fonte: O autor (2019).

É possível observar que a ferramenta faz a leitura do *dataset* e em seguida faz o carregamento com algumas estatísticas predefinidas tais como, a distribuição do conjunto de dados, contagem e peso dos atributos. Com a base incluída dentro do software, foram aplicados os algoritmos citados anteriormente.

Inicialmente foram aplicados os algoritmos baseados em árvore de decisão (J48, RandomTree, RepTree, RandomForest) com a taxa de *Percentagem Split* variável de acordo com que foi definido na configuração do ambiente. Os resultados dos algoritmos executados estão descritos na Tabela 17, Tabela 18 e na Tabela 19.

Tabela 17 - Resultados dos Testes nos Modelos de Árvore (50% -50%)

ALGORITMO	ERRO QUADRÁTICO (%)	ERRO ABSOLUTO (%)	TAXA TP (%)	TAXA FP (%)	PRECISION (%)	RECALL (%)	F1 SCORE (%)	ROC AREA (%)
J48	0,0857	0,0144	0,939	0,009	0,951	0,939	0,939	0,993
RandomTree	0,0849	0,0142	0,939	0,009	0,951	0,939	0,939	0,997
RepTree	0,0857	0,0144	0,939	0,009	0,951	0,939	0,939	0,993
RandomForest	0,0849	0,0142	0,939	0,009	0,951	0,939	0,939	0,997

Fonte: O autor (2019).

Tabela 18 - Resultados dos Testes nos Modelos de Árvore (70% -30%)

ALGORITMO	ERRO QUADRÁTICO (%)	ERRO ABSOLUTO (%)	TAXA TP (%)	TAXA FP (%)	PRECISION (%)	RECALL (%)	F1 SCORE (%)	ROC AREA (%)
J48	0,0852	0,0145	0,940	0,009	0,951	0,940	0,940	0,993
RandomTree	0,0844	0,0143	0,940	0,009	0,951	0,940	0,940	0,997
RepTree	0,0852	0,0145	0,940	0,009	0,951	0,940	0,940	0,993
RandomForest	0,0844	0,0143	0,940	0,009	0,951	0,940	0,940	0,997

Fonte: O autor (2019).

Tabela 19 - Resultados dos Testes nos Modelos de Árvore (80% -20%)

ALGORITMO	ERRO QUADRÁTICO (%)	ERRO ABSOLUTO (%)	TAXA TP (%)	TAXA FP (%)	PRECISION (%)	RECALL (%)	F1 SCORE (%)	ROC AREA (%)
J48	0,0851	0,0145	0,940	0,009	0,951	0,940	0,940	0,993
RandomTree	0,0844	0,0143	0,940	0,009	0,951	0,940	0,940	0,997
RepTree	0,0851	0,0145	0,940	0,009	0,951	0,940	0,940	0,993
RandomForest	0,0843	0,0143	0,940	0,009	0,951	0,940	0,940	0,997

Fonte: O autor (2019).

Nos primeiros testes todos modelos de árvore obtiveram dados semelhantes acerto, porém os dados com *Percentagem Split* de 70% - 30% foram os que obtiveram os melhores resultados de acordo com a Tabela 20.

Tabela 20 - Porcentagem de Acerto dos Splits

PERCENTAGEM SPLIT	PORCENTAGEM DE ACERTO
50% - 50%	93,8806
70% - 30%	94,0303
80% - 20%	94,0290

Fonte: O autor (2019).

. Dentre os quatro modelos testados, para definir qual o melhor modelo para este trabalho, também foram analisadas as características de tempo e também a medição da área de ROC (*Receiver Operating Characteristic*). O objetivo das Curvas ROC é examinar o desempenho de um classificador binário, criando um gráfico dos Positivos Verdadeiros vs. Positivos Falsos para cada limite de classificação (SEWAIWAR E VERMA, 2015), a Tabela 21 descreve os resultados desta análise.


Tabela 21 - Resultados Percentagem Split 70% - 30%

ALGORITMO	ACERTO (%)	ROC (%)	TEMPO (s)
J48	94,0303	0,993	0,27
RandomTree	94,0303	0,997	0,26
RepTree	94,0303	0,993	0,12
RandomForest	94,0303	0,997	0,74

Fonte: O autor (2019).

De acordo com os dados da Tabela 21, os algoritmos que possuem melhor desempenho de tempo e medição de ROC são os que tem base randômica, porém o algoritmo que possui melhor tempo de execução foi o *RandomTree* e este foi escolhido para ser avaliado com o resultado dos próximos testes. A Figura 40 demonstra no gráfico de ROC dos algoritmos testados.

Figura 40 - Gráfico de ROC 70% - 30%



Fonte: O autor (2019).

