

UNIVERSIDADE FEDERAL DO PARANÁ

MAYCON LISBOA DOS SANTOS

MÉTODO PARA IMPLEMENTAR UM SISTEMA DE ANÁLISE DE DADOS  
GERADOS PELOS EQUIPAMENTOS CNCs POR MEIO DE TECNOLOGIAS 4.0,  
IIOT E *DATA ANALYTICS*.

CURITIBA

2022

MAYCON LISBOA DOS SANTOS

MÉTODO PARA IMPLEMENTAR UM SISTEMA DE ANÁLISE DE DADOS  
GERADOS PELOS EQUIPAMENTOS CNCs POR MEIO DE TECNOLOGIAS 4.0,  
IIOT E DATA ANALYTICS.

Dissertação apresentada ao curso de Pós-Graduação em Engenharia de Manufatura, Setor de Tecnologia, Universidade Federal do Paraná como requisito parcial à obtenção do título de Mestre em Engenharia de Manufatura.

Orientador: Prof. Dr. Pablo Valle  
Coorientador: Prof. Dr. Fernando Deschamps

CURITIBA

2022

DADOS INTERNACIONAIS DE CATALOGAÇÃO NA PUBLICAÇÃO (CIP)  
UNIVERSIDADE FEDERAL DO PARANÁ  
SISTEMA DE BIBLIOTECAS – BIBLIOTECA DE CIÊNCIA E TECNOLOGIA

Santos, Maycon Lisboa dos

Método para implementar um sistema de análise de dados gerados pelos equipamentos CNCS por meio de tecnologias 4.0, IIOT E Data Analytics / Maycon Lisboa dos Santos. – Curitiba, 2022.

1 recurso on-line : PDF.

Dissertação (Mestrado) - Universidade Federal do Paraná, Setor de Tecnologia, Programa de Pós-Graduação em Engenharia de Manufatura.

Orientador: Pablo Deivid Valle

Coorientador: Fernando Deschamps

1. Internet das coisas. 2. Eficiência industrial. 3. Equipamento agrícola. I. Universidade Federal do Paraná. II. Programa de Pós-Graduação em Engenharia de Manufatura. III. Valle, Pablo Deivid. IV. Deschamps, Fernando. V. Título.

Bibliotecário: Leticia Priscila Azevedo de Sousa CRB-9/2029

## TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação ENGENHARIA DE MANUFATURA da Universidade Federal do Paraná foram convocados para realizar a arguição da Dissertação de Mestrado de **MAYCON LISBOA DOS SANTOS** intitulada: **MÉTODO PARA IMPLEMENTAR UM SISTEMA DE ANÁLISE DE DADOS GERADOS PELOS EQUIPAMENTOS CNCs POR MEIO DE TECNOLOGIAS 4.0, IIOT E DATA ANALYTICS.**, sob orientação do Prof. Dr. PABLO DEIVID VALLE, que após terem inquirido o aluno e realizada a avaliação do trabalho, são de parecer pela sua APROVAÇÃO no rito de defesa.

A outorga do título de mestre está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

Curitiba, 15 de Dezembro de 2022.

Assinatura Eletrônica  
18/12/2022 17:55:49.0  
PABLO DEIVID VALLE  
Presidente da Banca Examinadora

Assinatura Eletrônica  
25/12/2022 21:28:18.0  
MARCOS AUGUSTO MENDES MARQUES  
Avaliador Externo (DEPARTAMENTO DE ENGENHARIA DE  
PRODUÇÃO - UFPR)

Assinatura Eletrônica  
12/01/2023 14:01:06.0  
EDUARDO ALVES PORTELA SANTOS  
Avaliador Externo (UNIVERSIDADE FEDERAL DO PARANÁ -  
DEPARTAMENTO DE ADMINISTRAÇÃO GERAL E APLICADA)

Assinatura Eletrônica  
16/12/2022 13:51:52.0  
FERNANDO DESCHAMPS  
Coorientador(a) (UNIVERSIDADE FEDERAL DO PARANÁ)

## **AGRADECIMENTOS**

Ao meu pai Antônio que até meus onze anos me ensinou e educou e a minha mãe Neili que ao longo da minha vida se dedicou a me mostrar o caminho certo tendo o respeito a todos como prioridade, me incentivou a ter muita perseverança e dedicação, além de todo carinho e amor a mim ofertado, minha eterna gratidão.

À minha querida e amada esposa Joana Paula e aos nossos três filhos Pedro, Guilherme e Miguel por estarem ao meu lado, com paciência, carinho e aceitando minhas ausências para dedicação aos estudos, meu agradecimento por acreditarem e embarcarem nesta jornada.

Ao orientador Pablo e coorientador Fernando, pelos ensinamentos, incentivos, orientações e pelas amizades geradas nesse ecossistema proporcionado pela PPGEM, obrigado.

À empresa empregadora pelo apoio e financiamento no período de elaboração dessa obra e aos colegas que apoiaram e se dedicaram ao projeto meu agradecimento por compartilharem os momentos profissionais que passamos juntos.

## RESUMO

A produtividade da agricultura é essencialmente composta pela tecnologia, trabalho e terra. A tecnologia garante a competitividade econômica do setor, onde as empresas de manufatura de bens de capital vêm procurando se adequar às novidades nessa área, porém, deparam-se com equipamentos instalados e em depreciação, ocasionando perdas de eficiência. Dado isso, a medição do sistema de manufatura se torna essencial para o entendimento das anomalias que influenciam a eficácia dos equipamentos, sendo o monitoramento de seus equipamentos de suma importância para identificar e eliminar os desperdícios e perdas dos processos. Assim sendo, esta pesquisa apresenta como é possível aplicar os conceitos de indústria 4.0, para melhoria da análise de seus indicadores de produtividade utilizando-se do método *Design Science Research* (DSR), - método que orienta a coleta, modelagem, padronização dos dados de CNCs (*Computer Numeric Control*), com técnicas como *Industrial Internet of things* (IIoT) e *Data Analytics*. O método foi praticado em uma empresa de equipamentos agrícolas, a qual considerou os resultados significantes, no que tange ao conhecimento das tecnologias da Indústria 4.0 e de seus processos e equipamentos. O resultado da acurácia foi destaque na prática do método proposto, com a implementação de um sistema automático de análise de dados, que obteve um resultado da acuracidade de 85% versus 38% do processo atual, no índice de disponibilidade e para o índice de performance de 77% contra 54%. O resultado demonstra que a aplicação do método para implementação das tecnologias da I4.0, é impactante na precisão dos indicadores de disponibilidade e produtividade, e consequentemente no aumento da eficiência dos equipamentos. Ademais, tem um impacto positivo no “chão de fábrica” devido a visualização, em tempo real, dos resultados pelo operador no próprio equipamento.

Palavras-chave: eficiência geral do equipamento; indústria 4.0; IIoT; análise de dados.

## **ABSTRACT**

The productivity of agriculture is essentially composed of technology, labor and land. Technology guarantees the sector's economic competitiveness, where capital goods manufacturing companies have been trying to adapt to new developments in this area, however, they are faced with installed and depreciating equipment, causing efficiency losses. For this reason, the measurement of the manufacturing system is essential for understanding the anomalies that influence the effectiveness of the equipment, where the monitoring of its equipment is of paramount importance to identify and eliminate waste and process losses. In this way, this research presents how it is possible to apply the concepts of industry 4.0, to improve the analysis of its productivity indicators. For this purpose, using the Design Science Research (DSR) method, presented here as a method that guides the collection, modeling, standardization of data from CNCs (Computer Numeric Control), using techniques such as Industrial Internet of things (IIoT) and Data Analytics. The proposed method was applied in an agricultural equipment company, which considered the results significant in terms of knowledge of Industry 4.0 technologies and its processes and equipment. The accuracy result was highlighted in the implementation of the proposed method, with the implementation of an automatic data analysis system, which obtained an accuracy result of 85% versus 38% of the current process, in the availability index and 77% against 54% in the performance index. The result demonstrates that the application of the method for implementing the I4.0 technologies has a direct impact on the accuracy of the availability and productivity indicators, and consequently increases the efficiency of the equipment. In addition, it has a positive impact on the "factory floor" due to the visualization of results by the operator on the equipment itself in real time.

Key words: overall equipment efficiency; industry 4.0; IIoT; data Science; smart manufacturing.

## LISTA DE ILUSTRAÇÕES

FIGURA 1 – PRODUÇÃO DE GRÃOS (SOJA) EM TONELADA .....	15
FIGURA 2 – PRODUÇÃO DE EQUIPAMENTOS AGRÍCOLAS .....	16
FIGURA 3 – ILUSTRAÇÃO EVOLUÇÃO COLHEITADEIRA DE GRÃOS .....	18
FIGURA 4 – EIXO DE PESQUISA E PALAVRAS-CHAVE.....	22
FIGURA 5 – ILUSTRAÇÃO DA EVOLUÇÃO DA INDÚSTRIA .....	25
FIGURA 6 – CONCEITO DE CONECTIVIDADE IIOT .....	26
FIGURA 7 – CLASSIFICAÇÃO DOS PRINCIPAIS CONCEITOS .....	29
FIGURA 8 – CONCEITO PARA IMPLEMENTAÇÃO DE SISTEMA DE ANÁLISE DE DADOS.....	30
FIGURA 9 – CONCEITO DE CONHECIMENTO E IMPLEMENTAÇÃO DE PROJETO .....	38
FIGURA 10 – LÓGICA PARA CONSTRUÇÃO DAS CLASSES DE PROBLEMAS.....	39
FIGURA 11 – ARQUITETURA DE COMUNICAÇÃO IIOT E <i>DATA SCIENCE</i> .....	46
FIGURA 12 – ITENS PROPOSTOS PARA AVALIAÇÃO DE CONECTIVIDADE .....	48
FIGURA 13 – ESTRUTURA DO SISTEMA DE ANÁLISE DE DADOS.....	52
FIGURA 14 – ARQUITETURA DE COMUNICAÇÃO IIOT E ARMAZENAMENTO DOS DADOS.....	54
FIGURA 15 – PIRÂMIDE DE RESPONSABILIDADES .....	56
FIGURA 16 – ACURÁCIA E PRECISÃO .....	60
FIGURA 17 – RESULTADO DO MAPEAMENTO DOS ATIVOS.....	62
FIGURA 18 – RESULTADO MAPEAMENTO DE CONECTIVIDADE.....	63
FIGURA 19 – MODELO DO PAINEL DIGITAL DESENVOLVIDO PARA VISÃO DO OPERADOR .....	65
FIGURA 20 – <i>DASHBOARD</i> E FUNCIONALIDADES .....	66



## LISTA DE QUADROS

QUADRO 1 – TIPOS DE ARTEFATOS .....	40
QUADRO 2 – ETAPAS DO PROCESSO DSR E ARGUMENTAÇÃO CIENTÍFICA. ....	41
QUADRO 3 – DIRETRIZES DE AVALIAÇÃO DO <i>DESIGN RESEARCH</i> .....	42
QUADRO 4 – ATIVIDADES DO DESENVOLVIMENTO DO ARTEFATO .....	47

## LISTA DE GRÁFICOS

GRÁFICO 1 – COMPARATIVO DE HORAS PARADAS .....	73
GRÁFICO 2 – GRÁFICO DE DISPERSÃO DOS ERROS VERSUS TEMPO DE PARADAS .....	74
GRÁFICO 3 – GRÁFICO DE <i>BOX-PLOT</i> DO % ERRO DE DISPONIBILIDADE.....	74

## LISTA DE TABELAS

TABELA 1 – RESUMO DA APLICAÇÃO METODOLOGIA PROKNOW-C.....	23
TABELA 2 – TAREFAS E MÉTODOS ESTATÍSTICOS .....	33
TABELA 3 – OEE COMBINADOS COM SEIS TIPOS DE PERDA.....	36
TABELA 4 – VALORES NUMÉRICOS DAS CLASSIFICAÇÕES DA CRITICIDADE.....	49
TABELA 5 – PARÂMETROS, PESOS E FAIXAS DE CRITICIDADE .....	50
TABELA 6 – RESULTADOS DA TABELA DE CRITICIDADE .....	64
TABELA 7 – VALORES DE REFERÊNCIA.....	68
TABELA 8 – VALORES DO PROCESSO MANUAL .....	69
TABELA 9 – VALORES DO SISTEMA PROPOSTO.....	69
TABELA 10 – RESULTADO DA ACURÁCIA DO ÍNDICE DE DISPONIBILIDADE.....	70
TABELA 11 – RESULTADO DO CÁLCULO DO ÍNDICE PERFORMANCE .....	71
TABELA 12 – RESULTADO DO CÁLCULO DO ÍNDICE DE QUALIDADE .....	72
TABELA 13 – RESULTADO DO CÁLCULO DO OEE.....	72

## LISTA DE ABREVIATURAS E SIGLAS

ANFAVEA	Associação Nacional dos Fabricantes de Veículos Automotores
CBM	Condito Based Monitoring
CEP	Controle Estatístico de Processos
CLP	Controladores Lógicos Programáveis
CNC	Computer Numeric Control
CPPS	Cyber-Physical Production Systems
CPS	Cyber-Physical Systems
DA	Data Analytics
DSR	Design Science Research
FMEA	Failure Mode and Effect Analysis
IBGE	Instituto Brasileiro de Geografia e Estatística
IIoT	Industrial Internet of Things
IoT	Internet of Things
KBM	Knowledge-Based Maintenance
LSPA	Levantamento Sistemático da Produção Agrícola
ML	Machine Learning
MSA	Measurement System Analysis
NIST	National Institute of Standards and Technology
OEE	Overall Equipment Effectiveness
PDCA	Plan, Do, Check, Act
PPGEM	Programa de Pós-Graduação em Engenharia de Manufatura
PTF	Produtividade Total dos Fatores
SLR	Systematic Literature Review
TPM	Manutenção Produtiva Total
WCM	World Class Manufacturing

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	14
1.1	CONTEXTUALIZAÇÃO	15
1.1.1	Crescimento e produtividade da agricultura brasileira	15
1.1.2	Inovação tecnológica na agricultura	16
1.1.3	Inovação no sistema de fabricação – Manufatura Inteligente	18
1.2	FORMULAÇÃO DO PROBLEMA	19
1.3	OBJETIVO	19
1.3.1	Objetivo geral	20
1.3.2	Objetivos específicos	20
1.4	PRODUTO TECNOLÓGICO	20
1.5	CONTRIBUIÇÕES DO TRABALHO	21
1.5.1	Contribuição para a academia	21
1.5.2	Contribuição para a indústria	21
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	21
2.1	REVISÃO SISTEMÁTICA DA LITERATURA (RSL)	22
2.1.1	Metodologia de pesquisa	23
2.2	REVISÃO BIBLIOGRÁFICA	24
2.2.1	Indústria 4.0	24
2.2.2	Conectividade IIoT - <i>Industrial Internet of Things</i>	25
2.2.3	Geração e análise de dados	27
2.2.4	<i>Data Analytics, Data Mining e Machine learning</i>	28
2.2.5	Técnicas e métodos de análise de dados	31
2.2.6	Técnicas de análises, tarefas e métodos	32
2.2.7	OEE – <i>Overall Equipment Effectiveness</i> e produtividade	33
2.2.8	Conhecimento e aprendizado na análise de falhas	37
<b>3</b>	<b>ABORDAGEM METODOLÓGICA</b>	38
3.1	<i>DESIGN SCIENCE RESEARCH</i>	38
3.1.1	<i>Design Science Research</i> como uma metodologia	39
<b>4</b>	<b>APLICAÇÃO DO DSR NA PESQUISA</b>	42
4.1	CONSCIENTIZAÇÃO DO PROBLEMA	43
4.2	SUGESTÃO PARA O PROBLEMA	44

4.3	DESENVOLVIMENTO .....	45
4.4	AVALIAÇÃO .....	59
4.4.1	Acuracidade como fonte de avaliação .....	59
4.5	CONCLUSÃO DO DSR .....	61
<b>5</b>	<b>RESULTADOS E DISCUSSÕES</b> .....	<b>61</b>
5.1	RESULTADOS DAS ATIVIDADES DE DESENVOLVIMENTO .....	61
5.1.1	<i>Dashboard</i> e suas funcionalidades .....	65
5.2	RESULTADO DA ACURACIDADE DO ARTEFATO .....	68
5.2.1	Resultado da acuracidade do índice de disponibilidade .....	68
5.2.2	Resultado da acuracidade do índice de performance.....	70
5.2.3	Resultado da acuracidade do índice de qualidade .....	71
5.2.4	Resultado da acuracidade do OEE.....	72
5.3	CONCLUSÃO DO ARTEFATO.....	75
<b>6</b>	<b>CONSIDERAÇÕES FINAIS</b> .....	<b>75</b>
<b>7</b>	<b>RECOMENDAÇÕES PARA TRABALHOS FUTUROS</b> .....	<b>77</b>
	<b>REFERÊNCIAS</b> .....	<b>78</b>
	<b>APÊNDICE 1 – LISTA DE ARTIGOS PESQUISADOS NA REVISÃO</b> .....	<b>85</b>
	<b>ANEXO 1 - ANÁLISE TAGUCHI PARA EXPERIMENTO DE USINAGEM...</b>	<b>86</b>

## 1 INTRODUÇÃO

A agricultura recente é moderna e incorporadora de ciência e tecnologia que impulsionam a produtividade. Nos últimos anos, o enorme aproveitamento do uso da terra e as exportações recordes, fazem o Brasil se destacar no cenário mundial. Na agricultura, observa-se que o conceito de produtividade está chegando na "linha de produção da agricultura", a "terra", onde cultivar mais com menor terreno. Para esse propósito, a tecnologia e equipamentos com alto desempenho são importantes para garantir o melhor ganho produtivo com o menor "pedaço de terra".

A tecnologia é o fator que mais influência no aumento da produção agrícola, também responsável por cerca de 60% do crescimento no Valor Bruto da Produção (VBP). Mirando no setor de equipamentos de bens de capital, para atender este crescimento de desempenho produtivo, as indústrias responsáveis pela fabricação desses equipamentos precisam modernizar-se e apoiar-se nas tecnologias (VIEIRA FILHO; GASQUES, 2020).

A Indústria 4.0 desempenha um papel fundamental para melhorar a eficiência das máquinas industriais, responsáveis pela fabricação dos produtos agrícolas, como tratores e colheitadeiras. Com uma maior dependência das tecnologias para os equipamentos agrícolas, as fábricas necessitam se adaptar para garantir o avanço tecnológico nos componentes manufaturados, no qual o desafio é garantir a produtividade e atender as exigências de uma manufatura de precisão e tecnológica nos processos industriais.

Entender os efeitos que afetam a produtividade por meios de técnicas convencionais, não é mais suficiente para as fábricas acompanharem as revoluções tecnológicas. Faz-se necessário um método eficiente para implementação das técnicas, captura e leitura dos dados gerados pelos equipamentos industriais e análises sistemáticas, incentivando os operadores e os gestores a tomarem as decisões corretas no momento de corrigir ou ajustar os equipamentos, garantindo os indicadores de produtividades existentes.

Posto isso, neste trabalho será apresentado um método para implementação de um sistema de análise de dados, para obtenção do indicador OEE - *Overall Equipment Effectiveness* mais assertivo e inteligente, com o intuito de trazer mais eficiência para o processo industrial.

## 1.1 CONTEXTUALIZAÇÃO

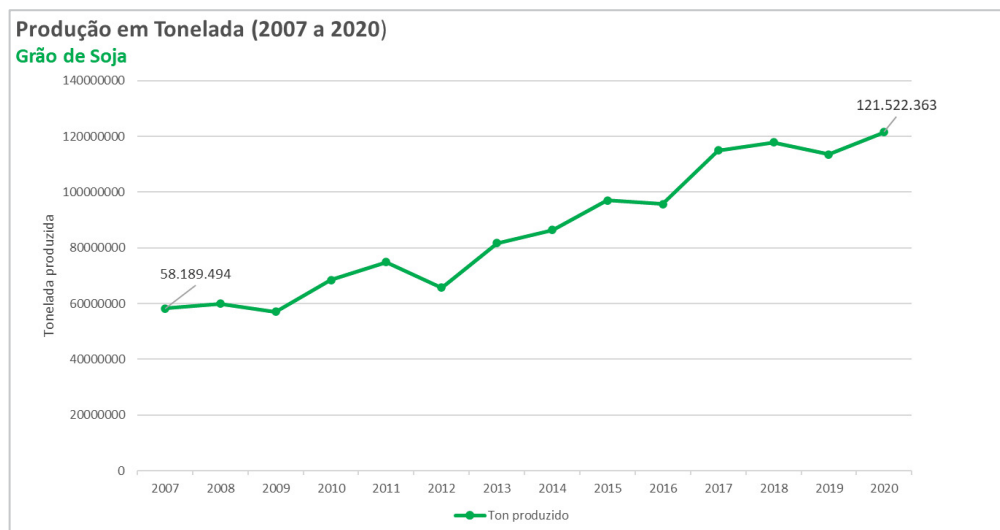
### 1.1.1 Crescimento e produtividade da agricultura brasileira

Com base no Censo Agropecuário de 2017, realizado pelo Instituto Brasileiro de Geografia e Estatística (IBGE), Vieira Filho e Gagues (2020) mostraram que o Brasil se destacou na Produtividade Total dos Fatores (PTF), correspondendo a uma taxa de crescimento médio anual aproximada de 4,3%, superior a outros países, tais como: Argentina (2,7%), Chile (3,1%), Estados Unidos (1,9%) e China (3,3%).

Melhorar o desempenho e a produtividade muitas vezes estão ligados a novas tecnologias embarcadas nos equipamentos. A introdução da tecnologia busca, a cada ano, melhorar o desempenho e reduzir os custos operacionais, incentivando um processo de modernização nas indústrias de equipamentos, para que essas novas tecnologias sejam incorporadas na manufatura de seus produtos.

Seguindo nessa abordagem a produção brasileira de soja, em 2020 foi de 121.522.363 ton. contra 58.189.494 ton (toneladas). de 2007 (FIGURA 1), aumento de 108,8% conforme no sistema de Levantamento Sistemático da Produção Agrícola (LSPA) do IBGE (2021).

FIGURA 1 – PRODUÇÃO DE GRÃOS (SOJA) EM TONELADA

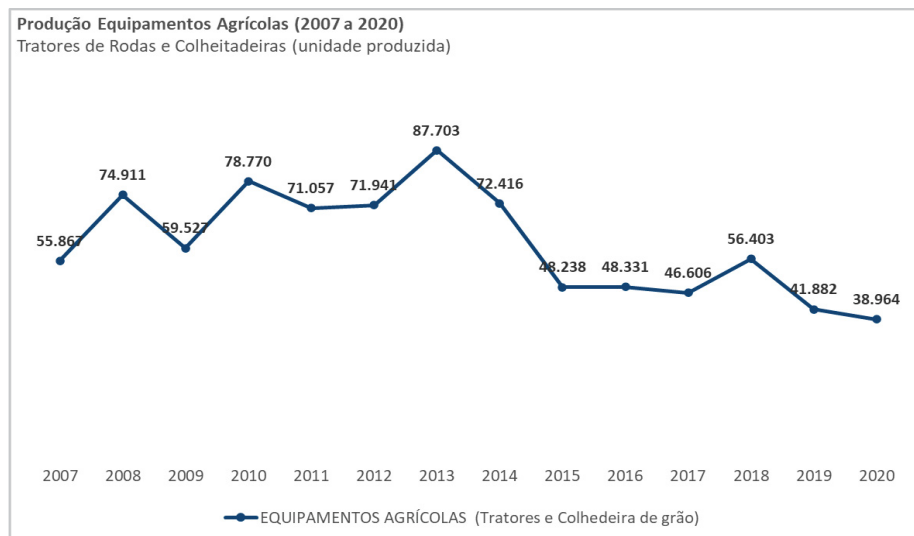


Fonte: Adaptado de IBGE (2021).



Em contrapartida quando analisada a produção de equipamentos agrícolas (FIGURA 2), com base nos dados disponíveis pela Associação Nacional dos Fabricantes de Veículos Automotores - ANFAVEA (2021), a produção de equipamentos agrícolas (tratores e colheitadeiras), tem-se que em 2007 o número de equipamentos produzidos foi de 55.863 unidades, já em 2020 foi de apenas 38.964 unidades, ou seja, uma redução de 30,3%.

FIGURA 2 – PRODUÇÃO DE EQUIPAMENTOS AGRÍCOLAS



Fonte: Adaptado da ANFAVEA (2021)

Essa análise nos leva a algumas conclusões. Diferente do crescimento da produção de grão a produção de equipamentos não teve aumento e ao contrário percebe-se uma redução na última década, isso se dá pelo fato de que nos últimos anos o nível tecnológico dos equipamentos utilizados, é tão eficaz que é possível alcançar produtividades recordes sem o aumento do parque de equipamentos.

### 1.1.2 Inovação tecnológica na agricultura

Ao longo das últimas décadas, a terra tornou-se um recurso cada vez mais escasso e valioso, estabelecendo um limite para a produção agrícola. Com as mudanças climáticas, o uso eficiente da água e utilização de tecnologias genéticas de grãos, passou a ser essencial na ótica produtiva. Além disso, o trabalho antes realizado pela mão-de-obra humana, tem diminuído nas áreas rurais em razão da

intensidade da urbanização e do aumento do setor de serviços. Portanto, a incorporação de tecnologias modernas na agricultura, mostra-se crucial para os ganhos de produtividade e para o progresso sustentável.

Segundo Vieira Filho e Fishow (2017), as tecnologias poupa-trabalho (relacionadas ao capital fixo), podem ser representadas por uma estimativa do valor dos veículos, tratores, máquinas e implementos (dada certa depreciação e esperança média de vida). Além disso, o maquinário em geral alugado e as tecnologias poupa-terra (ligadas ao capital variável), são dimensionadas pelo gasto com sementes e mudas, produtos para correção química do solo, fertilizantes, agroquímicos, ração animal e medicamentos veterinários.

No lado do poupa-trabalho o avanço tecnológico das últimas quatro décadas, contribuiu com a redução da emissão de poluentes, gastos com combustível e aumento da precisão dos equipamentos com o aumento médio da potência das máquinas.

Mirando nessa linha, as perdas na colheita quando realizadas com colheitadeiras de grão antes dos anos 70 no Brasil eram aproximadamente de 10% a 12%, já nos anos 1990 essas perdas caíram para 6%. Em 2015 as colheitadeiras produzidas apresentavam 0,5% de perda (CARBONI, 2015). Indicando a necessidade cada vez menor de investimento em capital fixo, o que explica parte do que foi apresentado na FIGURA 2.

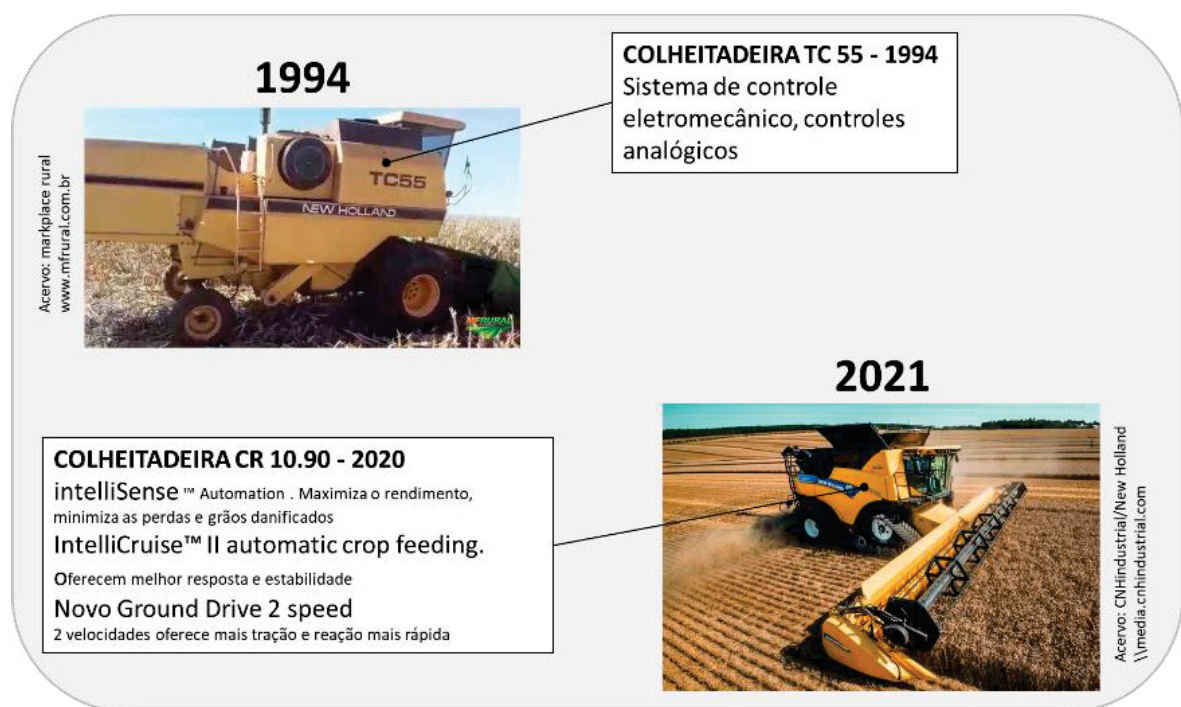
Certamente, outros fatores econômicos, políticos e sociais do Brasil impactaram na redução da produção de equipamentos agrícolas, mas não se pode deixar de considerar a evolução tecnológica das indústrias de bens de capital. As quais investem em tecnologia para o desenvolvimento de equipamentos cada vez mais eficientes e produtivos.

Exemplo, na fabricação de uma colheitadeira de 1994, a engenharia de processo era desafiada a encontrar soluções para manufaturar equipamentos com uma complexidade tecnológica muito inferior, quando comparado com os atuais dotados de sensores, computadores, sistemas de comunicação por satélite e interface digitais.

Para ilustrar melhor essa evolução, na FIGURA 3 observa-se os equipamentos que eram fabricados em 1994, uma colheitadeira da marca New Holland, Modelo TC 55, ano 1994, que possuía comandos e controles

eletromecânicos com interface analógica, já a colheitadeira, CR 10.90, também da marca New Holland dos anos 2020/2021, oferecem sistemas inteligentes de monitoramento, piloto automático e telemétrica 4.G, tela sensível ao toque, contam ainda com sensores de calibração automático, GPS e até câmeras digitais (NEW HOLLAND, SITE, 2021). Essa comparação demonstra quanto a evolução tecnológica impacta nos produtos e processos de manufatura, e conseqüentemente em toda a fábrica.

FIGURA 3 – ILUSTRAÇÃO EVOLUÇÃO COLHEITADEIRA DE GRÃOS



Fonte: Adaptada do acervo de imagens NEW HOLLAND, SITE (2021)

### 1.1.3 Inovação no sistema de fabricação – Manufatura Inteligente

Para Kusiak (2018) a manufatura inteligente é um sistema totalmente integrado e colaborativo, que responde em tempo real para atender às novas demandas e condições na fábrica, na rede de abastecimento e nas necessidades do cliente. O maior desafio pode estar na aceitação da realidade da manufatura estar em constante evolução, assim como os produtos por ela manufaturado (KUSIAK, 2018).

Neste contexto, os processos e equipamentos utilizados para manufaturar os produtos com tal avanço tecnológico, tem fundamental papel, pois necessitam

acompanhar a evolução constante dos produtos, garantindo sua eficiência produtiva mediante o fornecimento de informações precisas de sua produtividade.

Com essa velocidade de transformação e informações disponíveis, faz-se necessário uma manufatura inteligente que possa acompanhar esta evolução tecnológica. Apresentar um sistema de coleta, armazenamento e transformação dos dados em indicadores relevantes para tomada de decisão e gerenciamento da manufatura é fundamental para que as indústrias possam acompanhar o avanço e os progressos tecnológicos sofridos pelos produtos manufaturados.

Para garantir o avanço tecnológico nos produtos, a manufatura tem o desafio de encontrar alternativas para atender as novas demandas e desenvolver soluções para fabricar peças e componentes que exigem um processo inteligente e de alta precisão.

## 1.2 FORMULAÇÃO DO PROBLEMA

O *Overall Equipment Effectiveness* (OEE), será mais bem explicado no item 2.2.7. deste documento, é o indicador mais utilizado pela indústria para gerenciar a efetividade global das máquinas e equipamentos industriais. Nesse contexto, uma das principais causas do insucesso da medição do OEE é a falta de integração do equipamento com os sistemas de planejamento, apontamento e monitoramento. Mesmo considerando a manufatura digital como uma solução para a inovação tecnológica, os processos tradicionais seguem desconectados e fazendo o uso de planilhas para cálculo do OEE, não asseverando dados confiáveis para o gerenciamento contínuo dos equipamentos e dos processos.

O problema se dá da necessidade de um método para integrar a tecnologia de coleta de dados com o sistema de cálculo analítico dos indicadores, capaz de apontar as anomalias que acontecem ao longo do processo e indicar a eficácia do equipamento em tempo real, tornando a gestão do equipamento mais ágil e a tomada de decisões mais assertiva.

## 1.3 OBJETIVO

### 1.3.1 Objetivo geral

O objetivo geral consiste em apresentar um método que oriente a coleta, modelagem, padronização dos dados das máquinas de usinagem CNC, utilizando-se de técnicas da indústria 4.0 como IIoT e *Data Analytics*, dispondo os resultados em painéis digitais (*dashboard*) calculados automaticamente, garantindo uma melhor acurácia na formatação dos indicadores.

### 1.3.2 Objetivos específicos

Como objetivo específico, tem-se:

- Selecionar criteriosamente os equipamentos que serão avaliados, para evitar distúrbios que possam impactar na produtividade atual.
- Conceber um método, como modelo de arquitetura de informação, que possa ser utilizado pelo sistema de análise de dados.
- Implementar o método e que possa definir a hierarquia da decisão.
- Analisar os resultados e medir a acurácia do método proposto em equipamentos reais de manufatura.
- Melhorar o modelo de visualização com uma proposta de leiaute de *Dashboard* para facilitar a tomada de decisão em tempo real.

## 1.4 PRODUTO TECNOLÓGICO

O projeto do produto tecnológico tem como base as lacunas encontradas no contexto científico, pensando na concepção de uma metodologia de aplicação genérica para implementação de tecnologias, como IIoT e *Data Analytics*. Espera-se que, auxilie na medição do desempenho de equipamentos conectados ao sistema de coleta e armazenamento de dados e, que possam ser apresentadas de forma que oriente na tomada de decisão, independentemente de uma série de análises e cálculos.

Assim, pode-se contribuir com as indústrias que apresentam dificuldades de utilizar dados de equipamentos, integrar sistemas ou implementar um modelo de transformação digital, advindas das tecnologias da indústria 4.0.

A aplicabilidade deste projeto de pesquisa tecnológico em um cenário real de manufatura, se fará em uma empresa com mais de 40 anos no Brasil, com equipamentos que foram instalados em meados de 1980, ainda utilizados na produção, e sua eficiência produtiva é medida através do indicador de OEE.

## 1.5 CONTRIBUIÇÕES DO TRABALHO

### 1.5.1 Contribuição para a academia

Esta pesquisa é focada nas dificuldades atuais das empresas, em como utilizar técnicas da quarta revolução industrial, que auxilie os pesquisadores a integrar os assuntos, favorecendo o entendimento e aplicabilidade das técnicas das novas tendências tecnológicas na indústria.

Para que se possa gerar valor tanto para a academia quanto para a indústria simultaneamente, uma revisão da literatura demonstra que, cada vez mais, os pesquisadores precisam integrar os assuntos relacionados a IIoT e *Data Analytics*. Sendo assim, o trabalho visa dar aos pesquisadores *insights* e competências para uma investigação mais ampla e tecnicamente robusta, de como as tendências recentes como a indústria 4.0, podem impactar no setor manufatureiro e na tomada de decisão.

### 1.5.2 Contribuição para a indústria

Em relação a contribuição para a indústria, destaca-se o método estruturado para implementação de um sistema de análise de dados, seguido de um passo-a-passo de como o integrar as tecnologias da indústria 4.0.

## 2 FUNDAMENTAÇÃO TEÓRICA

A base teórica é de suma importância para fundamentar os conceitos e transmitir confiança científica e qualidade técnica ao estudo da pesquisa, para isso uma revisão sistemática da literatura foi elaborada para garantir o entendimento e

buscar respostas científicas aos desafios da pesquisa além do aprendizado com outros pesquisadores.

Também, nesta sessão do estudo, será apresentada a revisão da literatura direcionada ao conhecimento e conceitos da indústria 4.0., definição das tecnologias analíticas empregues na medição de desempenho do equipamento e a importância das tecnologias de IIoT para o monitoramento em tempo real, para que se entenda o potencial disruptivo destas, assim como possíveis aplicações na indústria.

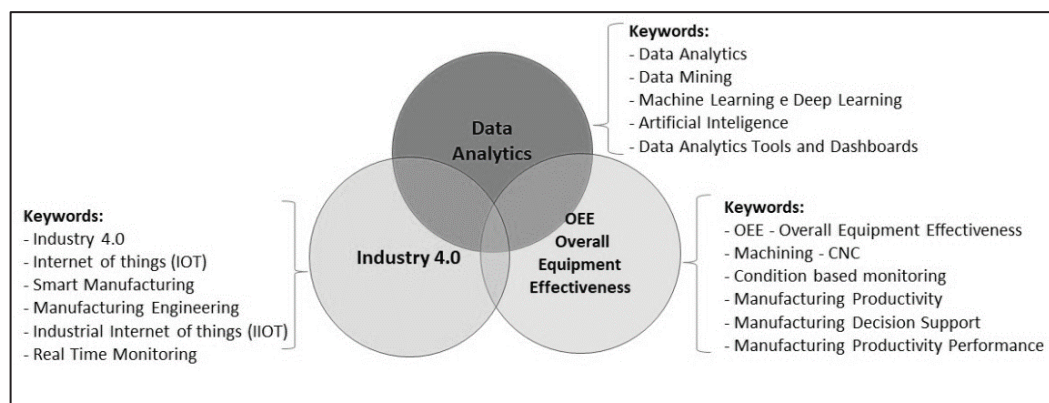
## 2.1 REVISÃO SISTEMÁTICA DA LITERATURA (RSL)

Atentando para o avanço sistemático e dinâmico das tecnologias, a partir da criação do conceito de "Indústria 4.0" e da evolução do desempenho Industrial (ACATECH, 2016), foram definidos três termos como temas centrais da revisão bibliográfica. São eles: *Industry 4.0*, *Data Analytics* e *OEE (Overall Equipment Effectiveness)*.

Foram realizadas buscas nas fontes de base acadêmicas "*Web of Science*" e "*Scopus*", focando em publicações na língua inglesa e portuguesa, publicadas posteriormente a 2015 e classificadas como "*Articles*" e "*Conference Papers*".

Acredita-se que a busca pelos termos "*Industry 4.0*", "*Data Analytics*" e "*OEE - Overall Equipment Effectiveness*" seria exaustivo à análise e leitura, se considerados os 3 eixos isoladamente. Assim sendo, foi composta a combinação dos três termos e a inclusão de palavras-chave para cada eixo, focados em trazer resultados direcionados ao trabalho, conforme indicado na FIGURA 4.

FIGURA 4 – EIXO DE PESQUISA E PALAVRAS-CHAVE



Fonte: Autor (2022)

### 2.1.1 Metodologia de pesquisa

Buscou-se dar ênfase ao estudo, focando e direcionando a pesquisa através da combinação dos 3 eixos e com inclusão de palavras-chave na exploração, conforme indicado na TABELA 1.

Foi realizada uma Revisão Sistemática da Literatura (RSL), por meio da aplicação do método Proknow-C (CARVALHO, *et al.*, 2020). A aplicação da RSL possibilitou uma abordagem concreta para estabelecer uma base relevante no contexto da pesquisa, incluindo a aplicação de terminologias e tendências da indústria 4.0.

TABELA 1 – RESUMO DA APLICAÇÃO METODOLOGIA PROKNOW-C

PROCESSO DE SELEÇÃO E ESCOLHA DOS ARTIGOS				
Base de dados CAFe - Comunidade Acadêmica Federada	Eixos de Pesquisa termos principal (Inglês)	Palavras-chave seleção da palavras-chave	Pesquisa palavras-chave	Cruzamento das Palavras-chave uso de conectores "AND"
Web of Science  Scopus	Data Analytics	<i>Data Analytics</i> - Data Mining - Machine Learning e Deep Learning - Artificial Intelligence - Data Analytics Tools and Dashboards	Pesquisa no Eixo Isolado com palavras-chave  <b>16.810</b> Artigos	Cruzamentos dos eixos com as palavras-chave  <b>295</b> Artigos
	Industry 4.0	<i>Industry 4.0</i> - Internet of things (IIOT) - Smart Manufacturing - Manufacturing Engineering - Industrial Internet of things (IIOT) - Real Time Monitoring	Pesquisa no Eixo Isolado com palavras-chave  <b>13.058</b> Artigos	<i>Data Analytics (AND +) "AND" OEE (AND+)</i> 50
	OEE  <i>Overall Equipment Effectiveness</i>	<i>OEE-Overall Equipment Effectiveness</i> - Machining - CNC - Condition based monitoring - Manufacturing Productivity - Manufacturing Decision Support - Manufacturing Productivity Performance	Pesquisa no Eixo Isolado com palavras-chave  <b>682</b> Artigos	<i>Industry 4.0 (AND +) "AND" Data Analytics (AND+)</i> 150  <i>Industry 4.0 (AND+) "AND" OEE (AND+)</i> 95
PROCESSO DE FILTRAGEM DOS ARTIGOS				
Filtro com avaliação de repetição	Filtro com avaliação do título	Filtro com avaliação das citações	Filtro com avaliação do Abstrat	Filtro com avaliação do leitura completa
Exclusão dos Artigos e Papers repetidos  <b>280</b>	Exclusão dos Artigos e Papers em que o título não está alinhado a pesquisa desejada  <b>66</b>	Exclusão dos Artigos e Papers em que não tiveram no mínimo 10 citações (linha de corte igual a 10 citações)  <b>53</b>	Exclusão dos Artigos e Papers em que após leitura do Abstrat não tiveram aderência com a pesquisa e projeto  <b>30</b>	Exclusão dos Artigos e Papers após leitura completa do artigo, e aqueles que estavam disponíveis para leitura  <b>23</b>

Fonte: Autor (2022)

As etapas para aplicação do método Proknow-C podem ser observadas na TABELA 1. A análise dos artigos foi feita de acordo com a adesão ao Título, adesão



ao Resumo (Abstract), adesão geral da Introdução e Conclusão e, por fim, uma leitura detalhada dos artigos selecionados. O repositório final de literatura foi então definido nos 30 artigos restantes, que tiveram seus conteúdos analisados. A aplicação do método Proknow-C resultou em 23 artigos, com o maior nível de adesão, que se somaram ao portfólio para elaboração desta dissertação (este portfólio encontra-se listado no APÊNDICE 1).