No gráfico acima, foi traçado uma linha de tendência de forma a simplificar o entendimento a análise da ROC. Esta linha divide os dados em dois limiares, variando no valor de 0 até 1 e é denominado como AUC (*Area Under the ROC Curve*) onde o valor 0,5 é o valor médio, ou seja, quanto maior o valor do AUC melhor é o desempenho do algoritmo.

Nos próximos testes foram aplicados os algoritmos baseados em classificação bayesiana (*NaiveBayes*, *BayesNet*) com a taxa de *Percentagem Split* variável de acordo com

que foi definido na configuração do ambiente. Os resultados dos algoritmos executados estão descritos na Tabela 22, Tabela 23 e na Tabela 24.

Tabela 22 - Resultados dos Testes nos Modelos de NaiveBayes (50% -50%)

ALGORITMO	ERRO QUADRÁTICO (%)	ERRO ABSOLUTO (%)	TAXA TP (%)	TAXA FP (%)	PRECISION (%)	RECALL (%)	F1 SCORE (%)	ROC AREA (%)
NaiveBayes	0.1467	0.0383	0,816	0,013	0,910	0,816	0,845	0,965
BayesNet	0.0902	0.0117	0,939	0,009	0,951	0,939	0,939	0,997

Fonte: O autor (2019).

Tabela 23 - Resultados dos Testes nos Modelos de NaiveBayes (70% -30%)

ALGORITMO	ERRO QUADRÁTICO (%)	ERRO ABSOLUTO (%)	TAXA TP (%)	TAXA FP (%)	PRECISION (%)	RECALL (%)	F1 SCORE (%)	ROC AREA (%)
NaiveBayes	0.1467	0.0383	0,816	0,013	0,910	0,816	0,845	0,966
BayesNet	0.0887	0.0118	0,940	0,009	0,951	0,940	0,940	0,997

Fonte: O autor (2019).

Tabela 24 - Resultados dos Testes nos Modelos de NaiveBayes (80% -20%)

ALGORITMO	ERRO QUADRÁTICO (%)	ERRO ABSOLUTO (%)	TAXA TP (%)	TAXA FP (%)	PRECISION (%)	RECALL (%)	F1 SCORE (%)	ROC AREA (%)
NaiveBayes	0.1466	0.0383	0,816	0,013	0,910	0,816	0,844	0,966
BayesNet	0.0883	0.0119	0,940	0,009	0,951	0,940	0,940	0,997

Fonte: O autor (2019).

Nos testes dos modelos de classificação bayesiana obtiveram dados bastante variados dependendo da *Percentagem Split* utilizada, a Tabela 25 descreve a porcentagem de acerto em cada caso para os algoritmos analisados.

Tabela 25 - Resultados dos Testes de Split com Classificação Bayesiana

PERCENTAGEM SPLIT	ALGORITMO	PORCENTAGEM DE ACERTO
50% - 50%	NaiveBayes	81,6368
50% - 50%	BayesNet	93,8806
70% - 30%	NaiveBayes	81,5803
70% - 30%	BayesNet	94,0303
80% - 20%	NaiveBayes	81,5751
80% - 20%	BayesNet	94,029

Fonte: O autor (2019).

De acordo com os dados da Tabela 25, o melhor cenário de testes encontrado foi na *Percentagem Split* de 70% - 30% onde se obteve a maior taxa de acerto pelo algoritmo **BayesNet**. O algoritmo *NaiveBayes* teve um desempenho relativamente inferior, e isto acontece devido a característica que denomina este algoritmo, ou seja, a “ingenuidade” que faz com **dentro da base** de dados seja considerado que existe a **independência** entre os atributos. No cenário deste trabalho, como foi dito anteriormente, para se classificar um

estudo as variáveis são avaliadas como um conjunto e a combinação de seus valores gera o estado final e esta característica diminui a taxa de acerto do algoritmo.

Para definir qual método se adapta melhor ao cenário da monografia, foi comparado os 2 algoritmos que obtiveram os melhores resultados dentro da ferramenta de mineração. A Tabela 26 descreve os dados que foram utilizados para realizar a comparação:

Tabela 26 - Comparação entre os melhores algoritmos

ALGORITMO	ACERTO (%)	ERRO QUADRÁTICO (%)	ERRO ABSOLUTO (%)	F1 SCORE (%)	ROC AREA (%)	TEMPO (s)
RandomTree	94,0834	0,0837	0,0142	0,941	0,997	0,04
BayesNet	94,0834	0,0897	0,0117	0,941	0,997	0,14

Fonte: O autor (2019).

Na tabela acima é possível perceber que os algoritmos possuem resultados muito semelhantes, entretanto existem algumas diferenças que foram utilizadas na escolha do método de análise. Para justificar a escolha os seguintes atributos foram levados em consideração:

- Erro Quadrático – RMSD (*Root Mean Square Error*): Medida das diferenças entre os valores (amostra e população) previstos por um modelo ou estimador e os valores realmente observados. Representa o desvio padrão da amostra das diferenças entre os valores previstos e os valores observados. Isto agrega as magnitudes dos erros nas previsões por vários tempos em uma única medida de poder preditivo (WANG, 2018). O RMSD é calculado para n previsões em tempos t de acordo com a equação (5):

$$\text{RMSD} = \sqrt{\frac{\sum_{t=1}^n (\hat{y}_t - y)^2}{n}}. \quad (5)$$

- Erro Absoluto – MAE (*Mean Absolute Error*): A métrica MAE não leva em conta se o erro foi superestimado ou subestimado, caracterizando-se por ser a média dos erros cometidos pelo modelo de previsão durante uma série de execuções (WANG, 2018). O MAE é calculado por meio da equação (6):

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |f_i - y_i| = \frac{1}{n} \sum_{i=1}^n |e_i|. \quad (6)$$

Onde F_i é o valor de predição e Y_i é o valor real.

Com os valores de comparação definidos, a Tabela 27 demonstra os resultados de cada algoritmo avaliando os dois aspectos:

Tabela 27 - Análise Comparativa


ALGORITMO	ERRO QUADRÁTICO (%)	ERRO ABSOLUTO (%)
RandomTree	0,0837	0,0142
BayesNet	0,0897	0,0117

Fonte: O autor (2019).

De acordo com a Tabela 27 o algoritmo *RandomTree* foi o que possuiu os menores valores para as métricas de erro, outro fator que ajudou na escolha foi o tempo de execução do algoritmo na ferramenta *WEKA* o qual é **10s** mais rápido se comparado com o *BayesNet*.

Para representar melhor o desempenho dos métodos a Figura 41 demonstra o gráfico de ROC dos dois melhores algoritmos.

Figura 41 Gráfico de ROC dos melhores algoritmos 70% - 30%

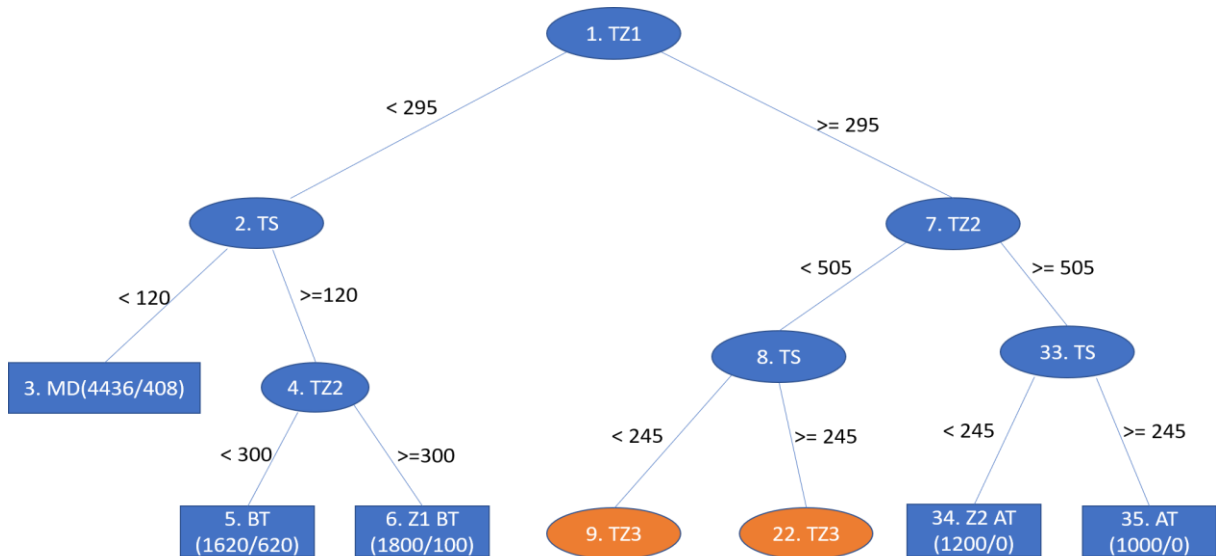


Fonte: O autor (2019).

O gráfico da Figura 37 confirma que os dois algoritmos possuem boa performance na base de dados, portanto a escolha do *RandomTree* foi baseada apenas nas métricas de erro e também pela capacidade de visualização da árvore e pseudocódigo do algoritmo que contribuíram bastante para a codificação do software.