## 2.2 REVISÃO BIBLIOGRÁFICA

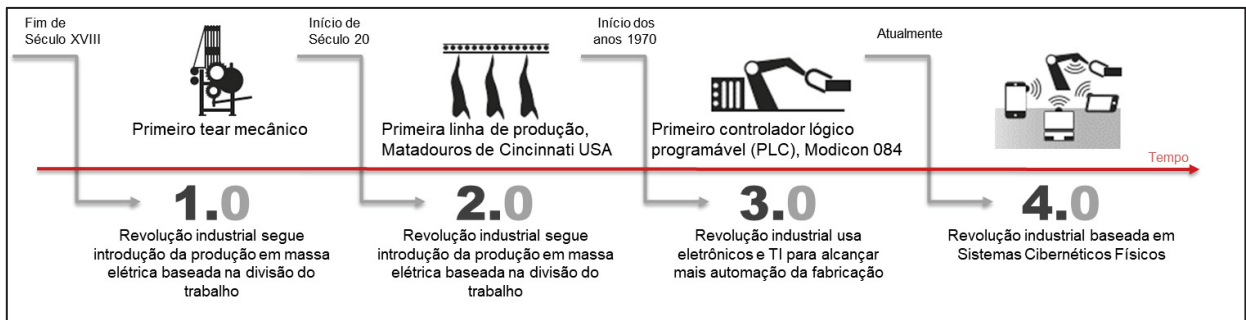
Com o resultado da RSL, nesta sessão será apresentado conceitos da indústria 4.0 e a definição das tecnologias, para que se entenda o potencial disruptivo dessas, assim como possíveis aplicações futuras.

### 2.2.1 Indústria 4.0

A termo Indústria 4.0 é uma denominação para a quarta revolução industrial, que está ocorrendo atualmente. O conceito de indústria 4.0 surgiu na Alemanha, fazendo-se cada vez mais comum nos últimos anos, precedido por três revoluções industriais provenientes da mecanização, da eletricidade e das tecnologias da informação (CHEN *et al.*, 2018).

Na FIGURA 5 é possível observar a evolução cronológica das revoluções industriais, onde também são indicadas as principais características de cada fase. Conforme Aceto *et al.* (2017), e olhando para as três revoluções anteriores, nota-se que a primeira ocorreu no final do século XVII e foi impulsionada pela evolução dos motores a vapor, energia da água e mecanização. A segunda revolução industrial foi impulsionada pelas linhas de montagem, pioneiras por Henry Ford, que primeiro oficializou a produção em massa por quase um século. A terceira revolução industrial, que ocorreu na década de 1970, foi promovida pelo uso de tecnologias de computação e automação de processos de fabricação.

FIGURA 5 – ILUSTRAÇÃO DA EVOLUÇÃO DA INDÚSTRIA



Fonte: Adaptada de Aceto *et al.* (2017)

Na última década, a indústria manufatureira vem evoluindo, solidificando o conceito da Indústria 4.0 com o objetivo de modernizar a tecnologia de sua fabricação e desenvolver fábricas inteligentes, capaz de promover maior competitividade e adaptabilidade. A indústria 4.0 compreende o desenvolvimento e integração de tecnologias de informação e comunicação nos processos de negócios e fabricação (ACETO *et al.*, 2019). Grandes indústrias em todo o mundo desenvolveram programas de implementação da Indústria 4.0, onde, muitos deles, sem saber o que realmente estavam buscando e o que deveria ser feito. Sendo assim, o caminho para a Indústria 4.0 será diferente para cada segmento da empresa e para cada fábrica. (WAGIRE *et al.*, 2019).

Neste contexto, as empresas de manufatura ainda encontram diversas lacunas para entender a revolução que estão sofrendo. No entanto, Wagire, Rathore e Jain, (2019), citam que cada vez mais desenvolvem técnicas para passagem de um estágio ao outro, onde cabe a cada empresa entender como implementar as técnicas e aproveitar dos resultados obtidos pelos estudos, que são cada vez mais representativos e direcionados a tornarem os processos mais inteligentes e autônomos.

### 2.2.2 Conectividade IIoT - *Industrial Internet of Things*


O sistema de manufatura inteligente é composto por sistemas ciber físicos ou do inglês *Cyber-Physical Systems* (CPS), tecnologias de comunicação de informação moderna (computação, controle, comunicação etc.) (KUSIAK, 2018). Com a finalidade

de maior competitividade, redução de custos, aumento da produtividade e a eficiência em suas instalações, o setor de manufatura industrial está continuamente em busca de soluções para alcançar seus objetivos. Na quarta revolução industrial, a manufatura inteligente é uma necessidade, já que muitos sensores e atuadores inteligentes estão interconectados e integrados em sistemas industriais modernos, usando tecnologias avançadas desenvolvidas pela tecnologia da *Internet of Things* (IoT), (XU *et al.*, 2018).

Com o avanço da IoT e da chamada *Industrial Internet of Things* (IIoT), Xu *et al.* (2018), comenta que a conexão com as máquinas é um conceito que a General Electric define como - a rede de uma infinidade de dispositivos conectados por tecnologias de comunicação, que resultam em sistemas que podem monitorar, coletar, trocar, analisar e trazer novos *insights* valiosos.

Rumo à Indústria 4.0, a conectividade na manufatura é o principal foco das empresas em busca de vincular o maior número possível de dispositivos, como pode ser exemplificado na FIGURA 6. O entendimento e conhecimento das variáveis geradas em seus processos produtivos já instalados, levou as empresas ao sensoriamento e a transmissão dos dados em tempo real. Assim, esses dados, podem ser interpretados e transformados em informações de qualidade subsidiando decisões assertivas em busca da redução dos custos de fabricação.

FIGURA 6 – CONCEITO DE CONECTIVIDADE IIOT



Fonte: Autor (2021)

Segundo Khan *et al.* (2020), a IIoT atua, como um subconjunto de IoT, no monitoramento dos dados, possibilitando a automação e a conexão dos equipamentos industriais para detecção, coleta, processamento e comunicação dos eventos em tempo real, possibilitando alta eficiência e produtividade operacional.

O desafio em implementar um sistema de IIoT é proporcional ao nível de automação que os equipamentos se encontram. Diversos autores, Tan (2010), Wang (2010), Khan *et al.* (2020), Aheleroff *et al.* (2020), entre outros, apontam a atualização tecnológica dos ativos e integração dos equipamentos, elencado nos grandes desafios das empresas industriais. A indústria manufatureira mantém seus equipamentos por um tempo maior que as transformações tecnológicas acontecem.

Classificar, identificar e eleger quais equipamentos devem sofrer atualizações, ou serem substituídos, é uma tarefa que as empresas precisam se atentar e colocar na rotina de adequações. Dessa maneira, podem usufruir da transmissão dos dados em tempo real, para posteriormente desenvolver sistemas de tomadas de decisão automáticas. Todavia, na prática, as empresas preservam a utilização dos equipamentos, com objetivo de redução dos custos de fabricação, mas devem manter os equipamentos atualizados e fornecendo seus dados de forma mais automática e ágil.

### 2.2.3 Geração e análise de dados

Muitos sistemas de manufatura ainda não estão prontos para gerenciar um volume alto de dados, ou *Big Data*, devido às altas demandas de acesso, qualidade e complexidade de extração, exigência de alta potência computacional, além da grande capacidade técnica exigida para tradução desses dados. Para aumentar a qualidade da extração, para que os dados sejam utilizados com eficiência e que sejam o reflexo verdadeiro da realidade da amostra, outro aspecto extremamente importante, nessa cadeia, é o *Data Mining* ou mineração de dados, o qual terá um papel essencial para identificar os padrões e realizar previsões aplicadas em diagnósticos e prognósticos de falhas (AJAY KUMA, 2018).

Essa mudança de paradigma, possibilita a extração de conhecimento significativo dos ativos monitorados por meio da adoção da conectividade. Ademais, estratégias inteligentes de monitoramento, fusão de dados, bem como a aplicação da análise efetiva dos dados - *Data Analytics* e *Machine Learning* - são fundamentais para estruturar planos e métodos de otimização de processos industriais, com o objetivo de prever efetivamente comportamentos anormais nos equipamentos.

O prognóstico, apoiado por uma base de dados, está cada vez mais visto com especial atenção e ganhando popularidade no ambiente industrial. Isso devido a capacidade de estimar eventos dos equipamentos industriais e o processo produtivo como um todo, fazendo com que o processo monitorado seja capaz de provisionar a ocorrência de eventos anormais. Isso é fundamental e essencial para o planejamento de melhoria contínua e, conseqüente, impacto no aumento da produtividade e na redução de custos na manufatura, fazendo com que o desempenho do negócio seja crescente. (DIEZ-OLIVAN, 2019)

A conexão entre o mundo real e o físico está no centro da quarta revolução industrial, não há como separá-los, se realmente a estratégia de uma empresa está alinhada para seguir rumo à Indústria 4.0 (DIEZ-OLIVAN, 2019).

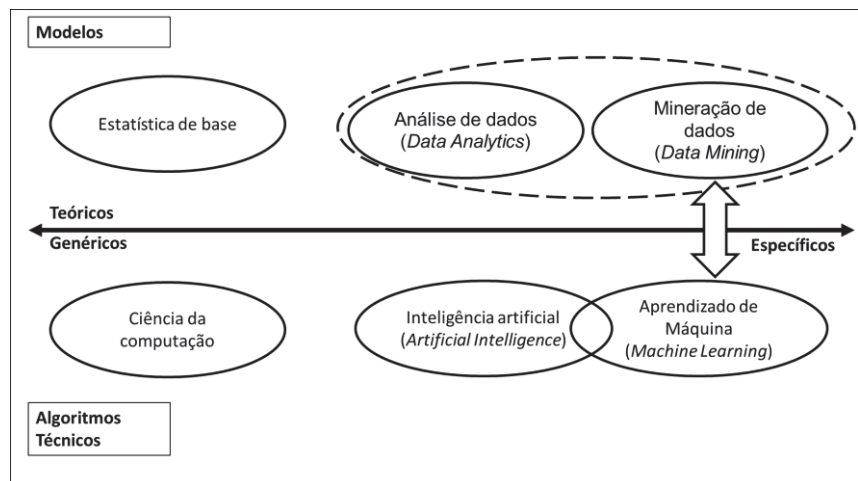
Ressalta-se, que a geração dos dados deve trazer resultados que apoiem a tomada de decisão. Encontrar padrões nos dados ajuda na formatação dos indicadores, que apontam a direção de um processo. Assim, como os dados organizados e padronizados, podem orientar a tomada de decisão.

#### 2.2.4 *Data Analytics, Data Mining e Machine learning*

Algumas pessoas observavam a estatística como uma ciência desconhecida e muitas vezes imprecisa. Talvez pelo fato que a resolução de problemas exige conhecimento acadêmico e suporte computacional. Mas, com a popularização e avanço da ciência da computação e a evolução de algoritmos de resolução de problemas, a estatística passou a ser mais difundida e se tornou uma aliada no entendimento dos problemas (CATTANEO *et al*, 2018). Termos como *Data Science* (DS), *Data Analytics* (DA), *Data Mining* (DM), *Machine Learning* (ML), *Artificial Intelligence* (IA) e outros, emergem no ambiente de análise e tratamento de dados, e entender o conceito por trás destes termos antes de aplicar as soluções computacionais disponíveis se torna imprescindível.

Para tentar esclarecer os termos e a aplicação de técnicas estatísticas, foi apresentado por Cattaneo *et al* (2018), o conceito observado na FIGURA 3.

FIGURA 7 – CLASSIFICAÇÃO DOS PRINCIPAIS CONCEITOS



Fonte: Adaptado de Cattaneo (2018)

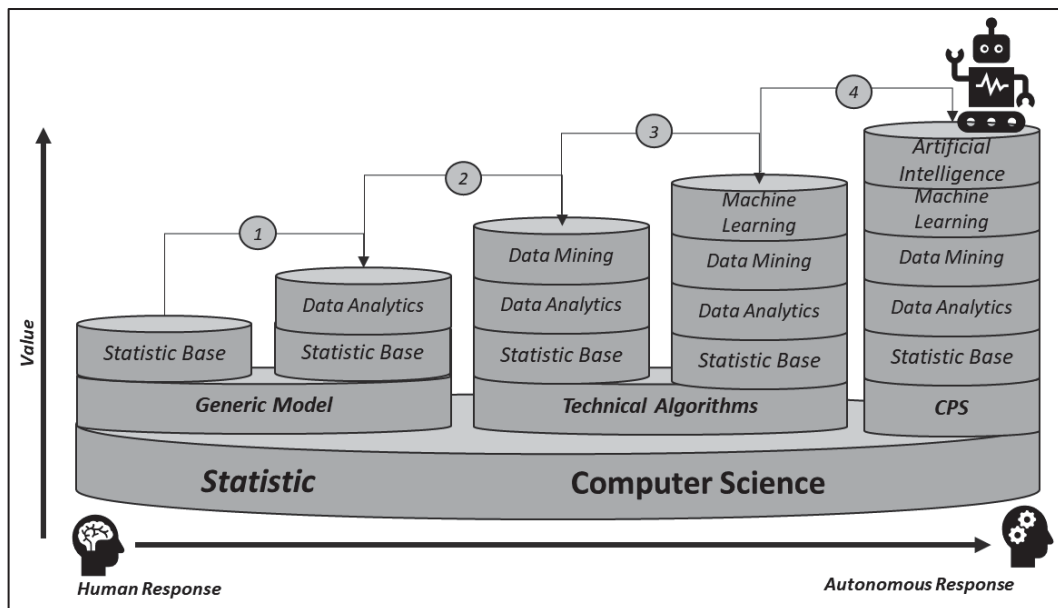
Segundo Cattaneo *et al.* (2018) a base estatística é fundamental para modelagens mais teóricas, e a ciência da computação no desenvolvimento de algoritmos genéricos, mas para alcançar o conceito de aprendizado de máquina (*Machine Learning*), e gerar os algoritmos técnicos mais específicos, que possam realizar tarefas autônomas de uma inteligência artificial (*Artificial Intelligence*) é fundamental o desenvolvimento de uma análise de dados (*Data Analytics*) ligado a Mineração de dados (*Data Mining*).

Ainda de acordo com Cattaneo *et al.* (2018) o *Machine Learning* desenvolve a maioria dos algoritmos técnicos para encontrar e descrever padrões estruturais dos dados, sendo o chamado instrumento tecnológico. Esse se conecta com *Data Mining* que, por sua vez é o campo da modelagem estatística e ligado a *Data Analytics*, que está relacionado aos conceitos e fundamentos estatísticos, que suportam *Data Mining* quanto aos preceitos estatísticos para tratamento dos dados.

Peres *et al.* (2018), apresentam como diretrizes para a implementação de análises de dados escaláveis, flexíveis e plugáveis para os sistemas de supervisão em tempo real para ambientes de manufatura o modelo - Análise Inteligente de Dados e Supervisão em Tempo Real. Frente a essa realidade, os Sistemas de Produção Ciber-Físicos, do inglês *Cyber-Physical Production Systems* (CPPS) podem ser vistos como uma tecnologia 4.0 emergente, que veio para evidenciar ainda mais a importância da coleta de dados, seu armazenamento seguro, a análise eficaz para dar confiança às manutenções preditivas, descritiva e prescritiva para uma abordagem eficaz de gerenciamento aos sistemas produtivos (RAFIQUE e VELASCO, 2018).

Segundo Lisboa *et al.* (2021), para que se realize uma análise sistemática de dados, tem-se que ter uma estatística de base, conhecimento em ciência da computação e, em seguida, construir um modelo incremental de conhecimento, partindo da base estatística e ciência da computação até avançar em algoritmos de sistemas autônomos de análise de dados. Na FIGURA 8, é apresentado o conceito para a implementação de uma análise sistemática de dados.

FIGURA 8 – CONCEITO PARA IMPLEMENTAÇÃO DE SISTEMA DE ANÁLISE DE DADOS.



Fonte: (LISBOA, et al., 2021)

Esta avaliação da evolução do conhecimento pode ser dividida em 4 passos.

A saber:

**Passo 1** – Diz respeito à estatística e seus conceitos, permite às empresas perceber a importância dos conhecimentos teóricos e acadêmicos da estatística de base. As corporações precisam se concentrar em treinamento e desenvolvimento nos princípios básicos de estatística, investindo em capacitação e programas de aprendizado, que recorrem aos conceitos estatísticos para identificar, analisar e prevenir falhas elevando positivamente o conhecimento dos fundamentos da estatística de base.

**Passo 2** – Exige-se um aperfeiçoamento no entendimento de *data Analytics*, conectado diretamente a fase de modelagem estatística. Para Zhang *et al* (2017) transformar os dados, em “fonte de dados e informação”, organizando e estruturando os dados para obter padrões é de grande valia para definir o comportamento dos

dados e gerar modelos que servirão para uma análise mais profunda. Realizar o *data analytics*, aplicando técnicas estatísticas para selecionar e transformar os dados em algoritmos para validação por testes estatísticos (HASTIE, TIBSHIRANI e FRIEDMAN, 2013).

Passo 3 – Recorrente o *data analytics* e *Data Mining* são considerados a mesma coisa. Porém, como apresentado pelo modelo Cattaneo *et al.* (2018), *Data Mining* teria relação, diretamente, com a extração de informações e *data analytics* com as técnicas estatísticas. O objetivo principal da mineração dos dados é garantir a confiabilidade através de algoritmos modelados, utilizando técnicas estatísticas que, atualmente, estão inseridas em pacotes de programação de *software* como o *R Studio* e *Phyton*.

Passo 4 – O *Machine Learning* pode ser dividido em três categorias diferentes, sendo - métodos de aprendizagem supervisionados; semisupervisionados; não supervisionados. Algoritmos de métodos de aprendizagem podem ser evoluídos para uma inteligência artificial, com decisão até mesmo autônoma. O aprendizado da máquina deve ser bem compreendido para que seja possível avançar para inteligência artificial, supervisionada ou autônoma.

Com o objetivo de garantir impactos positivos na rentabilidade, deve-se observar esta transformação como uma estratégia, que exige uma abordagem gradativa. Gerar valor e transformar os processos de dependência humana, em processos autônomos, até chegar a um modelo de inteligência artificial que tem como base a estatística e a ciência da computação. Um processo incremental que, a cada passo se soma com o conhecimento adquirido precedentemente, suporta a estrutura do conhecimento para um desenvolvimento de modelos autônomos de análise de problemas.

#### 2.2.5 Técnicas e métodos de análise de dados

Muito se fala de conhecimento e descoberta de informações, através da análise de dados, entretanto a ciência da estatística é muito ampla e profunda com seus fundamentos e conceitos, para tanto, neste item serão demonstrados alguns métodos e técnicas comumente utilizadas, para geração de algoritmos para processamento de dados.



O Processo de descoberta e conhecimento dos dados, chamado de KDD (do inglês: *Knowledge Discovery in Database*), é dividido nas seguintes etapas: Limpeza, Integração, Seleção, Transformação, Mineração de dados, Avaliação dos padrões, Apresentação e Assimilação dos conhecimentos gerados (HAN et al., 2011). Existem diferentes abordagens e diferentes etapas. Entretanto, de modo geral a Mineração de dados como parte do KDD é segundo Han *et al.* (2011) um dos principais processos. A Mineração de dados depende essencialmente da técnica e dos métodos que serão aplicados na base de dados, possibilitando o tratamento e descobrimento das informações presentes. Segundo Cattaneo *et al.* (2018), a mineração de dados é a extração de informações implícitas, anteriormente desconhecidas e potencialmente úteis dos dados. A ideia é construir algoritmos numéricos que investiguem conjuntos de dados para extrair padrões e regularidades ocultas. Na mineração de dados, os dados são armazenados eletronicamente e a busca é automatizada por meio do sistema computacional. Porém, ainda sim, faz-se necessário uma análise humana posterior sobre onde e de que maneira esse conhecimento pode ser aplicado.

Ainda, conforme Cattaneo *et al.* (2018), a mineração de dados é classificada pela sua habilidade em realizar determinadas tarefas, as quais extraem tipos diferentes de conhecimento do banco de dados, sendo necessário a utilização de algoritmos diferentes para cada uma delas.

#### 2.2.6 Técnicas de análises, tarefas e métodos

As técnicas de análise ou tarefas a serem seguidas são inúmeras. Porém, para melhor definir e exemplificar, observa-se as principais tarefas e os métodos estatísticos rotineiramente utilizados na TABELA 2.

Por ser possível a automatização, essas tarefas têm normalmente um propósito particular, da qual existem diversas implementações distintas por meio de vários algoritmos. Esses são divididos pelas tarefas levando em consideração o objetivo da implementação (RAFIQUE e VELASCO, 2018).

Essas técnicas são eleitas de acordo com o nível de extração da informação necessária, para sistemas de análise de dados coletados em automático. Muitas vezes se faz necessária a combinação de várias dessas técnicas, para transformar os dados em informação, que possa ser utilizada nos algoritmos.

TABELA 2 – TAREFAS E MÉTODOS ESTATÍSTICOS

Técnicas de análises (tarefas)	Método Sugerido (termos em inglês)
Regras de associação	<i>Frequent Item set Mining</i>
Classificação	<i>Decision Trees</i> <i>Bayesian Classification</i> <i>Rule-Based Classification (RBC)</i> <i>Neural Networks</i> <i>Support Vector Machines</i> <i>Lazy Learners</i> <i>Genetic Algorithm</i> <i>Rough Set</i> <i>Fuzzy Set</i>
Predição numérica	<i>Linear Regression</i> <i>No-Linear Regression</i>
Agrupamento	<i>Partitioning Methods: k-Means ; k-Medoids</i> <i>Hierarchical Methods</i> <i>Grid-Based Methods</i> <i>Model-Based Methods</i>

Fonte: Autor (2021)

### 2.2.7 OEE – *Overall Equipment Effectiveness* e produtividade

O setor de manufatura industrial está em contínua busca de soluções para alcançar seus objetivos produtivos. O aumento da aplicação de máquinas dotadas de Comando Numérico Computadorizado (CNC), Controladores Lógicos Programáveis (CLP), substituição das máquinas convencionais por outras que possuem sistemas com maior conectividade e inteligência embarcada, são notáveis. Ou seja, limita a tomada de decisões, com foco nos comandos de operação, do operador e por conseguinte, consegue a melhoria da repetibilidade e da produtividade (WANG *et al.*, 2018).

No que concerne às características das peças fabricadas, também sucedeu um aumento da demanda por peças de melhor qualidade e mais complexas. Isso faz com que cada vez mais os equipamentos produzidos pela indústria tenham que corresponder às exigências por qualidade, produtividade e baixo custo de operação. Para que todas as demandas dos clientes sejam atendidas, a indústria necessita

transformar as informações geradas no processo produtivo em indicadores de Produtividade (GUPTA e VARDHAN, 2016).

Seiichi Nakajima em 1988, publicou a primeira edição de seu livro *Introduction to TPM: Total Productive Maintenance*, e propõe que o *Overall Equipment Effectiveness* (OEE) seja o indicador que mede a eficiência do sistema de produção, e a TPM (Total Productive Maintenance), ou Manutenção Produtiva Total, o sistema que se propõe a um processo de produção enxuta.

OEE é tradicionalmente usado por profissionais, como uma medida operacional, para monitorar o desempenho da produção, mas também pode ser usado como um indicador para atividades de melhoria de processos (ANDERSSON e BELLGRAN, 2015). Neste contexto de Indústria 4.0 e produtividade, o OEE passa a ser um indicador importante para ser digitalizado e apresentado como visualização dos dados de manufatura.

O índice OEE é dividida em três métricas conhecidas como: disponibilidade, performance e qualidade. Essa combinação multiplicada forma o índice de eficácia do equipamento e seu valor é calculado como:

$$OEE = \% \text{ Disponibilidade} * \% \text{ Performance} * \% \text{ Qualidade} \quad (1)$$

O índice consiste na combinação de eficácia consolidada, por três métricas básicas, sendo a medida pela disponibilidade que viabiliza o tempo, a performance que mede o desempenho de máquina e qualidade do produto produzido (GUPTA e VARDHAN, 2016).

A disponibilidade é calculada com a relação entre Tempo Produzindo (TP) e Tempo Programado para Produzir (TPP). A disponibilidade representa o tempo que o equipamento terá para produzir, em relação ao tempo total disponível para produção, sendo calculado da seguinte maneira:

$$\% \text{ Disponibilidade} = \frac{TPP}{TP} * 100 \% \quad (2)$$

Onde,

TP = Tempo disponível Total - Tempo de Parada Total Planejada

TPP = TP – Total de Paradas

Uma atenção que se deve considerar, quando é realizado o cálculo de OEE e a métrica de disponibilidade, é que dependendo de como for composto o TPP influenciará no cálculo de disponibilidade. Quando pensando em *Machine Learning* e predição automática de disponibilidade, as perdas que serão consideradas no TPP devem ser bem registradas e definidas (ENGELMANN *et al.*, 2020).

A performance é a relação que demonstra a eficácia, ou quão bem o equipamento produz. Esse está relacionado com a velocidade de operação do equipamento, onde a performance compara a quantidade produzida (QP) com a quantidade teórica (QT). Ou seja, é a proporção do total de produção realizada, em relação ao que poderia ser produzido, conforme citam Gupta e Vardhan (2016). Jain, Bhatti e Singh, (2015) sugere que seja calculado da seguinte maneira:

$$\% \text{ Performance} = \frac{QP}{QT} * 100\% \quad (3)$$

Onde,

QP = Quantidade produção realizada

QT = Quantidade de produção teórica

Por fim, tem-se o índice de qualidade, que indica quantos itens bons foram produzidos em relação ao total de itens produzidos, sendo calculado da seguinte maneira:

$$\% \text{ Qualidade} = \frac{QPB}{QPB+QPR} * 100\% \quad (4)$$

Onde,

QPB = Quantidade de peças Boas

QPR = Quantidade de peças Ruins

O OEE é um poderoso indicador de produtividade, mas como mencionado é apenas um indicador de disponibilidade, performance e qualidade, que depende das análises que se dá, com o tratamento das perdas geradas (ENGELMANN *et al.*, 2020). As principais causas de queda da produtividade podem ser representadas por seis grandes perdas. Para um cálculo bem-sucedido, a coleta dos dados é de extrema importância, pois se os dados não forem confiáveis e bem direcionados a causa, o

resultado calculado não reflete a utilização da unidade de produção. De acordo com Engelmann *et al.* (2020), as perdas que influenciam o OEE podem ser combinadas conforme exposto na TABELA 3.

TABELA 3 – OEE COMBINADOS COM SEIS TIPOS DE PERDA

FATOR OEE	TIPO DE PERDA	CAUSA DA PERDA
DISPONIBILIDADE	1. AVARIAS Falhas do Equipamento	<ul style="list-style-type: none"> <li>• Falha do dispositivo</li> <li>• Falha do componente principal</li> <li>• Manutenção não programada</li> </ul>
	2. ARRANQUE Setup e Ajustes	<ul style="list-style-type: none"> <li>• Setup do Equipamento</li> <li>• Falta de Matéria Prima</li> <li>• Falta de mão-de-obra</li> </ul>
PERFORMANCE	3. MARCHA LENTA Baixa de velocidade e pequenas paradas	<ul style="list-style-type: none"> <li>• Falha do dispositivo de curto prazo (&lt; 5min)</li> <li>• Produto Defeituoso</li> <li>• Impedimento do Processo</li> <li>• Dispositivo fora da velocidade nominal</li> </ul>
	4. REDUÇÃO DE VELOCIDADE	<ul style="list-style-type: none"> <li>• Falta de treinamento (experiência)</li> <li>• Ociosidade</li> </ul>
QUALIDADE	5. DESVIO DE QUALIDADE Desvios de qualidade no processo produtivo	<ul style="list-style-type: none"> <li>• Peças refugadas pelo Processo – <i>Scrap</i></li> <li>• Retrabalho Processo – <i>Rework</i></li> <li>• Processo Danificado (peças Recuperada no processo)</li> </ul>
	6. DESVIO DE QUALIDADE PRODUTO Desvio de qualidade no produto	<ul style="list-style-type: none"> <li>• Peças refugadas – <i>Scrap</i></li> <li>• Retrabalho Produto – <i>Rework</i></li> <li>• Processo Danificado (peças Recuperada)</li> </ul>

Fonte: Engelmann *et al.* (2020)

O desafio de um OEE em automático está em definir as perdas e identificar a origem. Algumas perdas estão relacionadas às atividades não controladas por sensores ou equipamentos, onde, muitas vezes os cálculos de performance e disponibilidade podem ser afetados, com base na variabilidade dos dados não controlados por equipamentos. Logo uma análise criteriosa das causas e seus efeitos é crucial, para classificação das falhas com relação a sua origem, sendo

frequentemente necessário a inserção de técnicas estatísticas para definir a causa e a fonte de variação.

#### 2.2.8 Conhecimento e aprendizado na análise de falhas

São crescentes o desejo e a necessidade da previsão de anormalidades nos processos produtivos. A previsão de uma falha é de extrema importância para processos, que, a cada melhoria e adaptação recebida, espera-se uma performance cada vez maior.

A falta de disponibilidade, instabilidade e ineficiência, que foram dilemas e compreendidos como deficiências fundamentais por décadas na manufatura, estão cada vez mais dissonantes, frente aos novos desafios e expectativas no ambiente industrial. Muito relacionado a esse dilema veio da falta de conhecimento das falhas.

Além da previsão do evento, espera-se a explicação de como esse evento específico vai acontecer, sendo preditivo e prescritivo. Para se atingir esse nível de melhoria considerável, é necessário tomar decisões com base em eventos de prognósticos confiáveis de falhas.

Os autores Ansari, Glawar e Nemeth (2019) propõem que a termo '*Knowledge-Based Maintenance*' (KBM), deve ser usada para denotar toda a gama de recursos e capacidades funcionais. O termo KBM abrange vários conceitos e abordagens de manutenção, incluindo manutenção descritiva, diagnóstica, preditiva e prescritiva. Esses mesmos autores ainda destacam o desafio de lidar com o número significativo de "alarmes falsos", que por consequência, as abordagens avançadas de aprendizado de máquina são necessárias para melhorar a detecção desses falsos alarmes. Isso gera suporte à detecção de erros falsos-positivos e falsos negativos e, finalmente, a automatização do processo de suporte à decisão.

Ansari, Glawar e Nemeth (2019) relatam que as barreiras e limitações tecnológicas e não tecnológicas são encontradas com o aumento do nível de tecnologia na empresa, como competência de gerenciamento de dados industriais, análise eficaz de dados preditivos, estrutura de TI (Tecnologia da Informação), acessibilidade, disponibilidade e qualidade dos dados, segurança e privacidade dos dados.

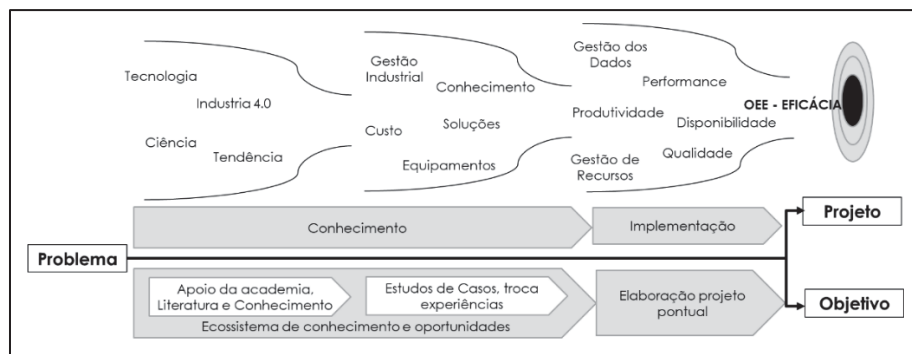
### 3 ABORDAGEM METODOLÓGICA

Este capítulo descreve a importância da abordagem metodológica *Design Science Research* (DSR), para aliviar o modelo estratégico de planejamento, execução e entregas, o qual consiste nas classes de problemas e artefatos. A partir de um problema teórico ou prático identificado, é necessário se conscientizar das repercussões à organização de sua existência ou persistência.

Além das repercussões, é necessário identificar quais objetivos ou metas são necessários para que o problema, transitoriamente seja considerado satisfatoriamente resolvido (LACERDA *et al.*, 2013). Esse procedimento consiste na “conscientização” e em um primeiro contorno do problema.

A partir dessa conscientização, é necessário realizar uma revisão sistemática na literatura, com o objetivo de estabelecer o conjunto de soluções empíricas conhecidas, a qual está sendo ilustrada na FIGURA 9.

FIGURA 9 – CONCEITO DE CONHECIMENTO E IMPLEMENTAÇÃO DE PROJETO



Fonte: Autor (2022)

Utilizar-se do DSR é uma opção segura por ser a mais utilizada dentre as metodologias possíveis, pois ao longo dos anos este método renomado de pesquisa vem sendo utilizado pelas áreas tecnológicas e de engenharia.

#### 3.1 DESIGN SCIENCE RESEARCH

A missão principal da *Design Science* é desenvolver conhecimento para a concepção e desenvolvimento de artefatos (AKEN, 2004). A questão da relevância do conhecimento produzido e a tensão na relação teoria-prática exigem, um novo foco

de pesquisa. Essas efetivamente direcionadas ao projeto de artefatos que sustentem melhores soluções para os problemas existentes (LACERDA *et al.*, 2013).

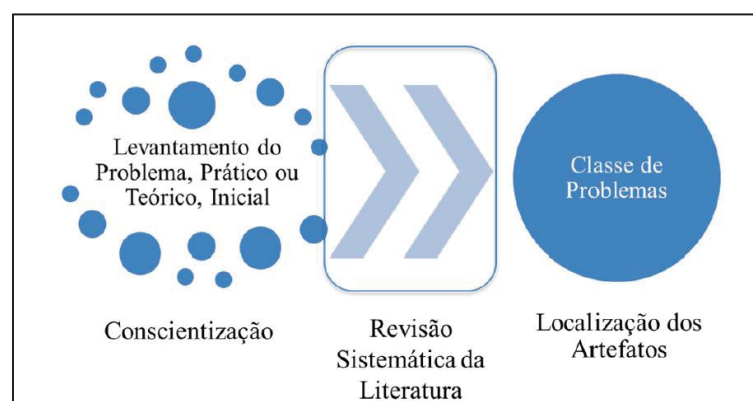
Segundo Romme (2003) os estudos relacionados às organizações devem incluir a *Design Science* e a *Design Science Research* (DSR), como um dos principais modos de conceber o conhecimento e de realizar pesquisas científicas.

O método DSR, para Vaishnavi e Kuechle (2004), é um novo olhar ou um conjunto de técnicas analíticas que permitem o desenvolvimento de pesquisas, nas diversas áreas, em particular na engenharia. A DSR tem como objetivo estudar, pesquisar e investigar o artificial e seu comportamento, tanto do ponto de vista acadêmico quanto da organização (BAYAZIT, 2004).

### 3.1.1 *Design Science Research* como uma metodologia

Sein *et al.* (2011) consideram que a definição de classes de problemas deve ser realizada para favorecer a pesquisa, desde sua concepção até a generalização de seus resultados. Visando assim, a aplicação da solução, não só para um problema em específico, mas sim para, justamente, uma certa classe de problemas. Para fins ilustrativos, cabe organizar uma lógica gráfica de definição de partida de classes de problemas, expressa na FIGURA 10.

FIGURA 10 – LÓGICA PARA CONSTRUÇÃO DAS CLASSES DE PROBLEMAS.



Fonte: Lacerda *et al* (2013)

Uma vez definidas as classes de problemas, é necessário caracterizar os artefatos associados. Simon (1996) denota os resultados de *Design* como sendo as criações de artefatos, normalmente concebidos para satisfazer uma necessidade ou



para atender a um objetivo. Esses artefatos, em algumas vezes, que têm caráter extensionista, são normalmente concebidos para atender a uma necessidade, ou para alcançar algum objetivo. O artefato é a organização dos componentes do ambiente interno para atingir objetivos em um determinado ambiente externo.

As saídas (resultados) da DSR são os artefatos. Ou seja, uma vez definidos os artefatos, pode-se tipificá-los como Constructos, Modelos, Métodos e Instanciações, segundo citam March e Smith (1995). No QUADRO 1, constam as definições de cada tipo de artefatos:

QUADRO 1 – TIPOS DE ARTEFATOS

TIPOS DE ARTEFATOS	DESCRIÇÃO DO CONCEITO
CONSTRUCTOS	Constructos ou conceitos formam o vocabulário de um domínio. Eles constituem uma conceituação utilizada para descrever os problemas dentro do domínio e para especificar as respectivas soluções. Conceituações são extremamente importantes em ambas as ciências, natural e de design. Eles definem os termos usados para descrever e pensar sobre as tarefas. Eles podem ser extremamente valiosos para designers e pesquisadores.
MODELO	Um modelo é um conjunto de proposições ou declarações que expressam as relações entre os constructos. Em atividades de <i>design</i> , modelos representam situações como problema e solução. Ele pode ser visto como uma descrição, ou seja, como uma representação de como as coisas são. Cientistas naturais muitas vezes usam o termo 'modelo' como sinônimo de 'teoria', ou 'modelos' como as teorias ainda incipientes. Na <i>Design Science</i> , no entanto, a preocupação é a utilidade de modelos, não a aderência de sua representação à Verdade. Não obstante, embora tenda a ser impreciso sobre detalhes, um modelo precisa sempre capturar a estrutura da realidade para ser uma representação útil.
MÉTODO	Um método é um conjunto de passos (um algoritmo ou orientação) usado para executar uma tarefa. Métodos baseiam-se em um conjunto de constructos subjacentes (linguagem) e uma representação (modelo) em um espaço de solução. Os métodos podem ser ligados aos modelos, nos quais as etapas do método podem utilizar partes do modelo como uma entrada que o compõe. Além disso, os métodos são, muitas vezes, utilizados para traduzir um modelo ou representação em um curso para resolução de um problema. Os métodos são criações típicas das pesquisas em <i>Design Science</i> .
INSTANCIÇÕES	Uma instanciação é a concretização de um artefato em seu ambiente. Instanciações operacionalizam constructos, modelos e métodos. No entanto, uma instanciação pode, na prática, preceder a articulação completa de seus constructos, modelos e métodos. Instanciações demonstram a viabilidade e a eficácia dos modelos e métodos que elas contemplam.

Fonte: Adaptado de Lacerda (2013)

Segundo Manson (2006), a metodologia de DSR compreende as etapas: Conscientização (Consciência do problema); Sugestão; Desenvolvimento; Avaliação

e Conclusão. As etapas da DSR pode ser melhor compreendidas pelo QUADRO 2, que detalha os argumentos de cada pesquisador em relação às etapas.

QUADRO 2 – ETAPAS DO PROCESSO DSR E ARGUMENTAÇÃO CIENTÍFICA.

ETAPAS DSR	ARGUMENTAÇÃO DOS PESQUISADORES
Conscientização (consciência do problema)	Manson (2006) entende que é nesse momento que se inicia a construção formal ou informal do processo de investigação. Nessa etapa, é requerida a análise de um conjunto de conceitos, teorias e relações verificadas e experimentalmente, sendo úteis para explicar processos e resultados organizacionais.
	Peffer (2004) explica que a conscientização do problema é a identificação de problemas e a motivação, é o momento em que se define o problema e justifica-se o valor da solução.
Sugestão	A Sugestão, segundo Manson (2006), está vinculada às atividades de desenvolver uma, ou mais, alternativas de artefato para a solução dos problemas. A Sugestão é um processo essencialmente criativo, análogo ao processo de teorização, nas ciências naturais, em que “[...] diferentes pesquisadores podem gerar distintas teorias para um conjunto igual de observações [...]” (MANSON, 2006, p. 163).
	Para Vaishnavi e Kuechler (2004). Observa-se que as sugestões para o problema são delineadas a partir da existência de conhecimento/teoria de base sobre o problema.
Desenvolvimento	Para Peffer (2004) e Vaishnavi e Kuechler (2004), o artefato é desenvolvido e implementado nessa fase. A etapa do desenvolvimento é a efetiva construção do artefato pelo pesquisador, podendo ser um ou conjunto de artefatos para solucionar o problema proposto e, para isso, dependerá da utilização de várias técnicas em conformidade com o objeto que se está estudando.
	Para Lacerda <i>et al.</i> (2013), o desenvolvimento corresponde ao processo de constituição do artefato, tal construção pode utilizar diferentes abordagens, tais como: algoritmos computacionais, representações gráficas, protótipos, maquetes em escala, entre outros. Assim sendo, o principal resultado do Desenvolvimento é o artefato em estado funcional.
Avaliação	Na fase de avaliação do artefato, Peffer (2004), Vaishnavi e Kuechler (2004) e Manson (2006) explicam que deve ser analisado e testado de acordo com as condições estabelecidas para validação; essa etapa contribui ao processo de melhoria do artefato construído.
	Segundo Lacerda <i>et al.</i> (2013) a avaliação é definida como o processo rigoroso de verificação do comportamento do artefato no ambiente para o qual foi projetado, em relação às soluções que se propôs alcançar. Uma série de procedimentos é necessária para verificar o desempenho do artefato.
Conclusão	Vaishnavi e Kuechler (2005) mencionam que não são apenas os resultados do esforço de consolidação e a “escrita” nessa fase, mas o conhecimento adquirido pelo esforço é frequentemente categorizado como “firmes”, fatos que foram aprendidos. Essa etapa pode ser aplicada repetidamente ou os comportamentos podem ser repetidos.
	Lacerda <i>et al.</i> (2013) define que a conclusão consiste na formalização geral do processo e sua comunicação às comunidades acadêmica e de profissionais.