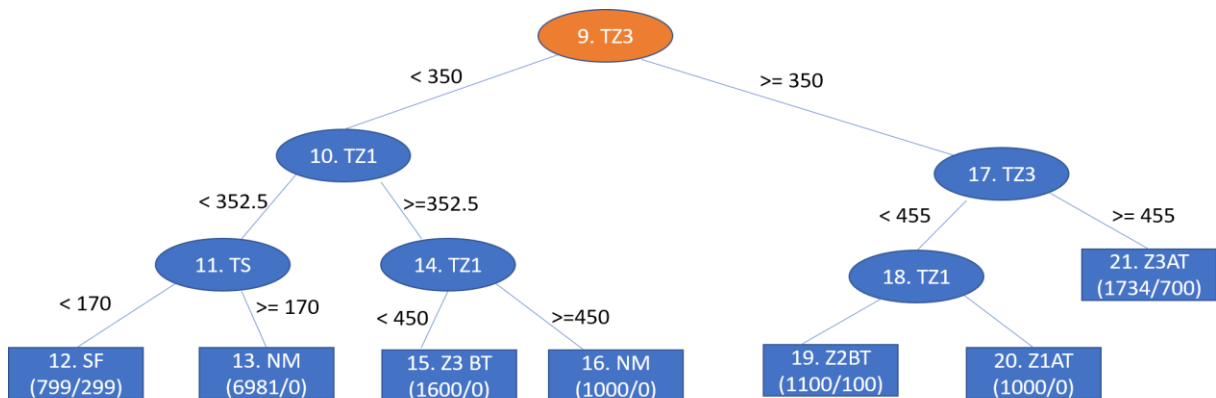
A partir da escolha do método *RandomTree*, por meio da ferramenta *WEKA* é possível visualizar a árvore gerada como está demonstrado na Figura 42, Figura 43 e na Figura 44.

Figura 42 - Nível 1 Árvore Binária



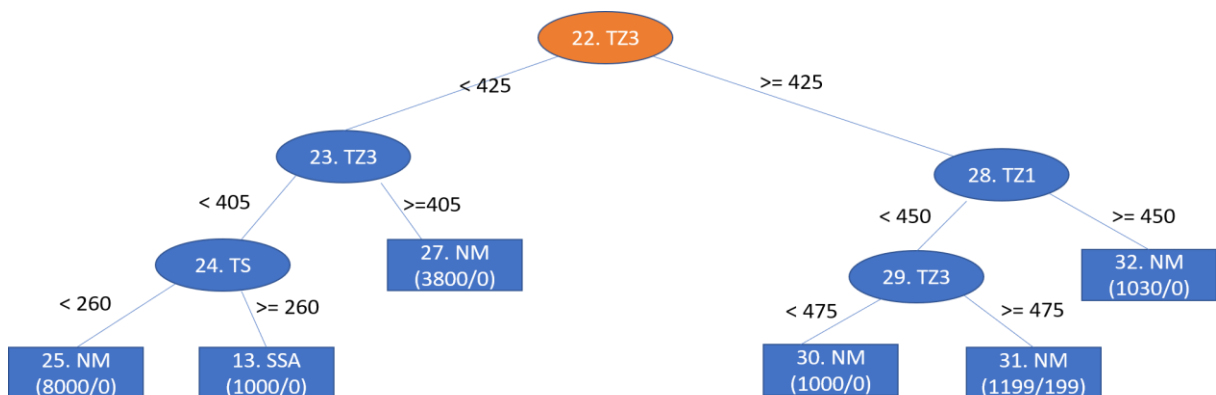
Fonte: O autor (2019).

Figura 43 - Nível 2 Árvore Binária



Fonte: O autor (2019).

Figura 44 - Nível 3 Árvore Binária



Fonte: O autor (2019).

A partir da análise da árvore gerada, é possível criar o pseudocódigo que também é fornecido pela ferramenta *WEKA* de acordo com a Figura 45.

Figura 45 - Pseudocódigo gerado pelo WEKA

```

1 Algoritmo "MachineData"
2 // Autor(a) : Diogo Manoel Pereira dos Santos
3 Var
4   Temp_z1: inteiro
5   Temp_z2: inteiro
6   Temp_z3: inteiro
7   Temp_Solda: inteiro
8   loop: logico
9 Inicio
10 repita
11   leia(Temp_z1)
12   leia(Temp_z2)
13   leia(Temp_z3)
14   leia(Temp_Solda)
15   se Temp_z1 < 295
16     se Temp_Solda < 120 entao
17       escreval("Máquina está Desligada")
18     senao se Temp_Solda >= 120
19       se Temp_z2 < 300 entao
20         escreval("A máquina esta com Baixa Temperatura")
21       se Temp_z2 >=300 entao
22         escreval("Zona 1 com Baixa Temperatura")
23       //Prosseguem as condições de acordo com os Ramos da Árvore
24 até loop <- verdadeiro
25 Fimalgoritmo

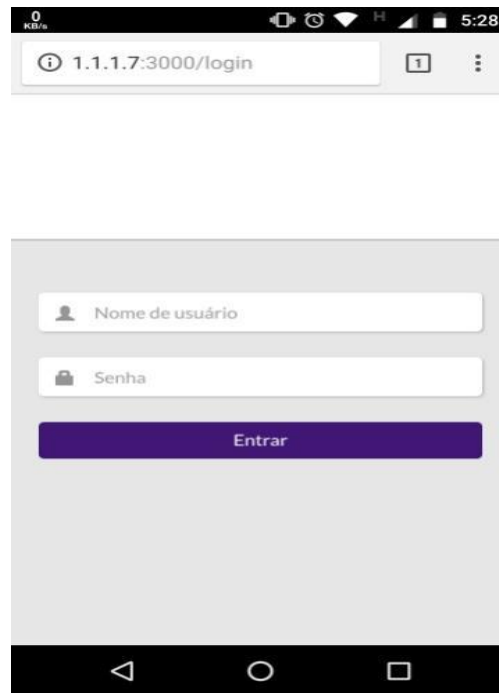
```

Fonte: O autor (2019).

O pseudocódigo segue a mesma estrutura da árvore, na Figura 41 vemos algumas das condições que correspondem ao ramo direito da Figura 38. O código desenvolvido coleta dados constantemente em *loop* infinito e os dados recebidos são processados pelo método de análise retornando as mensagens que serão disparadas para o usuário caso sejam encontradas anormalidades nos parâmetros da máquina de solda.

3.7 Telas do Sistema

A aplicação foi desenvolvida para rodar tanto em celulares quanto em *desktops* e foi construída para ser de fácil utilização e simples de se entender as informações da máquina. A descrição das telas será descrita na Figura 46, Figura 47, Figura 48 e na Figura 49.

Figura 46 - Tela de Login

Fonte: O autor (2019).

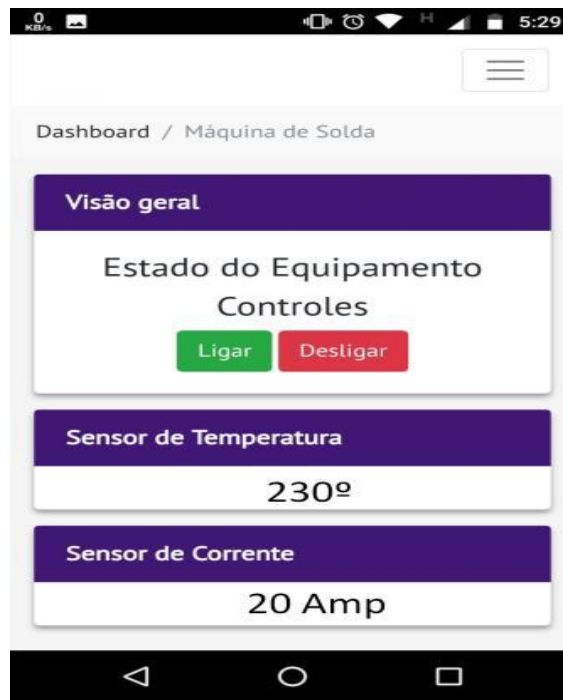
A tela inicial do sistema é referente ao *login* onde serão solicitadas as informações de acesso do funcionário da empresa já cadastrados no sistema. O login é importante para manter um nível de segurança da aplicação, pois a mesma trabalha com informações que somente os usuários autorizados poderão ter acesso.

Figura 47 - Dashboard

Fonte: O autor (2019).

A tela do usuário do sistema é referente ao *dashboard* onde serão exibidas as máquinas cadastradas, nesta tela o usuário poderá verificar os detalhes de cada máquina e enviar as informações para a máquina por meio dos botões de ação.

Figura 48 - Informações da Máquina



Fonte: O autor (2019).

A tela mais importante do sistema é referente a *Máquina de Solda* onde serão exibidas as informações que estão sendo coletadas (*real time*) pelo módulo escravo que são:

- Estado da Máquina (Ligada ou Desligada)
- Temperatura Atual da Solda – Vale ressaltar que a temperatura das zonas será utilizada no modelo de análise
- Corrente – Consumo da máquina. Que **posteriormente** poderá ser utilizada para calcular o gasto que a empresa tem com a máquina.

O usuário poderá executar duas ações nesta tela:

- Ligar: Envia sinal para o relé acionar a contatora para ligar a máquina.
- Desligar: Envia sinal para o relé acionar a contatora para desligar a máquina.

Figura 49 - Notificações



Fonte: O autor (2019).

Como foi mencionado na configuração do sistema, dentro do módulo servidor foi desenvolvido um algoritmo em *Nodejs* para transmissão das informações. O fluxo do processo segue três passos:

- Coleta de Dados: os sensores do módulo escravo coletam os dados em tempo real e enviar para o servidor.
- Processamento dos Dados: Dentro do servidor os dados são processados e classificados de acordo com os parâmetros estabelecidos.
- Notificação de Anomalias: Caso sejam encontrados parâmetros inválidos o sistema dispara a notificação via *Telegram* para os telefones cadastrados.

O sistema é relativamente de fácil utilização, inicialmente apenas para o usuário administrador receber alertas de possíveis falhas da máquina ou previsões de erros. Caso o usuário realize *logout* o sistema retorna para a tela de *login* porém as informações continuarão a ser coletadas e serem salvas no banco da aplicação.