Fonte: Adaptado de Lacerda (2013)

Por fim, a orientação de avaliação do DSR, apresentado por Hevner *et al.* (2004), que mencionam sete diretrizes para avaliar o projeto, são demonstradas no QUADRO 3.

QUADRO 3 – DIRETRIZES DE AVALIAÇÃO DO *DESIGN RESEARCH*

DIRETRIZ	INSTRUÇÃO	DESCRIÇÃO
1	Design como Artefato	A pesquisa fundamentada em Design Science deve produzir um artefato viável, na forma de um constructo, modelo, método e/ou uma instanciação.
2	Relevância do Problema	O objetivo da pesquisa fundamentada em <i>Design Science</i> é desenvolver soluções baseadas em tecnologia para problemas gerenciais importantes e relevantes.
3	Avaliação do <i>Design</i>	A utilidade, qualidade e eficácia do artefato devem ser, rigorosamente, demonstradas por meio de métodos de avaliação bem executados.
4	Contribuições do <i>Design</i>	Uma pesquisa fundamentada em <i>Design Science</i> deve prover contribuições claras e verificáveis nas áreas específicas dos artefatos desenvolvidos, e apresentar fundamentação clara em fundamentos de <i>design</i> e/ou metodologias de <i>design</i> .
5	Rigor da Pesquisa	A pesquisa em <i>Design Science</i> é baseada em uma aplicação de métodos rigorosos, tanto na construção como na avaliação dos artefatos.
6	<i>Design</i> como um Processo de Pesquisa	A busca por um artefato eficaz e efetivo exige a utilização de meios que sejam disponíveis, para alcançar os fins desejados, ao mesmo tempo que satisfaz as leis que regem o ambiente em que o problema está sendo estudado
7	Comunicação da Pesquisa	A pesquisa em <i>Design Science</i> deve ser apresentada tanto para o público mais orientado à tecnologia quanto para aquele mais orientado à gestão.

Fonte: Adaptado de Lacerda (2013).

A abordagem *Design Science Research* orienta que a pesquisa deve ser conduzida pela aplicação de métodos rigorosos tanto na construção quanto na avaliação do artefato. Na presente pesquisa, buscou-se seguir as diretrizes propostas pela *Design Science Research* e o desenvolvimento é apresentado no capítulo seguinte.

#### 4 APLICAÇÃO DO DSR NA PESQUISA

Com o objetivo de implementar as tecnologias da Indústria 4.0 como IIoT e *Data Analytics*, com uma visão nos equipamentos industriais, e com intuito de melhorar a produtividade dos equipamentos através da medição OEE, a aplicação da

pesquisa seguiu rigorosamente a metodologia DSR. Dessa maneira, espera-se que haja o melhor uso das tecnologias, dos equipamentos instalados e, para melhor aplicação de uma metodologia que possa ser usado na empresa, assim como por outras empresas e pesquisadores.

Com esse propósito, para o desenvolvimento e aplicação da pesquisa selecionou-se uma indústria do “setor de usinagem de transmissões”, que indica o processo de usinagem como fundamental para o manutenção da reputação de seus produtos. O setor de usinagem desta empresa possui, aproximadamente 23 equipamentos CNCs, com uma disponibilidade em função do processo e tipo de transmissões a serem usinados. O OEE é feito manualmente, por coleta de dados em fichas, cognominadas como “diários de bordo” e calculadas em ambiente que não o local de operação.

A pesquisa é dividida nas 5 etapas da metodologia DSR, Conscientização, Sugestão, Desenvolvimento, Avaliação e Conclusão, as quais serão explicadas nas seções seguintes.

#### 4.1 CONSCIENTIZAÇÃO DO PROBLEMA

A compreensão da conscientização do problema, foi levantada através da recente digitalização e avanço significativo das tecnologias incorporadas nos produtos, atualmente relacionado ao tema de pesquisa. O avanço tecnológico fomentado pela maior produtividade e redução dos desperdícios dos produtos (equipamentos agrícolas), exige que a sua manufatura acompanhe essa crescente necessidade. A cada nova tecnologia embarcada, a manufatura prepara seus ativos para atender as novas exigências e, com o aumento das exigências, a busca por soluções que a torne uma manufatura cada vez mais inteligente.

Devido características diferentes no campo fabril e no campo da informação, ainda há muitos problemas técnicos a serem resolvidos, para acelerar o caminho da manufatura inteligente, conforme citam Chen *et al.* (2018). Equipamentos físicos precisam ter suporte para aquisição de informações em tempo real, assim, a IIoT deve suportar novos protocolos e formatos de dados com alta flexibilidade e escalabilidade (como exemplo arquiteturas unificadas como OPC-UA). A plataforma de armazenamento deve ser capaz de analisar a semântica de vários dados e transmitir

a informação certa, para que haja a melhoria dos indicadores de performance produtiva (DALENOGARE *et al.*, 2017). Outrossim, a análise de dados pode fornecer a base científica para a tomada de decisões, enquanto a mineração de dados pode ser usada para garantir a otimização dos processos.

Observa-se que após a implementação das técnicas de fabricação inteligente, oriunda de fundamentos da indústria 4.0, percebe-se uma melhora substancial em vários indicadores de desempenho (MADHAB, MISHRA e MOHARANA, 2020).

Aspecto voltado a conscientização está no conhecimento e a sua falta em relação às tecnologias da indústria 4.0, em especial de IloT e *Data Analytics*, fizeram crucial a introdução de pesquisadores e discussões teóricas no âmbito da universidade e na indústria.

Em relação a parte da pesquisa, essa aconteceu apoiada principalmente no entendimento do problema como um todo. Para tanto, conforme já apresentado no capítulo 2, a fundamentação teórica teve um aspecto influenciador das mudanças do uso das tecnologias e das suas aplicações.

O fundamento dos conceitos da Indústria 4.0 e suas tecnologias, formatou um modelo para obtenção do indicador OEE, produtividade e suas aplicações para solucionar o problema da pesquisa. A saber: como implementar um sistema de mensuração do OEE, em tempo real, que possa ser visualizado em painéis (*dashboard*) e a tomada de decisão possa ser feita antes de uma perda de performance produtiva?

Desta forma, o artefato proposto é uma metodologia que compreenda desde a fase de conhecimento das tecnologias seguido dos conhecimentos dos equipamentos e processo, dos dados gerados passando pela aplicabilidade das técnicas analíticas para obtenção das informações do OEE e que possibilite apresentação nos painéis digitais (*dashboard*).

## 4.2 SUGESTÃO PARA O PROBLEMA

Após o passo da consciência do problema, seguiu-se para a sugestão. No processo de análise da literatura, realizado no capítulo 2.1 e com base a Vaishnavi e Kuechler (2004), a sugestão para o problema é delineada a partir da existência de

conhecimento/teoria, de base sobre o problema. De acordo com o conhecimento adquirido foi possível a construção do artefato, que se divide em 2 momentos.

Momento 1 - Implementar um modelo de escala menor: seria o piloto que abrangeria pontos relevantes como sendo o modelo inicial, aplicado em condições fidedignas ao processo e supervisionados pelos pesquisadores envolvidos no estudo. Com o desígnio de seleção de equipamentos e usuários, bem como avaliar e testar a efetividade do modelo.

Momento 2 – Conectar os equipamentos eleitos através das camadas de interconexão: uma fábrica inteligente necessita estar conectada e projetada para um sistema de *Smart Factory* que consiste principalmente em quatro camadas, segundo Chen et al. (2018). São elas:

1. Camada de recursos Físicos (*Physical Resource Layer*);
2. Camada de comunicação de rede (*Network Layer*);
3. Camada de aplicação/armazenamento de dados (*Data Application Layer*);
4. Camada de visualização/Interface (*Terminal Layer*).

Essas categorias formatarão a implicação do modelo de conexão a ser utilizado, sendo necessário planejar o desenho de cada camada como parte do artefato. Isso vai desde a comunicação com o recurso físico, criação do ambiente dos protocolos de comunicação de rede, incluindo o armazenamento e disponibilidade dos dados para geração de indicadores de performance em formato de painéis digitais (*dashboard*).

Para ter a visão do artefato como um todo, também é importante e necessário desenvolver um modelo hierárquico de responsabilidade, no qual os níveis da empresa e responsáveis pela decisão, são identificados e classificados em função de suas relevâncias na tomada de decisão e desenvolvimento dos *dashboards*.

### 4.3 DESENVOLVIMENTO

Segundo Peffers *et al.* (2007) e Vaishnavi e Kuechle (2004), na fase desenvolvimento é o passo no qual o artefato é avançado com os recorrentes ajustes, para que possa ser testado e avaliado. Pode ser um artefato ou um conjunto deles

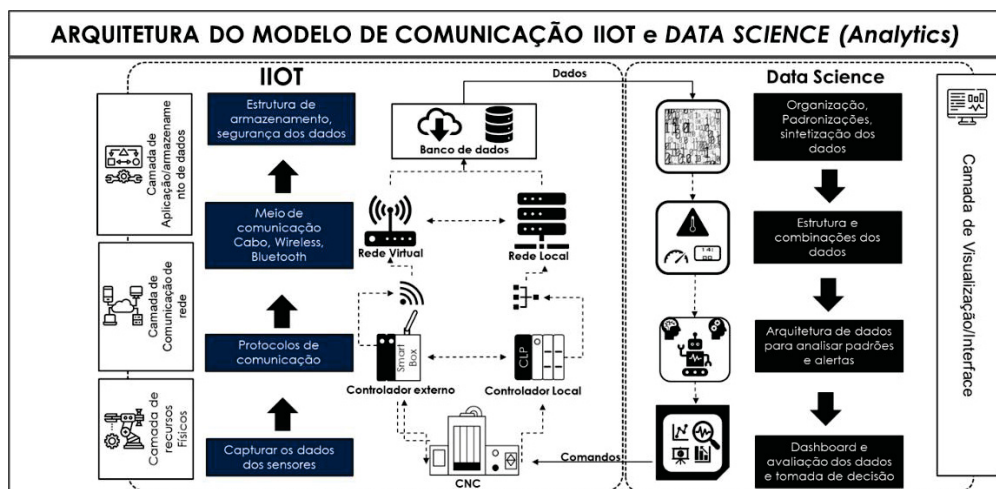
para solucionar o problema proposto e, para isso, dependerá da utilização de várias técnicas em conformidade com o objeto alvo do estudo.

Para o advenho do desenvolvimento é necessário pensar na solução do artefato, nos ativos instalados, nos usuários envolvidos, conexão de rede e comunicação, armazenamento e também na disponibilidade das informações. Para isso o artefato ou modelo foi dividido de acordo com as quatro camadas proposto por Chen *et al.* (2018) elencadas acima e desenvolvido conforme arquitetura apresentada na FIGURA 11.

O Método proposto pode ser dividido nas 4 principais camadas e subdividida em 9 atividades necessária, para desenvolvimento do artefato. São elas:

- 1) Mapeamento dos ativos envolvidos na pesquisa;
- 2) Seleção dos ativos;
- 3) Avaliação dos parâmetros de influência do processo;
- 4) Definição do protocolo de comunicação;
- 5) Definição do modelo de rede de comunicação a ser utilizada;
- 6) Sistema analítico de comunicação IoT e tratamento de dados;
- 7) Armazenamento e acesso dos dados;
- 8) Modelo hierárquico de responsabilidade;
- 9) Visualização dos painéis digitais.

FIGURA 11 – ARQUITETURA DE COMUNICAÇÃO IIOT E DATA SCIENCE.



Fonte: Autor (2021)

Ainda para cada atividade desenvolvida foi proposto um método ou ferramentas, que podem ser observadas no QUADRO 4, onde se destaca o que foi sugerido para o artefato.

Esse modelo foi avaliado e sugerido na etapa anterior do DSR, e atende ao estudo ligado ao processo que foi submetido, neste caso máquinas CNC e processo de fabricação. Para outros processos devem ser avaliado e pensado os método e ferramentas mais adequadas, respeitando o conceito do artefato proposto.

QUADRO 4 – ATIVIDADES DO DESENVOLVIMENTO DO ARTEFATO

ARQUITETURA DO MODELO DE COMUNICAÇÃO IIOT e DATA SCIENCE					
I. Camada de recursos Físicos ( <i>Physical Resource Layer</i> )		II. Camada de Comunicação de rede ( <i>Network Layer</i> )		III. Camada de Aplicação/armazenamento de dados ( <i>Data Application Layer</i> )	IV. Camada de Visualização/Interface ( <i>Terminal Layer</i> )
<b>ATIVIDADES DE DESENVOLVIMENTO</b>	1) Mapeamento dos Ativos envolvidos na Pesquisa - <b>Nível de Conectividade</b>	Estruturação da comunicação IIOT e <i>Data Analytics</i>			
	2) Seleção do(s) ativo (s) - <b>Matriz de Criticidade</b>	4) Definição do protocolo de comunicação com os ativos - <b>OPC-UA</b>	6) Sistema Analítico de comunicação IIoT e tratamento de dados: <b>Estrutura IIoT e Data Science.</b>	8) Modelo hierárquico de responsabilidade - <b>Nível Processo - Operador</b>	
	3) Avaliação dos Parâmetros de influência no Processo - <b>Método Taguchi</b>	5) Definição do modelo de rede de comunicação a ser utilizada - <b>Rede Industrial</b> . Local de comunicação e Posteriormente Nuvem	7) Armazenamento e Acesso as dados: <b>Por camada de programação</b>	9) Visualização dos Painéis digitais - <b>Dashboard POWER BI e QuikSENSE</b>	

Fonte: Adaptado de Che *et al.* (2018) e Kusiak (2018)

O artefato para ser implementado, avaliado e replicado deve ser descrito com maior número de detalhes. Para tanto foi elaborado uma prescrição para o uso das ferramentas recomendadas, a serem utilizadas em cada atividade proposta no artefato, descrita a seguir:

### 1) Mapeamento dos Ativos – Nível de Conectividade

O setor de usinagem da empresa pesquisada é composto por diversos equipamentos. Cada um assume diferente grau de importância no processo, por conseguinte, definir os equipamentos de estudo é de suma importância para atingir uma metodologia certa, que possa ser replicada posteriormente sem grandes impactos na produtividade.


Para um mapeamento dos ativos são avaliados. A saber:



- Quantidade de equipamentos instalados;
- Nível ou circunstância da conectividade (número de máquinas conectadas na rede, tipo de disponibilidade de conexão, se possui alguma restrição de hardware ou software e a disponibilidade de armazenagem de dados físico ou virtual);
- Equipamentos considerados obsoletos para conectividades (aqueles que não possuem nenhum tipo de sensoriamento, conexão ou forma viável de adaptação);
- Equipamentos que necessitem de atualização de hardware e/ou softwares.

Com base nessas acepções, uma avaliação do estado de conectividade faz se necessário, o apoio de especialistas em automação e/ou empresas de tecnologia é recomendado para uma avaliação especializada. Os itens sugeridos para serem avaliados são apresentados no modelo descrito na FIGURA 12, onde é elencada a classificação do nível de conectividade de cada equipamento, tomando em consideração sua comunicação, capacidade de transferência de dados e armazenamento de informações.

FIGURA 12 – ITENS PROPOSTOS PARA AVALIAÇÃO DE CONECTIVIDADE



Fonte: Autor (2021)

O mapeamento de conectividade demonstra o estado atual dos equipamentos e direciona a seleção, além de ser uma fonte de informação para o planejamento de

investimentos, intervenções de manutenções e gestão tecnológicas dos equipamentos.

## 2) Seleção dos ativos - Matriz de Criticidade

Não menos importante, outro ponto que pode impactar na definição dos equipamentos, além de seu estado físico, é os critérios técnicos e a metodologia de melhoria contínua.

Para facilitar a seleção dos equipamentos, o uso de uma Matriz de Criticidade é viável evitando análises subjetivas e descentralização das informações. Assim, pode-se comparar e analisar o impacto da escolha dos equipamentos, além da possibilidade de replicar em outras unidades fabris.

Para análise da criticidade foram seis parâmetros influenciadores na seleção dos equipamentos proposto no artefato. São eles:

1. Custos de implementação;
2. Tempo de implementação;
3. Recursos técnicos necessários;
4. Resultados dos testes;
5. Replicar nos demais equipamentos;
6. Aplicar algum tipo de metodologia para melhoria contínua.

A matriz teve como base, cinco níveis de criticidade, sendo que cada nível tem um valor numérico correspondente. O valor máximo é igual a 5 e o mínimo a 1, conforme a TABELA 4.

TABELA 4 – VALORES NUMÉRICOS DAS CLASSIFICAÇÕES DA CRITICIDADE

<b>CRITICIDADE</b>	<b>VALOR</b>
Máxima	<b>5</b>
Alta	<b>4</b>
Média	<b>3</b>
Mínima	<b>2</b>
Nenhuma	<b>1</b>

Fonte: Autor (2021)

Tem-se como objetivo desta classificação a possibilidade de agrupar as várias classificações, de cada parâmetro de criticidade. Além disso, atribuir um valor (peso), através de avaliação conjunta das mais variadas áreas, tais como, as áreas de manutenção, qualidade, processos e produção, conforme TABELA 5.

Os valores de cada parâmetro, multiplicados pelos seu respectivos pesos, serão utilizados para calcular o valor da criticidade. Posteriormente deve-se fazer a seleção dos equipamentos direcionados para o estudo.

Com a matriz de criticidade concretizada verifica-se o impacto, bem como a resposta à implementação das tecnologias de cada equipamento.

TABELA 5 – PARÂMETROS, PESOS E FAIXAS DE CRITICIDADE

Parâmetros	Criticidade					Peso
	Máxima	Alta	Média	Mínima	Nenhuma	
<b>Interferência na Produtividade</b>	Parada em Produção $\geq 10$ min.	Parada em Produção $< 10$ min.	Parada Progr. Horário Produtivo	Parada Progr. Horário Não-Produtivo	Não Interfere	<b>5</b>
<b>Custo da implementação</b>	$\geq 10\%$ equip. (Capital e Expenses)	$< 10\%$ equip. (Capital e Expenses)	somente Expenses (treinamento, especialistas)	Mínimo Custo $< U\$500$	Sem Custo mensuráveis	<b>4</b>
<b>Tempo de implementação</b>	$\geq 30$ dias	$< 30$ dias	1 semana	2 dias	$< 2$ dias	<b>3</b>
<b>Tempo de respostas dos testes (previstos)</b>	$\geq 30$ dias	$< 30$ dias	1 semana	2 dias	$< 2$ dias	<b>2</b>
<b>Recursos Técnicos</b>	Especializado com Apoio de Terceiros	Especializado com Técnico Interno	Média complexidade técnica	Baixa complexidade Técnica	Sem necessidades	<b>1</b>
<b>Replicar nos demais equipamentos</b>	Muito difícil, refazer toda metodologia	Refazer parte da metodologia	Moderado necessidade	Possível de replicar	Nenhuma Restrição	<b>1</b>
<b>Melhoria</b>	Não ajuda a resolução dos Problemas	Ajuda com algum projeto de melhoria continua	Faz parte da Matrix de resolução de Problemas	Top 10 da Matrix de resolução de problemas	Prioridade na Matrix de resolução de problemas	<b>5</b>
<b>Valor de Atribuído</b>	<b>5</b>	<b>4</b>	<b>3</b>	<b>2</b>	<b>1</b>	

Fonte: Autor (2021)

### 3) Avaliação dos Parâmetros de influência no processo - Método Taguchi

O OEE monitorado em tempo real é extremamente importante para uma reação rápida e proporcionar diagnósticos automáticos da situação on-line (imediate).contudo o sistema de usinagem é composto por vários fatores que influenciam nas métricas dos OEE. O Método Taguchi é uma abordagem que visa

conhecer os fatores que influenciam no processo, através de uma abordagem estatística de número de fatores e níveis, que são utilizados para estudar os efeitos dos parâmetros envolvidos. (BALONI, PATHAK e CHANNIWALA, 2015). Por este motivo foi proposto o Taguchi para avaliar os efeitos dos parâmetros na qualidade do produto, e a influência dos fatores no indicador OEE.

#### 4) Definição do protocolo de comunicação - OPC-UA

Para desenvolver um método de análise sistemática de dados, ou melhor descrevendo, uma metodologia de engenharia de dados que incluem algoritmos e aplicativos de aquisição de dados. Assim, optou-se em utilizar o protocolo de comunicação OPC-UA<sup>1</sup>, por ser uma comunicação mais amigável e independente, o que garante o fluxo de informação contínuo entre os dispositivos industriais de diversos fornecedores. Esta linguagem proporciona uma maior interação, visto que nos ambientes industriais existem variados dispositivos e equipamentos, e o protocolo de comunicação OPC-UA possibilita uma integração maior de comunicação.

#### 5) Definição do modelo de rede de comunicação a ser utilizada – Rede Industrial Local

Após a etapa de conscientização e sugestão onde foram levantadas, várias alternativas de comunicação e armazenamento, a rede de servidores remotos hospedados na *Internet Cloud Computing* (sistema em Nuvem) seria uma solução viável e de melhor operacionalidade. Sendo que para armazenar, gerenciar e processar dados de um modelo de teste ou seja o estudo piloto, um servidor local ou uma arquitetura de comunicação e de armazenamento, como *on premise* (Rede Local), é recomendado. Principalmente pela modelagem e a escassez de dados, além da necessidade de sigilo dos parâmetros manuseados ser responsabilidade e gestão dos pesquisadores.

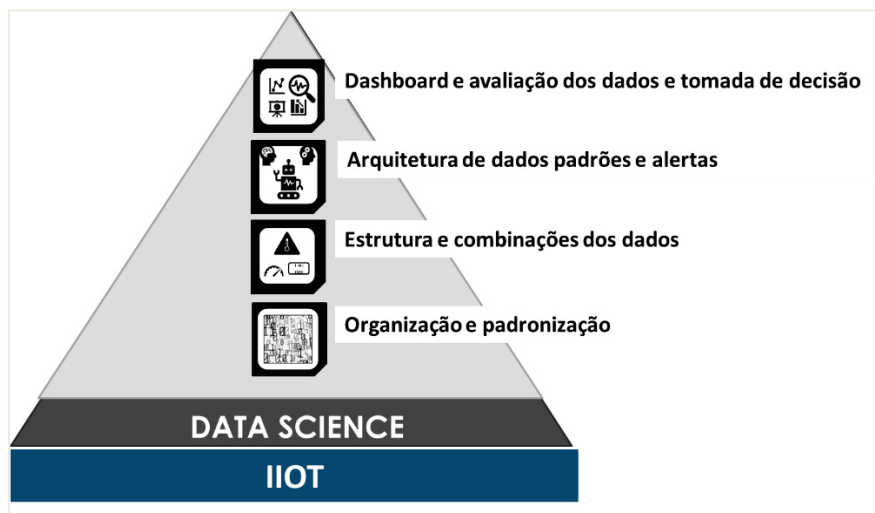
---

<sup>1</sup> OPC-UA : *Open Platform Communications - Unified Architecture* “Um padrão de interoperabilidade para a troca de dados segura e confiável no espaço de automação industrial e em outras indústrias. <https://opcfoundation.org/about/opc-technologies/opc-ua/>

## 6) Sistema Analítico de comunicação IIoT e tratamento dos dados - Estrutura IIoT e *Data Science*

A estrutura de comunicação de dados segue um modelo de pirâmide, FIGURA 13. Na base fica a estrutura IIoT, que representa o sistemas de comunicação com os ativos (equipamentos), que corresponde pelas camadas de recursos físicos, comunicação de rede e aplicação/armazenamento dos dados.

FIGURA 13 – ESTRUTURA DO SISTEMA DE ANÁLISE DE DADOS



Fonte: Autor (2021)

Como observado na pirâmide temos a estrutura de *Data Science* que corresponde pela camada de visualização/Interface da análise dos dados, dividida em 4 níveis, são eles:

**Organização e Padronização:** A conectividade entre diversos dispositivos necessita de uma organização e padronização. Muitas vezes a linguagem utilizada pelas máquinas são de um formato que codifica os dados serializados, em uma “*array de bytes*” - Binário. Este método é o mais utilizado pelos fornecedores de máquinas, por reduzir o custo computacional em termos de codificação e decodificação. Como só podem ser interpretadas por clientes compatíveis é muito utilizada pelos fabricantes. Para tanto a sugestão foi definir os códigos de máquinas e classificá-los de acordo os dados além de relaciona-los com outros eventos, tasi como, o modo Auto, modo *Stand By*, Modo Parada, porta fechada, porta aberta, alertas, ciclo por

segundo, frequência (Hz). Realizar esta clusterização dos dados e correlacioná-los de acordo com cada evento é um facilitador da análise dos dados e otimização dos algoritmos de classificação dos dados gerados pelos equipamentos.

**Estrutura e Combinações dos dados:** Tendo os dados clusterizados ou padronizados, agora de forma organizada, deve-se estruturar o modelo de combinação dos dados. Isso se resume na transformação dos dados brutos em informação estruturada para modelagem dos pacotes de dados, definição da amostragem, tempo de processamento, categorização dos eventos por indicadores. Serão esses construídos através dos algoritmos de geração dos indicadores, que compõem o OEE e outros indicadores perceptíveis no decorrer do estudo.

**Arquitetura de dados, Padrões e Alertas:** com as combinações e estrutura de dados, pode ser definido os algoritmos de modelagem de dados e os software de comunicação. Além de como será a estrutura dos dados para entrega, tipo de formatação que os dados deverão sofrer.

Ordenar os dados por evento, espaço-tempo e discriminá-los através da origem, tipo de máquina e tipo de sensor e outros parâmetros que possam identificar a origem dos dados e definir seu destino.

**Dashboard, avaliação dos dados e tomada de decisão:** A combinação dos dados e eventos, necessitam de uma forma amigável e de fácil visualização e navegação. Neste sentido, os *dashboard* ou sistema visual de painéis, resumem a real e atual situação do equipamento, sendo composto por gráficos, tabelas e indicadores. Sendo responsáveis por identificar possíveis anomalias e gerar os alertas necessários baseado na sua criticidade.

## 7) Armazenamento e acesso a dados – por camada de programação

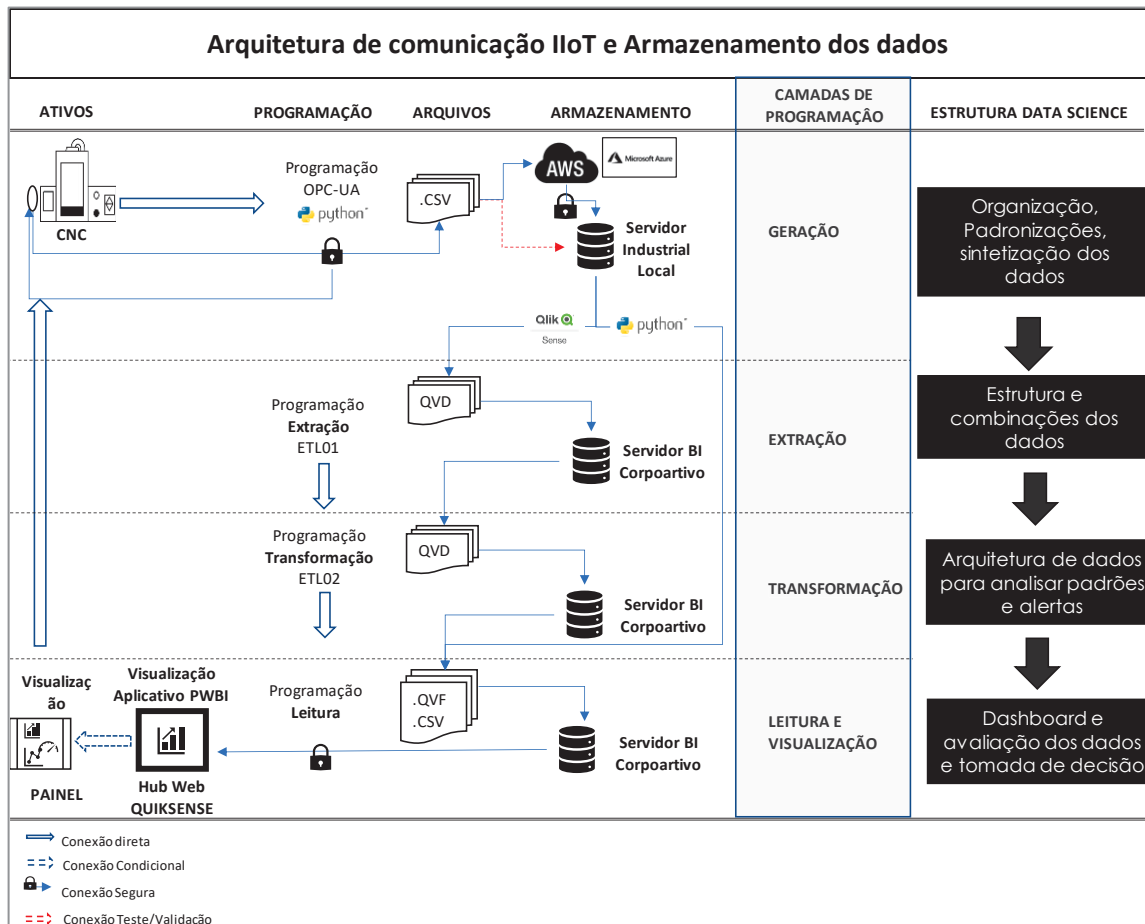
Uma arquitetura de tratamento e armazenamento de dados por camadas de programação como apresentado na FIGURA 14 tem como objetivo dividir os níveis da estrutura de *data science* de forma a se otimizar os recursos de armazenamento, bem como os acessos aos dados com segurança evitando perdas e/ou acessos indevidos.

As camadas de programação são fundamentais para definir o tipo de programação e o grau de complexidade que o sistema será submetido, são elas:

**Geração:** Na primeira, tem-se os dados gerados pelos equipamentos, por meio de seus sensores, processados pelo PLC do equipamento ou outro sistema de interface. A extração dos dados é feita por meio de programação via *script* de programação para a extração de dados, gerando os arquivos do tipo CSV (Valores Separados por Vírgula). Esses são armazenados em servidor industrial local, ou plataformas de serviço de nuvem, como por exemplo, AZURE ou AWS.

Muitas vezes a conexão e extração são diretamente realizada pelos *scripts* de programação realizados diretamente no PLC dos equipamentos, através de protocolos OPC-UA ou com apoio de software de programação como *Python*.

FIGURA 14 – ARQUITETURA DE COMUNICAÇÃO IIOT E ARMAZENAMENTO DOS DADOS



Fonte: Autor (2022)

**Extração:** A camada de extração tem como o único propósito, carregar dados brutos gerados nos arquivos CVS e armazenar em servidor distinto, devidamente catalogado. Nessa camada de programação não se recomenda nenhum tipo de

transformação, nem mesmo a simples renomeação de campos/colunas gerados pelo script de conexão. A camada de extração fornece uma duplicata das tabelas do banco de dados, que se pode carregar quantas vezes for necessário nos aplicativos subsequentes, sem a necessidade de voltar ao banco de dados original ou fazer novo acesso ao equipamento para extração do dado gravado, mantendo assim a segurança e integridade do sistema de conexão. Essa lógica de extração incremental e armazenamento em servidores distintos, torna a camada de extração ainda mais eficiente, limita a extração do banco de dados apenas aos registros mais recentes, gerando os arquivos do tipo “QVD”, arquivos de uso do software “Qlik Sense”, outra opção é a extração por meio de programação com software “Python” durante o estudo ambos estavam disponíveis.

**Transformação:** Com os arquivos já extraídos e devidamente armazenados, segue com a transformação dos dados. A camada de transformação é uma maneira de preparar os dados através das técnicas de *Data Analytics* e *Data Mining*, aplicar métodos estatísticos para geração dos algoritmos de estruturação. Nessa camada, outras fontes são adicionadas, fontes externas que ajudam na arquitetura de padronização a dos dados. Essa programação é decisiva para identificar a granularidade dos dados contidos nas linhas dos arquivos ou tabelas de consulta, para gerar o nível de acesso e para as futuras visualizações bem como aumentar o nível de detalhe ao gerar as referências e alertas.

Alem disso, a camada transformação dos dados é o momento que todas as tabelas transformadas são disponibilizadas para uso dos softwares de visualização de dados, os painéis digitais (*dashboard*). A principal vantagem da camada de transformação é desenvolver um conjunto de lógicas e aplicar comumente sem a necessidade de repetir as programações.

**Visualização:** Observar os dados em formato de painéis é um dos objetivo desse artefato. A criação dos painéis de interface com os usuários são desenhados, com gráficos, tabelas e indicadores que, combinados entre si, são usados para provocar respostas mais rápidas e fortalecer as comparações e como consequencia favorecer a tomada de decisões.

Nesta camada, os painéis são apresentados em leiaute personalizados para cada nível de responsabilidade, no artefato o foco foi direcionado no operador do CNC, tornando os *Dashboard* mais didáticos e de fácil entendimento.

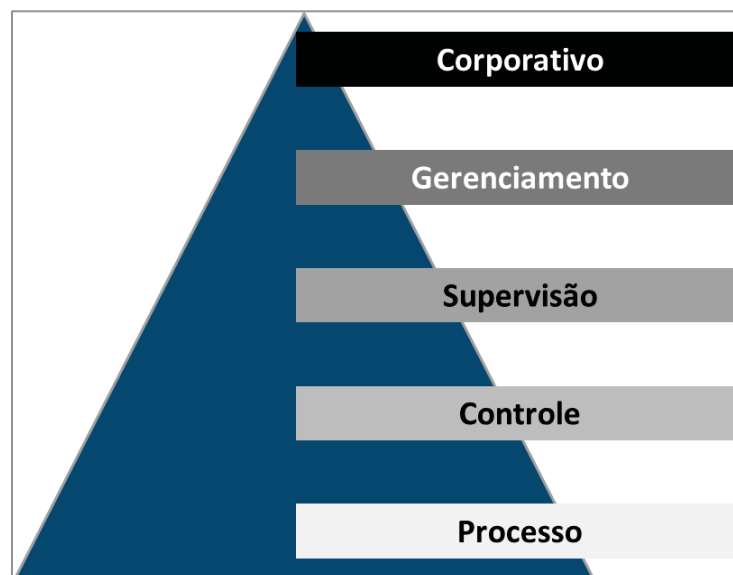


### 8) Modelo Hierárquico de Responsabilidade - Nível Processo , Operador

Respeitar e definir um modelo hierárquico é necessário, para avaliar, tomar decisões e gerar ações. Moraes e Castrucci (2017) apresentam um modelo baseado na pirâmide da automação (FIGURA 15), que possibilita classificar as informações de acordo com o nível hierárquico de responsabilidade.

As informações geradas devem ter acesso direto, de acordo com o nível da organização, deve fluir do processo (operador) ao corporativo (direção) de forma rápida e vertical. Isso torna o sistema ágil e eficiente para a tomada de decisões, sendo levado ao topo da pirâmide, somente as informações que realmente façam com que a decisão possa ser tomada, deixando as demais camadas regir suas próprias decisões.

FIGURA 15 – PIRÂMIDE DE RESPONSABILIDADES



Fonte: Adaptado de Moraes e Castrucci (2017)

Um sistema de tomada de decisão por nível de responsabilidade, quando estabelecido, contribui para priorizar e planejar quais dados serão transformados e apresentados seja em tempo real, ou com periodicidade pré-definidos. Isso garante uma programação orientada aos dados, de acordo com a necessidade da organização.

Para o estudo do artefato, o processo (operador) foi focado, para atingir o público que opera a máquina, que interage com os parâmetros, e tem papel essencial na operação, o qual dificilmente deverá ser substituído por um sistema completamente computadorizado.

### 9) Visualização dos painéis digitais - *Dashboard*

Dados em tempo real são muito importantes para tomada de decisão. Porém para ter uma eficiência no resultado de visualização, são necessários definir os valores de referência para cada indicador (gráfico, tabela, valor indicativo) que será apresentado nos painéis digitais (*dashboard*).

Como os processos são em maioria heterogêneos, tendo o envolvimento humano e máquina, as informações devem ser apresentadas de forma a trazer informações, que possam auxiliar o responsável pela tomada de decisão. Como visto anteriormente na definição da responsabilidade, os painéis devem trazer seus indicadores ligados a responsabilidade de cada visualizador, traduzindo as informações necessárias para um contexto visual simples, tornando o entendimento mais fácil, resultando na identificação de padrões, tendências e informações fora dos padrões (*outliers*).

Conforme cita Knalich (2019), isso pode parecer não muito intuitivo, mas o sucesso na visualização de dados não começa com a visualização de dados. Em vez disso, antes de começar a criar uma visualização ou comunicação de dados, atenção e tempo devem ser dedicados à compreensão do contexto da necessidade de comunicação.

Diversos softwares dispõem destes recursos de *Data Visualization* como Quilk Sense, Power BI, Tableau, Sas *Visual analytics*, entre outros. A seleção do *software* está em função da disponibilidade e recursos previsto de cada organização. Este estudo não está avaliando os softwares ou ferramentas, mas, classificando os painéis com o objetivo de definir os indicadores e segmentá-los ou os agrupando de acordo com o nível de importância para os diferentes objetivos estratégicos, analíticos e operacionais.

Esses materiais serão direcionados ao público que receberá a apresentação e de acordo com suas responsabilidades. Diretores, gerentes e executivos de nível

mais corporativo e gerencial, normalmente são direcionados aos painéis com objetivo estratégico, uma vez que apresentam uma visualização dos dados com uma granularidade mais baixa. Isso traz, em geral, indicadores com informações estratégicas de longo prazo e com uma necessidade de atualização periódica, as vezes mensal ou trimestral.

Já os indicadores de intuito analítico, geralmente, tem como público os coordenadores e analistas, profissionais ligados à supervisão e controle com nível de granularidade médio, com detalhamento nos dados para realização das análises mais profundas, que requerem comparações mais ricas. Essas, muitas vezes, segmentadas e mais detalhadas, com históricos mais extensos para formatação de análises que requerem uma visão mais analíticas e suportada por técnicas de investigação.

Como citado anteriormente, nessa pesquisa o artefato foi concentrado na base da pirâmide, o operador, visto que com o objetivo de melhorar a performance do processo de usinagem, esta seria o segmento primário para ser desenvolvido e sugerido os painéis digitais. Nesse segmento operacional, os painéis devem trazer informações que possam ser avaliadas em tempo real ou o mais imediato, trazendo informações complementares ao indicador primário como o OEE. Além disso, encontrar indicadores que possam ser úteis na tomada de decisão que afetem as métricas dos indicadores primários, como a disponibilidade, performance ou qualidade, O artefato foi composto de 2 indicadores que contribuem para uma tomada de decisão além dos dados de OEE.

Indicador de desvio do tempo determinado versus o realizado: esse indicador tem como objetivo, demonstrar o comparativo entre o tempo previsto e o tempo realizado, indicando ao operário o quanto o processo desvia do tempo determinado. Este tipo de apontamento ajuda o operário a entender o comportamento e demonstrar tendências, que podem ser corrigidas ou mantidas como bons exemplos.

Indicador de alteração dos parâmetros de utilização da máquina: relaciona-se aos parâmetros de performance do equipamento, como velocidade (RPM). Quando, em condições normais de programação, os parâmetros ideais são definidos como 100%, o indicador deve demonstrar o percentual utilizado pelo operador em cada ciclo. Este indicador suporta o operário no entendimento das variações de velocidade, influenciador do indicador primário OEE, e em combinação com o indicador de desvio

de tempo colabora para que o operador do equipamento possa tomar uma decisão de melhoria na performance.

#### 4.4 AVALIAÇÃO

Nesta etapa o artefato foi avaliado no que tange a sua aplicação, conforme as nove atividades propostas na etapa de desenvolvimento. Para cada atividade verificou-se a relevância e a aplicação em cenário real de manufatura.


Todas as atividades foram avaliadas em conjunto com a equipe especializada, envolvendo profissionais de manutenção, produção, qualidade e engenharia de produto. Outro aspecto analisado foi a aderência e viabilidade de implementação, onde todos os ajustes realizados foram devidamente avaliados.

##### 4.4.1 Acuracidade como fonte de avaliação

A acuracidade das informações projetadas nos *dashboards*, foi outro aspecto considerado na validação, indispensável no que tange à precisão dos dados que formatam o OEE dos equipamentos.

Teoricamente, o valor verdadeiro de uma grandeza é um conceito abstrato. Na prática, no entanto, pode-se dispor de uma grandeza (padrão) com qualidade superior a outra, podendo-se considerá-la como de referência. Conforme Monico *et al.* (2009) e como demonstrado na FIGURA 16, a acurácia é tomada como sendo o afastamento entre o valor de referência e o valor estimado. A sua precisão é a dispersão dos valores estimados.