É importante ressaltar que o sistema de notificações é independente do sistema *web*, ou seja, mesmo que o usuário não esteja logado no sistema as notificações ainda são disparadas caso sejam encontradas anomalias na máquina de solda.

4 CONCLUSÃO E PERSPECTIVAS FUTURAS

4.1 Considerações Finais

A manutenção preditiva veio ganhando grande visibilidade com o crescimento da Internet das Coisas nos últimos anos, o cenário da indústria 4.0 está se tornando tendência para os próximos anos no ambiente industrial e, portanto, é necessário que existam sistemas que adaptem as empresas para este novo contexto.

Este trabalho teve como objetivo construir uma aplicação utilizando os conceitos da manutenção preditiva para monitorar o estado do equipamento *máquina de solda* em um ambiente real de uma empresa, para isso foi necessário realizar um mapeamento sistemático dos principais trabalhos nesta área devido ao assunto ser bastante novo, o que ajudou na construção do método de análise e do software embarcado de coleta de dados.

O método proposto foi testado utilizando diversos tipos de algoritmos, após a análise dos resultados foi utilizado o método *RandomTree* que obteve uma taxa de acerto de 94.0834% que comprova o poder de classificação do algoritmo em cima dos dados gerados pela aplicação. O sistema também possui um módulo de controle através de uma aplicação *mobile* que permite ao usuário monitorar o estado da máquina e efetuar ações remotamente.

Dentro do contexto de indústria 4.0 a aplicação construída contribui com uma solução barata e de fácil implantação capaz de facilitar os processos de manutenção das empresas e aumentar a vida útil das máquinas influenciando na produtividade e gastos da indústria.

4.2 Limitações

Nesta monografia, o parâmetro de densidade do fluxo da máquina de solda não foi levado em consideração, pois não foi encontrado um sensor usado no Arduino para realizar a medição deste tipo de dado. Quanto ao método de análise, o sistema inicialmente realiza manutenção preventiva, e somente poderá realizar as predições quando os dados da base forem suficientes, o que necessita de tempo de coleta de dados que não foi medido.

4.3 Trabalhos Futuros

Como trabalhos futuros, pretende-se verificar meios de medição da densidade o que aumentará a quantidade de parâmetros gerados pela máquina e influenciara na precisão do método de análise. No método de análise serão analisados os resultados utilizando algoritmos híbridos na base de dados e atualizar a aplicação para calcular o gasto que a máquina gera baseado no consumo de corrente capturado nos sensores que vai agregar mais valor ao software no mercado.

REFERÊNCIAS

- ALCALA-FDEZ, Jesus et al. Comparison of KEEL versus open source Data Mining tools: **Knime and Weka software**. 2016.
- AMITH, C. A. et al. Predictive analysis for industrial maintenance automation and optimization using a smart sensor network. In: **Next Generation Intelligent Systems (ICNGIS), International Conference on**. IEEE, 2016. p. 1-5.
- BALASINGHAM, Kajanth. **Industry 4.0: Securing the Future for German Manufacturing Companies**. 2016. Dissertação de Mestrado. University of Twente.
- BELLO, Oladayo; ZEADALLY, Sherali. Intelligent device-to-device communication in the internet of things. **IEEE Systems Journal**, v. 10, n. 3, p. 1172-1182, 2016.
- CANIZO, Mikel et al. Real-time predictive maintenance for wind turbines using Big Data frameworks. **arXiv preprint arXiv:1709.07250**, 2017.
- CARMONA, Tadeu. **Treinamento Avançado em Redes de Computadores**. 1. Ed. São Paulo: Digerati Books, 2006. 128 p.
- CHANDRASEKAR, Priyanga et al. Improving the prediction accuracy of decision tree mining with data preprocessing. In: **2017 IEEE 41st Annual Computer Software and Applications Conference (COMPSAC)**. IEEE, 2017. p. 481-484.
- CHIU, Yu-Chen; CHENG, Fan-Tien; HUANG, Hsien-Cheng. Developing a factory-wide intelligent predictive maintenance system based on Industry 4.0. **Journal of the Chinese Institute of Engineers**, v. 40, n. 7, p. 562-571, 2017.
- CRISTALLI, C et al. **A Cyber-Physical System Approach for the Design of a Modular Smart Robotic Cell**. p. 0–5, 2016.
- DRATH, Rainer; HORCH, Alexander. Industrie 4.0: Hit or hype?[industry forum]. **IEEE industrial electronics magazine**, v. 8, n. 2, p. 56-58, 2014.
- FERREIRA, Luis Lino et al. A pilot for proactive maintenance in industry 4.0. In: **Factory Communication Systems (WFCS), 2017 IEEE 13th International Workshop on**. IEEE, 2017. p. 1-9.
- FIRJAN, BRASIL. Federação das Indústrias do Estado do Rio de Janeiro Sistema. Indústria 4.0: Internet Das Coisas. Rio de Janeiro, RJ. 38p., 2016.
- FORBES, Michael G. et al. Model predictive control in industry: Challenges and opportunities. **IFAC-PapersOnLine**, v. 48, n. 8, p. 531-538, 2015.
- GARCÍA GIORGINI, Omar. **Sistema de domótica mediante Raspberry PI e internet**. 2017. Tese de Doutorado. Universidad Nacional de Mar del Plata. Facultad de Ingeniería. Argentina.
- GORECKY, Dominic et al. Human-machine-interaction in the industry 4.0 era. In: **Industrial Informatics (INDIN), 2014 12th IEEE International Conference on**. Ieee, 2014. p. 289-294.
- HALL, Mark et al. The WEKA data mining software: an update. **ACM SIGKDD explorations newsletter**, v. 11, n. 1, p. 10-18, 2009.
- HENRIQUEZ, Patricia et al. Review of automatic fault diagnosis systems using audio and vibration signals. **IEEE Transactions on Systems, Man, and Cybernetics: Systems**, v. 44, n. 5, p. 642-652, 2014.
- HERMANN, Mario; PENTEK, Tobias; OTTO, Boris. Design principles for industrie 4.0 scenarios. In: **System Sciences (HICSS), 2016 49th Hawaii International Conference on**. IEEE, 2016. p. 3928-3937.