FIGURA 16 – ACURÁCIA E PRECISÃO



Fonte: Monico *et al.*, 2009

A forma de avaliar a acurácia nessa pesquisa é dada conforme :

$$Acurácia = \frac{nErro}{nTeste} * 100 \quad (5)$$

Onde,  $nTeste$  é igual ao número de testes realizados, e  $nErro$  dado como:

$$nErro = \sum Ac \quad (6)$$

Sendo ,  $Ac$  igual a 1 se  $\hat{p} \leq \alpha < \hat{p}'$  e 0 caso contrário. Quando  $Ac$  estiver dentro do intervalo de  $\hat{p}'$  e  $\hat{p}$  pode-se considerar como valor Acurado. Nesta pesquisa foi adotado um valor para  $\hat{p}' = -5\%$  e  $\hat{p} = +5\%$ ,

Onde  $\alpha$  se calcula com:

$$\alpha = \frac{VR}{VO} * 100 \quad (7)$$

Onde,  $VR$  = Valor de referência e  $VO$  = Valor Obtido

A acurácia medida nesta pesquisa foi definida por meio de comparativo. Esse realizado entre medição calculada manualmente e o sistema de medição proposto no

artefato. Ambas as medições são comparadas com os valores de referência (padrão), cujo qual é realizado com todo rigor e padrão para gerar um valor de confiança para efeito de comparação.

#### 4.5 CONCLUSÃO DO DSR

A conclusão é a última etapa do ciclo da pesquisa, em que o artefato é apresentado e finalizado o DSR. Nesta fase não só é formalizado o artefato, mas também apresentado os resultados. Os esforços em aumentar o conhecimento e disponibilizar informações e literatura sobre o tema, proporciona um artefato que possa ser aplicado repetidamente e aperfeiçoado a cada aplicação, no próximo capítulo os resultados são apresentados como parte de conclusão e validação do DSR.

### 5 RESULTADOS E DISCUSSÕES

Neste capítulo é apresentado os resultados da aplicação da metodologia e discussões sobre o artefato e sua validação como um DSR, disponibiliza-se, também os resultados que comprovam que o método apresentado dispõe de uma acurácia significativa, quando comparado com um sistema conhecido, que nessa pesquisa é o processo manual de coleta, cálculo e apresentação do indicador OEE, atualmente utilizado na empresa onde o estudo foi desenvolvido.

Além da melhoria da confiabilidade dos dados apresentados, também é possível concluir que os resultados da aplicação do DSR e as atividades listadas e descritas no capítulo 4.2, trazem um entendimento claro de que compartilhar o conhecimento, gera ganhos significativos no processo de coleta, armazenamento e publicação dos dados gerados pelos equipamentos. Pressupondo, assim, uma discussão ampla sobre a dificuldade de implementar um sistema de gestão de dados eficientes sem o conhecimento e implementação de um artefato estruturado e cientificamente orientado.

#### 5.1 RESULTADOS DAS ATIVIDADES DE DESENVOLVIMENTO

Como parte do desenvolvimento e avaliação do artefato, todas as etapas da pesquisa buscou contribuições claras e verificáveis, seguindo o rigor de uma pesquisa fundamentada em *Design Science*. Para cada atividade realizada no artefato, foi realizada uma avaliação rigorosa e analisados os resultados de forma a buscar um artefato eficaz.

A atividade de mapeamento dos equipamentos, na empresa foco desse estudo, traz uma resposta esclarecedora sobre a situação física dos ativos no seu estado atual de conectividade e comunicação de dados. Desta maneira, foi implementado uma forma visual e descritiva, que ajuda tanto o pesquisador quanto os gestores a examinar, com mais clareza, a real situação de conectividade dos equipamentos. Exemplo desse mapeamento é observado na FIGURA 17, que busca de forma visual mostrar o estado de conectividade dos CNC disponíveis para o estudo de caso, que contou com 23 máquinas CNC.

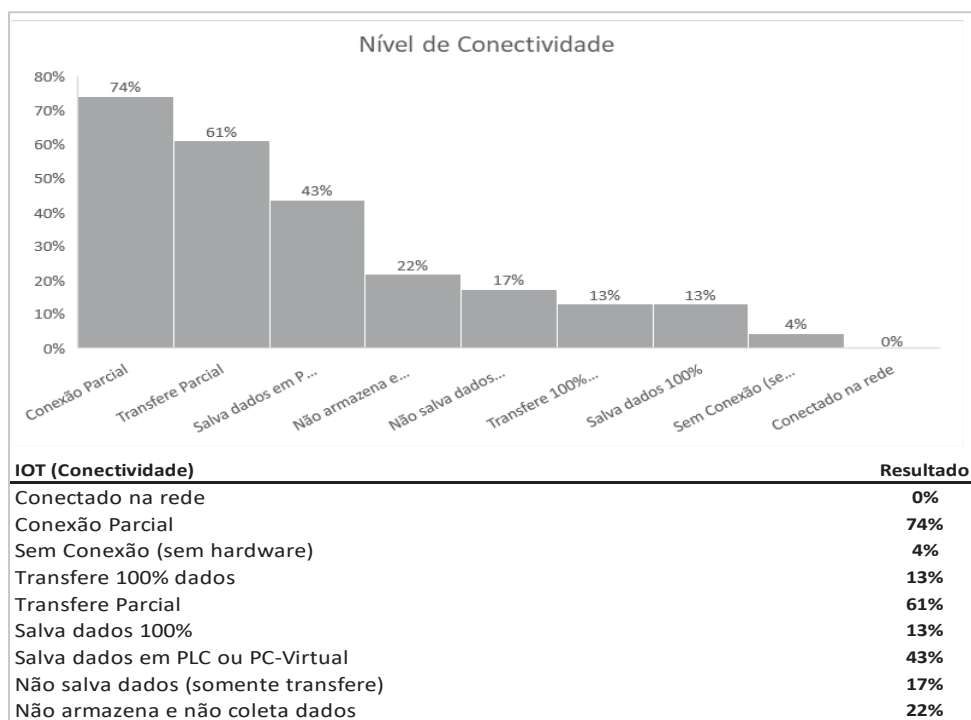
FIGURA 17 – RESULTADO DO MAPEAMENTO DOS ATIVOS

n. Equipamento		IOT (Conectividade)								
		● Conectadas na rede	● Conexão Parcial	○ Sem Conexão (sem hardware)	▲ Transfere 100% dados	▲ Transfere Parcial	■ Salva dados 100%	■ Salva Dados em PLC ou PC-Virtual	■ Não salva dados somente transfere	■ Não armazena e não coleta dados
1	CNC	x			x		x			
2	CNC								x	
3	CNC			x						
4	CNC	x				x		x		
5	CNC	x				x		x		
6	CNC	x				x		x		
7	CNC	x				x		x		
8	CNC	x		x		x	x			
9	CNC	x				x		x		
10	CNC	x				x			x	
11	CNC	x				x			x	
12	CNC	x				x			x	
13	CNC	x				x			x	
14	CNC	x				x		x		
15	CNC	x				x		x		
16	CNC	x			x		x			
17	CNC								x	
18	CNC								x	
19	CNC								x	
20	CNC	x				x		x		
21	CNC	x				x		x		
22	CNC								x	
23	CNC	x				x		x		
Número de equipamentos		0	17	1	3	14	3	10	4	5
CNC		0%	74%	4%	13%	61%	13%	43%	17%	22%

Fonte: Autor (2022)

O mapeamento de conectividade, como uma atividade proposta no artefato direciona as ações de manutenção e melhorias, conforme o estado atual dos equipamentos. Na FIGURA 18, pode-se observar que 74% dos equipamentos avaliados, possuem algum tipo de conexão. Todavia, sugere-se análises de viabilidade mais detalhada de cada equipamento por equipe especializada. Outra informação evidenciada é de que não existe equipamento conectado à rede de dados.

FIGURA 18 – RESULTADO MAPEAMENTO DE CONECTIVIDADE



Fonte: Autor (2022)

A mensuração do impacto da intervenção no processo é outro aspecto importante na aplicação do artefato. Através do resultado da matriz de criticidade, apresentado na TABELA 6, verifica-se quais equipamentos exercem um impacto de maior ou menor influência no processo produtivo. Possibilitando a seleção dos equipamentos que devem ser alvos de estudo e aplicação das atividades seguintes.

Com os resultados plotados em uma tabela de criticidade, pode-se avaliar quais equipamentos são de extrema complexidade. Levando em consideração a sua intervenção, o custo de implementação, os tempos de implementação e outras características que torna o alvo de implementação do artefato mais assertivo.



TABELA 6 – RESULTADOS DA TABELA DE CRITICIDADE

Criticidade somente CNC	PESOS						
	5	4	3	2	1	1	5
	Interferência na Produtivi- dade	Custo da implemen- tação	Tempo de implemen- tação	Tempo de respostas dos testes	Recursos Técnicos	Replicar nos demais equipamen- tos	Melhorias do Processo
<b>Máxima</b>	13%	26%	0%	0%	0%	0%	17%
<b>Alta</b>	17%	4%	22%	0%	13%	9%	52%
<b>Média</b>	61%	61%	65%	57%	48%	83%	26%
<b>Mínima</b>	4%	9%	13%	43%	39%	9%	4%
<b>Nenhuma</b>	4%	0%	0%	0%	0%	0%	0%
	<b>100%</b>	<b>100%</b>	<b>100%</b>	<b>100%</b>	<b>100%</b>	<b>100%</b>	<b>100%</b>

Fonte: Autor (2022)

Para a avaliação e o conhecimento dos parâmetros que influenciam no OEE e na produtividade, o método Taguchi trouxe resultados que podem ser observados com melhor detalhe no ANEXO 1. Nele, em resumo, demonstra que o tipo de inserto e o material usado na usinagem sofrem a maior variação e alteram a qualidade e performance do equipamento. Dessa forma, apresenta substanciais informações do processo, com inúmeras combinações, que devido a análise de Taguchi, podem ter identificados os fatores, que influenciam o processo e foram incluídos no monitoramento e apresentados para os operadores nos *dashboards* desenvolvidos.

Considerando as atividades 4 a 8, estas exigiram diversas discussões e suportes especializados para implementação, dado a complexidade de conexão com os equipamentos, tratamento e disponibilidade dos dados conforme desenhado na etapa de desenvolvimento. Dificuldade, essa que foi superada com a busca especializada, como empresas de integração de sistemas, cientistas de dados e desenvolvedores de painéis digitais. Por sua vez a arquitetura descrita na FIGURA 14, que orienta as atividades de conexão e disponibilidade de dados e mede a efetividade do *dashboard*, só foi possível com a participação do operador, condutor de processo, inspetor de qualidade.

O painel digital proposto no artefato, desenvolvido em plataforma “Microsoft Power BI”, resume as informações de relevância na tomada de decisão do operário, o leiaute proposto e construído com foco na visão do operário. Informações resumidas e de maior relevância, concentradas em uma única página, tela (FIGURA 19).

FIGURA 19 – MODELO DO PAINEL DIGITAL DESENVOLVIDO PARA VISÃO DO OPERADOR



Fonte: Autor com base no *Dashboard* desenvolvido no artefato (2022)

Também com o foco de tomada de decisão foi possível introduzir um indicador de erros absolutos e relativos, que auxiliam o operário na avaliação de tendência dos processos, ficando a cargo do próprio operário a decisão de intervir ou não no processo com base aos resultados apresentados no *dashboard*.

### 5.1.1 *Dashboard* e suas funcionalidades

O painel de visualização teve sua construção desenvolvida, de acordo com as funcionalidades necessárias para o processo decisório, ligado ao operário e a tela foi dividida conforme apresentado na FIGURA 20.

FIGURA 20 – DASHBOARD E FUNCIONALIDADES



Fonte: Autor com base no *dashboard* desenvolvido (2022)

O *dashboard* foi apresentado como:

- ( 1 ) Data de visualização do *dashboard* de acordo com os dados disponíveis no banco de dados, pode ser selecionado em menu de calendário.
- ( 2 ) Valores que compõe o OEE, disponibilidade, performance e qualidade, calculados com base na data selecionada em (1).
- ( 3 ) OEE em formato de indicador “relógio”, considerando os valores indicativos de ruim representada pela cor vermelha, admissível (cor vermelha) e bom representada pela cor verde. Esse indicativo é fornecido pela empresa em que os valores 0% a 75% é considerado um valor ruim, maior que 75% a 85% considerado um valor admissível e maior que 85% até 100% se considerada um valor de classe mundial. O ponteiro demonstra o valor obtido do OEE (disponibilidade x performance x qualidade) com referência a data selecionada em ( 1 ).
- ( 4 ) Produtividade calculada com base na data selecionada em (1). O Valor de Produtividade considera o teórico possível de ser produzido, em relação ao produzido. Este valor é apresentado em percentual (%) e com indicador “relógio”, apresentando os valores indicativos em vermelho, amarelo e verde (ruim, admissível e bom), com 0 a 50% considerado Ruim, maior que 50% a 75% admissível e maior de 75% a 100% considerado bom para produtividade.

- ( 5 ) Indicador de Produtividade que apresenta em números absolutos a quantidade o valor obtido da produtividade, produção teórica e produção real, em unidades com referência a data selecionada em (1).
- ( 6 ) Indicador de custo da produtividade, para cada tipo de peça usinada, ou programa utilizado, este indicador compara o tempo teórico disponível para um determinado programa selecionado, com o tempo real realizado, pela operação a diferença é multiplicada pelo fator de custo por hora.
- ( 7 ) Indicador de Status de qualidade, quantidade de peças boas e peças ruins realizadas com referência a data selecionada em (1).
- ( 8 ) Indicadores de OEE desdobrado por tipo de peça, ou programa com referência a data selecionada em (1).
- ( 9 ) Histórico dos resultados do indicador OEE, com referência a data selecionada em (1).
- ( 10 ) Indicadores de OEE detalhado pelos dados da última peça, ou programa realizado.
- ( 11 ) Indicadores de produtividade detalhado pelos dados da última peça, ou programa realizado.
- ( 12 ) Gráfico com as perdas relacionadas aos seis tipos de perda, conforme descrito na TABELA 3.
- ( 13 ) Gráfico do erro absoluto da diferença entre o tempo previsto, versos o tempo realizado.
- ( 14 ) Gráfico do percentual de alteração dos parâmetros de performance do equipamento.

Os itens 12, 13, 14 são indicadores que complementam o processo de tomada de decisão. Ou seja, os que representam o comportamento do processo e as causas de paradas.

O painel sugerido tem como resultado auxiliar na tomada de decisão que afeta o processo em tempo real, e visa trazer uma visão adequada do processo, reduzindo o tempo de reação e resolução de problemas, além de desburocratizar a decisão, levando o operário a identificar possíveis desvios de acordo com o resultado obtido do processo.

## 5.2 RESULTADO DA ACURACIDADE DO ARTEFATO

Como descrito na última etapa do DSR, avaliação, a acurácia foi uma forma de validar o modelo proposto no artefato e comparar com o modelo atualmente utilizado pela empresa. Foram colhidas, no turno da manhã em período produtivo, 13 observações para efeito comparativo. Os testes foram realizados em períodos controlados e supervisionados pela equipe do projeto, onde todos os dados registrados para efeito de mensurar a acuracidade do processo manual e pelo sistema proposto.

### 5.2.1 Resultado da acuracidade do índice de disponibilidade

Na TABELA 7 os resultados do tempo de início, final e paradas foram registrados. Conforme item 2.2.7 deste trabalho, o percentual de disponibilidade do equipamento foi calculado, onde os resultados foram registrados como valores de referência. Resultados esses, apresentados aqui com objetivo de mensurar a acuracidade em disponibilidade, um dos três índices que compõe o OEE.

TABELA 7 – VALORES DE REFERÊNCIA

Testes realizados		VALORES DE REFERÊNCIA					
nTeste	data	Início	Final	Paradas Hrs (Pr)	Total Hrs (Th)	Hrs Disp. (Th - Pr)	% Disponibilidade Referência (VR)
1	07/mar	06:43	10:55	0:23:00	4:12:00	3:49:00	91%
2	08/mar	06:40	10:12	0:18:00	3:32:00	3:14:00	92%
3	09/mar	06:43	10:43	0:15:00	4:00:00	3:45:00	94%
4	10/mar	06:45	10:45	0:12:00	4:00:00	3:48:00	95%
5	15/mar	06:42	10:45	0:22:00	4:03:00	3:41:00	91%
6	16/mar	06:55	10:55	0:21:00	4:00:00	3:39:00	91%
7	21/mar	06:42	10:56	0:11:00	4:14:00	4:03:00	96%
8	22/mar	06:44	10:55	0:18:00	4:11:00	3:53:00	93%
9	23/mar	06:45	10:57	0:33:00	4:12:00	3:39:00	87%
10	24/mar	06:44	11:03	0:23:00	4:19:00	3:56:00	91%
11	05/abr	06:43	11:02	0:05:00	4:19:00	4:14:00	98%
12	06/abr	06:45	10:53	0:45:00	4:08:00	3:23:00	82%
13	07/abr	06:55	10:45	0:55:00	3:50:00	2:55:00	76%
<b>TOTAL</b>				5:01:00	53:00:00	47:59:00	91%

Fonte: Autor (2022)

Na sequência será apresentado os dados obtidos pelo registro manual e pelo sistema de coleta em automático. A TABELA 8 apresenta os dados obtidos pelo

processo anual, realizado conforme a rotina da empresa. Sem a interferência da equipe da pesquisa, as medições foram tomadas pelo operário e registrada no seu diário de bordo, seguindo sua rotina normal de trabalho.

TABELA 8 – VALORES DO PROCESSO MANUAL

Testes realizados		VALORES OBTIDOS DO PROCESSO MANUAL					
nTeste	data	Início	Final	Paradas Hrs (Pr)	Total Hrs (Th)	Hrs Disp. (Th - Pr)	% Disponibilidade <i>Valores Obtidos (VO)</i>
1	07/mar	06:40	10:50	0:05:00	4:10:00	4:05:00	98%
2	08/mar	06:40	10:10	0:06:00	3:30:00	3:24:00	97%
3	09/mar	06:40	10:40	0:02:00	4:00:00	3:58:00	99%
4	10/mar	06:40	10:45	0:02:00	4:05:00	4:03:00	99%
5	15/mar	06:40	10:45	0:02:00	4:05:00	4:03:00	99%
6	16/mar	06:50	10:55	0:12:00	4:05:00	3:53:00	95%
7	21/mar	06:40	10:55	0:02:00	4:15:00	4:13:00	99%
8	22/mar	06:40	10:55	0:05:00	4:15:00	4:10:00	98%
9	23/mar	06:40	10:55	0:17:00	4:15:00	3:58:00	93%
10	24/mar	06:40	11:00	0:13:00	4:20:00	4:07:00	95%
11	05/abr	06:40	11:00	0:02:00	4:20:00	4:18:00	99%
12	06/abr	06:40	10:50	0:18:00	4:10:00	3:52:00	93%
13	07/abr	06:50	10:40	0:27:00	3:50:00	3:23:00	88%
<b>TOTAL</b>				1:53:00	53:20:00	51:27:00	96%

Fonte: Autor (2022)

Na TABELA 9 são apresentados os dados obtidos pelo sistema proposto, os quais foram extraídos do sistema em arquivo do tipo CSV, e os registrados para efeito de comparação.

TABELA 9 – VALORES DO SISTEMA PROPOSTO

Testes realizados		VALORES OBTIDOS PELO SISTEMA					
nTeste	data	Início	Final	Paradas HS	Total HS	HSD	% Disponibilidade <i>Valores Obtidos (VO)</i>
1	07/mar	06:43	10:54	0:29:14	4:11:00	3:41:46	88%
2	08/mar	06:40	10:13	0:32:48	3:33:00	3:00:12	85%
3	09/mar	06:44	10:44	0:28:48	4:00:00	3:31:12	88%
4	10/mar	06:44	10:45	0:17:48	4:01:00	3:43:12	93%
5	15/mar	06:42	10:45	0:29:10	4:03:00	3:33:50	88%
6	16/mar	06:55	10:55	0:12:00	4:00:00	3:48:00	95%
7	21/mar	06:42	10:56	0:02:32	4:14:00	4:11:28	99%
8	22/mar	06:44	10:54	0:29:07	4:10:00	3:40:53	88%
9	23/mar	06:45	10:57	0:25:12	4:12:00	3:46:48	90%
10	24/mar	06:44	11:04	0:13:57	4:20:00	4:06:03	95%
11	05/abr	06:43	11:03	0:06:11	4:20:00	4:13:49	98%
12	06/abr	06:45	10:52	0:41:10	4:07:00	3:25:50	83%
13	07/abr	06:55	10:44	0:49:36	3:49:00	2:59:24	78%
<b>TOTAL</b>				5:17:33	53:00:00	47:42:27	90%

Fonte: Autor (2022)

Aplicando o cálculo de acuracidade, conforme o item 4.4.1, obtém-se o resultado apresentado na TABELA 10. Nela, o processo manual obteve uma acuracidade de 38% e o sistema automático de 85%, confirmando que o sistema proposto apresenta um resultado satisfatório para o artefato da pesquisa. No total o sistema manual teve 96% de disponibilidade, que difere em 5 pontos percentuais do valor de referência, que foi de 91%. Para o sistema proposto, a diferença foi apenas um ponto percentual, apresentando um resultado de 90% de disponibilidade.