- JAZDI, Nasser. Cyber physical systems in the context of Industry 4.0. In: **Automation, Quality and Testing, Robotics, 2014 IEEE International Conference on**. IEEE, 2014. p. 1-4.
- KANG, Hyoung Seok et al. Smart manufacturing: Past research, present findings, and future directions. **International Journal of Precision Engineering and Manufacturing-Green Technology**, v. 3, n. 1, p. 111-128, 2016.
- KITCHENHAM, Barbara et al. Systematic literature reviews in software engineering—a systematic literature review. **Information and software technology**, v. 51, n. 1, p. 7-15, 2009.
- LEE, Jay; BAGHERI, Behrad; KAO, Hung-An. A cyber-physical systems architecture for industry 4.0-based manufacturing systems. **Manufacturing Letters**, v. 3, p. 18-23, 2015.
- LI, Zhe; WANG, Yi; WANG, Ke-Sheng. Intelligent predictive maintenance for fault diagnosis and prognosis in machine centers: Industry 4.0 scenario. **Advances in Manufacturing**, v. 5, n. 4, p. 377-387, 2017.
- MALCHER, Paulo Robson Campelo et al. Um Mapeamento Sistemático sobre Abordagens de Apoio à Rastreabilidade de Requisitos no Contexto de Projetos de Software. 2015.
- MARKETSANDMARKETS. Predictive maintenance markets –global forecast to 2021. 2017.
- MARKOV, Zdravko; RUSSELL, Ingrid. An introduction to the WEKA data mining system. In: **ACM SIGCSE Bulletin**. ACM, 2006. p. 367-368.
- MCAFEE, Andrew et al. Big data: the management revolution. **Harvard business review**, v. 90, n. 10, p. 60-68, 2012.
- MESBAH, Ali et al. Stochastic nonlinear model predictive control with probabilistic constraints. In: **American Control Conference (ACC), 2014**. IEEE, 2014. p. 2413-2419.
- MOBLEY, R. Keith. **An introduction to predictive maintenance**. Elsevier, 2002.
- PACKWOOD, Dez et al. FPGA-based Mixed-Criticality Execution Platform for SystemJ and the Internet of Industrial Things. In: **Real-Time Distributed Computing (ISORC), 2015 IEEE 18th International Symposium on**. IEEE, 2015. p. 174-181.
- PANGARTTE, Reginaldo. **Sistemas Poka Yoke para processo de teste em indústria eletroeletrônica**. 2014.
- PEREIRA, Felipe Ricardo Canezin. **Estudo e implementação de um amplificador classe D utilizando tecnologia montada em superfície (SMT)**. 2017. Trabalho de Conclusão de Curso. Universidade Tecnológica Federal do Paraná.
- PETERSEN, Kai et al. Systematic Mapping Studies in Software Engineering. In: **EASE**. 2008. p. 68-77.
- PORTER, Michael E.; HEPPELMANN, James E. How smart, connected products are transforming competition. **Harvard business review**, v. 92, n. 11, p. 64-88, 2014.
- PRASAD, Ray. **Surface mount technology: principles and practice**. Springer Science & Business Media, 2013.
- QIN, Jian; LIU, Ying; GROSVENOR, Roger. A categorical framework of manufacturing for industry 4.0 and beyond. **Procedia Cirp**, v. 52, p. 173-178, 2016.
- REISCHAUER, Georg. Industry 4.0 as policy-driven discourse to institutionalize innovation systems in manufacturing. **Technological Forecasting and Social Change**, v. 132, p. 26-33, 2018.
- RÜßMANN, Michael et al. Industry 4.0: The future of productivity and growth in manufacturing industries. **Boston Consulting Group**, v. 9, 2015.

- RUSSELL, Ingrid; MARKOV, Zdravko. An introduction to the Weka data mining system. In: **Proceedings of the 2017 ACM SIGCSE Technical Symposium on Computer Science Education**. ACM, 2017. p. 742-742.
- SANDRINI, Paulo de Tarso et al. O sistema MES como ferramenta para aplicação da gestão do conhecimento visando a melhoria do aprendizado de um sistema complexo adaptativo de manufatura sendo um atrator de melhoria do desempenho produtivo. 2014.
- SCHLUSE, Michael et al. Experimentable Digital Twins—Streamlining Simulation-Based Systems Engineering for Industry 4.0. **IEEE Transactions on Industrial Informatics**, v. 14, n. 4, p. 1722-1731, 2018.
- 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)**. IEEE, 2018. p. 1-8.
- SEWAIWAR, Purva; VERMA, Kamal Kant. Comparative study of various decision tree classification algorithm using WEKA. **International Journal of Emerging Research in Management & Technology**, v. 4, p. 2278-9359, 2015.
- SHETTY, Rashmi B. Predictive Maintenance in the IoT Era. **Prognostics and Health Management of Electronics: Fundamentals, Machine Learning, and the Internet of Things**, p. 589-612, 2018.
- SONDAGEM ESPECIAL: Indústria 4.0. **Revista da Confederação Nacional Da Indústria**. Brasília: Ed. 66, n. 2 abr. 2016. 13 p.
- SPENDLA, Lukas et al. Concept of predictive maintenance of production systems in accordance with industry 4.0. In: **Applied Machine Intelligence and Informatics (SAMi), 2017 IEEE 15th International Symposium on**. IEEE, 2017. p. 000405-000410.
- SURESH, P. et al. A state of the art review on the Internet of Things (IoT) history, technology and fields of deployment. In: **Science Engineering and Management Research (ICSEMR), 2014 International Conference on**. IEEE, 2014. p. 1-8.
- SUSTO, Gian Antonio et al. Machine learning for predictive maintenance: A multiple classifier approach. **IEEE Transactions on Industrial Informatics**, v. 11, n. 3, p. 812-820, 2015.
- TORO, C.; BARANDIARAN, I.; POSADA, J. **A perspective on knowledge based and intelligent systems implementation in industrie 4.0**. **PROCEDIA COMPUTER SCIENCE**, v. 60, n. 1, p. 362–370, 2015. Disponível em: <<http://dx.doi.org/10.1016/j.procs.2015.08.143>>.
- TRNKA, Andrej. Big data analysis. **European Journal of Science and Theology**, v. 10, n. 1, p. 143-148, 2014.
- TSAI, Chun-Wei; LAI, Chin-Feng; VASILAKOS, Athanasios V. Future Internet of Things: open issues and challenges. **Wireless Networks**, v. 20, n. 8, p. 2201-2217, 2014.
- VAIDYAA, Saurabh; AMBADB, Prashant; BHOSLEC, Santosh. Industry 4.0—a glimpse. **Design Engineering**, v. 2351, p. 9789, 2018.
- WAN, Jiafu et al. Software-defined industrial internet of things in the context of industry 4.0. **IEEE Sensors Journal**, v. 16, n. 20, p. 7373-7380, 2016.
- WANG, Weijie; LU, Yanmin. Analysis of the Mean Absolute Error (MAE) and the Root Mean Square Error (RMSE) in Assessing Rounding Model. In: **IOP Conference Series: Materials Science and Engineering**. IOP Publishing, 2018. p. 012049.
- YAQOOB, Ibrar et al. Internet of things architecture: Recent advances, taxonomy, requirements, and open challenges. **IEEE wireless communications**, v. 24, n. 3, p. 10-16, 2017.

- ZHAO, Chunhui. Fault subspace selection and analysis of relative changes based reconstruction modeling for multi-fault diagnosis. In: **Control and Decision Conference (2014 CCDC), The 26th Chinese**. IEEE, 2014. p. 235-240.
- ZHOU, Keliang; LIU, Taigang; ZHOU, Lifeng. Industry 4.0: Towards future industrial opportunities and challenges. In: **Fuzzy Systems and Knowledge Discovery (FSKD), 2015 12th International Conference on**. IEEE, 2015. p. 2147-2152.
- ZOLL, Marian; JÄCK, Daniel; VOGT, Marcus W. Evaluation of Predictive-Maintenance-as-a-Service Business Models in the Internet of Things. In: **2018 IEEE International Conference on Engineering, Technology and Innovation (ICE/ITMC)**. IEEE, 2018. p. 1-9.