TABELA 10 – RESULTADO DA ACURÁCIA DO ÍNDICE DE DISPONIBILIDADE

Testes realizados		VALORES DE REFERÊNCIA	VALORES OBTIDOS DO PROCESSO MANUAL	VERIFICAÇÃO PROC. MANUAL		VALORES OBTIDOS PELO SISTEMA	VERIFICAÇÃO SISTEMA		
nTeste	data	% Disponibilidade Referência (VR)	% Disponibilidade Valores Obtidos (VO)	Erro $\alpha$	Ac +/-5% $\hat{p} / \hat{p}'$	% Disponibilidade Valores Obtidos (VO)	Erro $\alpha$	Ac +/-5% $\hat{p} / \hat{p}'$	
1	07/mar	91%	98%	8%	0	88%	-3%	1	
2	08/mar	92%	97%	6%	0	85%	-8%	0	
3	09/mar	94%	99%	6%	0	88%	-6%	0	
4	10/mar	95%	99%	4%	1	93%	-3%	1	
5	15/mar	91%	99%	9%	0	88%	-3%	1	
6	16/mar	91%	95%	4%	1	95%	4%	1	
7	21/mar	96%	99%	4%	1	99%	3%	1	
8	22/mar	93%	98%	6%	0	88%	-5%	1	
9	23/mar	87%	93%	7%	0	90%	4%	1	
10	24/mar	91%	95%	4%	1	95%	4%	1	
11	05/abr	98%	99%	1%	1	98%	0%	1	
12	06/abr	82%	93%	13%	0	83%	2%	1	
13	07/abr	76%	88%	16%	0	78%	3%	1	
				$\Sigma$ Ac =	5			$\Sigma$ Ac =	11
		91%	96%	Acurácia 5 / 13		90%	Acurácia 11/13		
				38%			85%		

Fonte: Autor (2022)

### 5.2.2 Resultado da acuracidade do índice de performance

Para a verificação do segundo índice do OEE, a performance, foi avaliada como base a quantidade de produtos possíveis de serem usinados, com o tempo disponível e a quantidade de produção realmente obtida.

Esse índice de performance foi calculado com base a fórmula 5 apresentada no item 2.2.6, onde os resultados são apresentados na TABELA 11.

TABELA 11 – RESULTADO DO CÁLCULO DO ÍNDICE PERFORMANCE

Testes realizados		VALORES DE REFERÊNCIA				VALORES OBTIDOS PELO PROCESSO MANUAL				VERIFICAÇÃO PROC. MANUAL		VALORES OBTIDOS PELO SISTEMA				VERIFICAÇÃO SISTEMA			
nTeste	data	Hrs Disp. (Th -Pr)	Produção Teórica	Produção Obtida	%Performance Referência (VR)	Hrs Disp. (Th -Pr)	Produção Teórica	Produção Obtida	%Performance Valores Obtidos (VO)	Erro $\alpha$	Ac $\beta / \beta'$ +/-5%	Hrs Disp. (Th -Pr)	Produção Teórica	Produção Obtida	%Performance Valores Obtidos (VO)	Erro $\alpha$	Ac $\beta / \beta'$ +/-5%		
1	07/mar	3:49:00	19	13	68%	4:05:00	21	13	62%	-10%	0	3:41:46	19	13	68%	0%	1		
2	08/mar	3:14:00	16	14	88%	3:24:00	17	14	82%	-6%	0	3:00:12	15	14	93%	7%	0		
3	09/mar	3:45:00	19	14	74%	3:58:00	20	14	70%	-5%	1	3:31:12	18	14	78%	6%	0		
4	10/mar	3:48:00	19	14	74%	4:03:00	21	14	67%	-10%	0	3:43:12	19	14	74%	0%	1		
5	15/mar	3:41:00	19	14	74%	4:03:00	21	14	67%	-10%	0	3:33:50	18	14	78%	6%	0		
6	16/mar	3:39:00	19	14	74%	3:53:00	20	14	70%	-5%	1	3:48:00	19	14	74%	0%	1		
7	21/mar	4:03:00	21	15	71%	4:13:00	22	15	68%	-5%	1	4:11:28	21	15	71%	0%	1		
8	22/mar	3:53:00	20	16	80%	4:10:00	21	16	76%	-5%	1	3:40:53	19	16	84%	5%	1		
9	23/mar	3:39:00	19	16	84%	3:58:00	20	16	80%	-5%	1	3:46:48	19	16	84%	0%	1		
10	24/mar	3:56:00	20	16	80%	4:07:00	21	16	76%	-5%	1	4:06:03	21	16	76%	-5%	1		
11	05/abr	4:14:00	22	16	73%	4:18:00	22	16	73%	0%	1	4:13:49	22	16	73%	0%	1		
12	06/abr	3:23:00	17	16	94%	3:52:00	20	16	80%	-15%	0	3:25:50	17	16	94%	0%	1		
13	07/abr	2:55:00	15	15	100%	3:23:00	17	15	88%	-12%	0	2:59:24	15	15	100%	0%	1		
										$\Sigma$ Ac =	7							$\Sigma$ Ac =	10
<b>TOTAL</b>		245	193	79%	<b>TOTAL</b>	263	193	73%	Acurácia 7/13		<b>TOTAL</b>	242	193	80%	Acurácia 10/13				
										Acurácia 54%								Acurácia 77%	

Fonte: Autor (2022)

Quando se observa os valores de referência, o total da produção teórica seria de 245 *versus* produção total obtida de 193 unidades. Gerando um índice de performance de 79%, enquanto no cálculo do processo manual obteve 73%, com uma produção teórica de 263 unidades e, para o sistema proposto, um valor de 80% com produção teórica de 242 unidades. Confirmando que o sistema automático é o que mais se aproxima do valor de referência. Sua acurácia novamente confirma um resultado satisfatório, para o sistema proposto com 10/13, que perfaz uma acurácia de 77%, contra 7/13 do processo manual que gera um resultado de 54%.

### 5.2.3 Resultado da acuracidade do índice de qualidade

O índice de qualidade, terceiro e último índice do OEE, por se tratar de uma medida em porcentagem da contagem de produtos conformes, sobre o total produzido e, devido a automação dessa quantidade ser realizada diretamente pelo operário no painel, não gera um comparativo. Isso porque o processo manual e o sistema proposto, ambos são registrados da mesma forma, não diferenciando do valor de referência.

A TABELA 12 é apresentada apenas com o intuito de mostrar os resultados para o índice de qualidade, que posteriormente será usado para o cálculo do OEE.



TABELA 12 – RESULTADO DO CÁLCULO DO ÍNDICE DE QUALIDADE

Testes realizados		ÍNDICE DE QUALIDADE		
nTeste	data	Produção Obtida	Produção Conforme	% Qualidade
1	07/mar	13	13	100%
2	08/mar	14	14	100%
3	09/mar	14	14	100%
4	10/mar	14	14	100%
5	15/mar	14	13	93%
6	16/mar	14	14	100%
7	21/mar	15	15	100%
8	22/mar	16	16	100%
9	23/mar	16	16	100%
10	24/mar	16	15	94%
11	05/abr	16	16	100%
12	06/abr	16	16	100%
13	07/abr	15	15	100%
<b>TOTAL</b>		193	191	<b>99%</b>

Fonte: Autor (2022)

## 5.2.4 Resultado da acuracidade do OEE

Partindo da premissa que o OEE é calculado pela multiplicação das três métricas: disponibilidade, performance e a qualidade, é possível medir o desempenho do equipamento. Observando o resultado da TABELA 13, onde o valor de referência do OEE é de 71%, de 70% no processo manual, e 71% valor obtido pelo sistema, uma diferença aparentemente não significativa, quando observado o valor do cálculo final do OEE. Por este motivo, deve-se analisar as métricas separadamente, como apresentado anteriormente nos itens 5.2.1 , 5.2.2 e 5.2.3.

TABELA 13 – RESULTADO DO CÁLCULO DO OEE

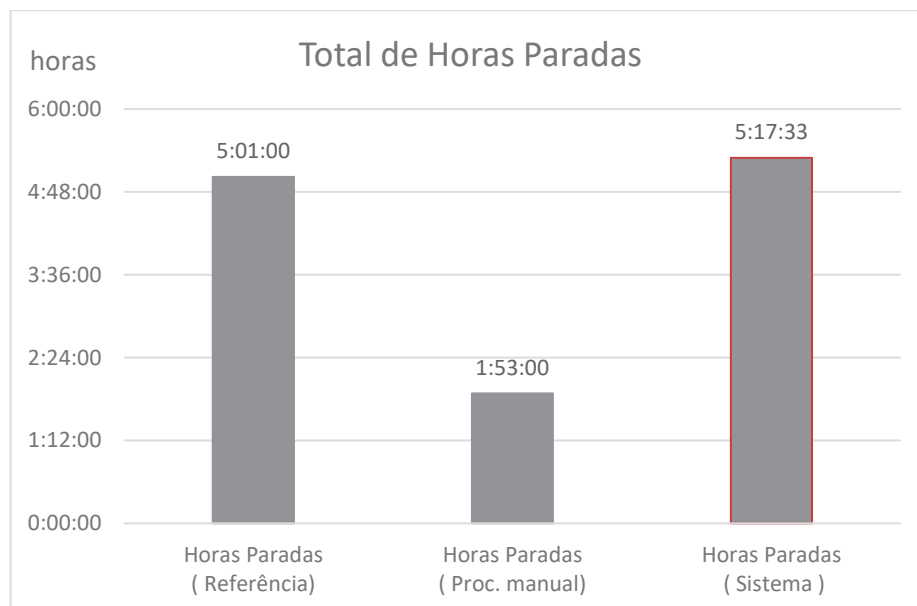
Testes realizados		VALORES DE REFERÊNCIA				VALORES OBTIDOS PELO PROCESSO MANUAL				VALORES OBTIDOS PELO SISTEMA			
nTeste	data	% Disp. Referência (VR)	% Perf. Referência (VR)	% Qual. (VR e VO)	OEE Referência (VR)	% Disp. Valores Obtidos	% Perf. Valores Obtidos	% Qual. (VR e VO)	OEE Referência (VR)	% Disp. Valores Obtidos	% Perf. Valores Obtidos	% Qual. (VR e VO)	OEE Referência (VR)
1	07/mar	91%	68%	100%	62%	98%	62%	100%	61%	88%	68%	100%	60%
2	08/mar	92%	88%	100%	80%	97%	82%	100%	80%	85%	93%	100%	79%
3	09/mar	94%	74%	100%	69%	99%	70%	100%	69%	88%	78%	100%	68%
4	10/mar	95%	74%	100%	70%	99%	67%	100%	66%	93%	74%	100%	68%
5	15/mar	91%	74%	93%	62%	99%	67%	93%	61%	88%	78%	93%	64%
6	16/mar	91%	74%	100%	67%	95%	70%	100%	67%	95%	74%	100%	70%
7	21/mar	96%	71%	100%	68%	99%	68%	100%	68%	99%	71%	100%	71%
8	22/mar	93%	80%	100%	74%	98%	76%	100%	75%	88%	84%	100%	74%
9	23/mar	87%	84%	100%	73%	93%	80%	100%	75%	90%	84%	100%	76%
10	24/mar	91%	80%	94%	68%	95%	76%	94%	68%	95%	76%	94%	68%
11	05/abr	98%	73%	100%	71%	99%	73%	100%	72%	98%	73%	100%	71%
12	06/abr	82%	94%	100%	77%	93%	80%	100%	74%	83%	94%	100%	78%
13	07/abr	76%	100%	100%	76%	88%	88%	100%	78%	78%	100%	100%	78%
<b>TOTAL</b>		<b>91%</b>	<b>79%</b>	<b>99%</b>	<b>71%</b>	<b>96%</b>	<b>73%</b>	<b>99%</b>	<b>70%</b>	<b>90%</b>	<b>80%</b>	<b>99%</b>	<b>71%</b>

Fonte: Autor (2022)

Para demonstrar que o sistema baseado em tecnologia de monitoramento automático apresenta resultados confiáveis, o GRÁFICO 1 mede o quanto esse processo é mais preciso e capaz de demonstrar a real situação das interferências do processo.

Observa-se que o total de horas de parada da máquina é equivalente a 5 horas e 1 minuto, conforme apontado no valor de referência. Já o valor registrado pelo operário foi de 1 hora e 53 minutos, uma diferença de 3 horas e 7 minutos. Todavia, o sistema em automático calculou um total de 5 horas e 17 minutos, uma diferença do referencial de apenas 17 minutos. Ou seja, uma acurácia considerada satisfatória para o estudo e que comprova que mesmo o OEE não apresentando uma diferença alta o sistema manual apresenta problemas no que tange ao registro feito pelo operário.

GRÁFICO 1 – COMPARATIVO DE HORAS PARADAS

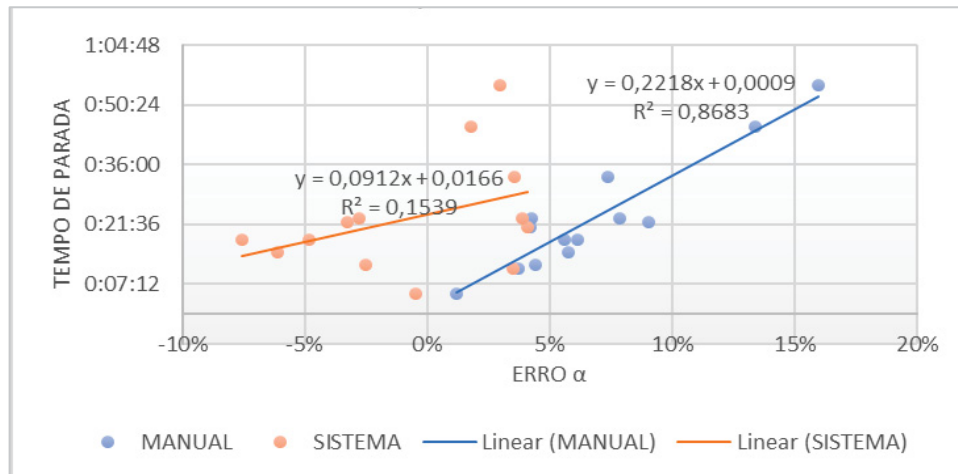


Fonte: Autor (2022)

Outro aspecto que demonstra o sistema em automático com um resultado confiável, é a dispersão dos erros de disponibilidade *versus* as paradas realizadas comparadas no processo manual e no sistema automático. No GRÁFICO 2, que compara o erro  $\alpha$  de disponibilidade no eixo horizontal e o tempo de parada dos valores referenciais na vertical, é possível verificar uma maior variação e tendência

para o processo manual. Diferente do sistema em automático que não apresenta uma tendência.


GRÁFICO 2 – GRÁFICO DE DISPERSÃO DOS ERROS VERSUS TEMPO DE PARADAS



Fonte: Autor (2022)

Também no GRÁFICO 3 de *Box-plot* é observado que o sistema proposto apresenta uma concentração dos erros em torno de zero, e seu “Box” está com a média e mediana muito próximo de 0%, diferentemente do processo manual que desloca a média e mediana para pouco mais de 5%, demonstra que o processo proposto apresenta variação menor em comparação com o sistema atual.

GRÁFICO 3 – GRÁFICO DE *BOX-PLOT* DO % ERRO DE DISPONIBILIDADE



Fonte: Autor (2022)

### 5.3 CONCLUSÃO DO ARTEFATO

Como parte de implementar uma metodologia, que possa orientar a coleta, modelagem, padronização dos dados gerados pelo equipamento e, apresentar os resultados em painel digital, esse objetivo foi alcançado.

O desenvolvimento do artefato, que busca mapear a situação dos equipamentos, intervir sem impactar no processo produtivo, coletar e armazenar os dados, preparar e publicar os indicadores de eficiência do equipamento em *dashboards*, foi possível de ser desenvolvido, aplicado e validado, seguindo o passo a passo descrito no método da pesquisa.

Com base no comparativo dos modelos testado, conclui-se que o artefato apresenta melhores resultados quando comparado ao modelo atual. A acuracidade no modelo proposto é melhor que o modelo atual em todos os índices avaliados no capítulo 5.2, assim sendo o artefato como um método se faz eficaz e efetivo para implementação.

## 6 CONSIDERAÇÕES FINAIS

Como discutido anteriormente, a eficiência dos equipamentos industriais tem uma grande influência e relevância no desenvolvimento tecnológico dos produtos de bens de capitais e conseqüentemente para o crescimento da agricultura. A contribuição deste trabalho é explorar as novas tendências da indústria 4.0, na implementação das técnicas de IIoT e *data analytics* e melhorar a eficiência de equipamentos industriais.

No entanto, não basta apenas aplicar as técnicas corretamente. É necessário o conhecimento dos processos e engajamento dos envolvidos, porquanto, muitas técnicas somente são possíveis de implementação quando a experiência e o conhecimento são integrados ao método proposto.

Nesse sentido, esse trabalho contribui para o entendimento do conceito de Indústria 4.0 e os benefícios em implementar as tecnologias de IIoT e *data Analytics*, além de esclarecer a importância do indicador OEE e suas métricas de disponibilidade, performance e qualidade.

O resultado da acurácia de 85% para o sistema de coleta automática e 38% para o processo atual, no índice de disponibilidade, demonstra que a implementação de um método estruturado de gestão de dados melhora a qualidade das informações obtidas, fundamentais para o aumento da disponibilidade dos equipamentos.

Outra observação relevante, no que tange a disponibilidade do equipamento, provém do fato de que os registros de paradas de máquinas realizados por processo manual, apresentam uma diferença de 3 horas e 7 minutos, com relação ao valor de referência. Já o sistema em automático teve uma diferença de 17 minutos, como apresentado no GRÁFICO 1, reforçando a utilização do método para implementação das técnicas da Indústria 4.0 e como uma metodologia a ser seguida.

No índice de performance, o resultado de 77% de acurácia nas medições do sistema de coleta automático *versus* 54% do processo atual, enfatiza que o modelo proposto oferece aderência ao conceito de melhoria dos processos e sua aplicação melhora a produtividade do equipamento.

Dois dos índices que compõem o OEE, disponibilidade e performance, tiveram melhoras na acuracidade, comprovando a eficácia do método. O terceiro índice, qualidade, não teve sua acurácia medida, visto que os valores são coletados e medidos nos mesmos padrões, sem interferência do processo automatizado.

Outro resultado importante da pesquisa foi o desenvolvimento de um *dashboard*, com base analítica e um leiaute direcionado ao operário da máquina, trazendo informações objetivas, tratadas e calculadas para orientar na tomada de decisão efetiva, garantindo maior responsabilidade e agilidade, resultando em um processo de maior qualidade e produtividade.

Destaca-se que a empresa que financiou esta pesquisa buscava implementar as tecnologias da indústria 4.0, através de um sistema de monitoramento e controle do OEE. Mas, obteve um método para implementação de técnicas da indústria 4.0 e um sistema automático de coletas de dados, e conseqüentemente melhoria na produtividade, acurácia nos dados registrados e conhecimento do seu processo de fabricação.

Diante disso, acredita-se que os objetivos estabelecidos para esta pesquisa foram alcançados. Com base nos resultados obtidos, o método apresentado pode ser implementado como sistema de monitoramento, utilizando as técnicas de IIoT e *data analytics*.

Por fim, o artefato (método) poderá ser utilizado pela empresa, na implementação de sistema automático de diversos equipamentos, podendo também ajudar a desenvolver trabalhos voltados para coleta de perdas, redução de desperdícios e aprimorar o conhecimento dos processos.

Das discussões e resultados apresentados, e como parte de um modelo a ser seguido e aprimorado, o índice de qualidade foi uma informação que, nesse artefato, não pode ser automatizado em sua totalidade.

## **7 RECOMENDAÇÕES PARA TRABALHOS FUTUROS**

Como desafio para trabalhos futuros, viabilizar tecnologias para coleta de dados não conectados em CLP ou “*smart box*”, instalados nos equipamentos. Como, por exemplo, dados oriundos das inspeções de qualidade em bancada ou dispositivos, sem interface direta, nos equipamentos monitorados remotamente.

Outra oportunidade encontrada no desenvolvimento do artefato foi o fato de utilizar os softwares “comerciais”, como Phyton, para coleta de dados oriundos de outros sistemas de controle e gestão. Além do Quilk Sense, para preparação dos dados, antes de disponibilizar para a visualização, observou-se que nesse campo existe uma oportunidade de desenvolvimento ainda não explorada, que pode ser alvo de pesquisas e oportunidades futuras.

## REFERÊNCIAS

- ACATECH; UNIVERSITÄT PADERBORN, Heinz N. I.; RWTH AACHEN UNIVERSITY, WZL. **Industrie 4.0 – International Benchmark, Options for the Future and Recommendations for Manufacturing Research**. ACATECH, 2016. Disponível em: <https://en.acatech.de/publication/industrie-4-0-international-benchmark-options-for-the-future-and-recommendations-for-manufacturing-research>. Acesso em: Maio 2020.
- ACETO, GIUSEPPE ACETO; VALERIO , PERSICO ; PESCAPÉ, ANTONIO. **A Survey on Information and Communication Technologies for Industry 4.0: State-of-the-Art, Taxonomies, Perspectives, and Challenges**. IEEE COMMUNICATIONS SURVEYS AND TUTORIALS, v. 21, n. 4, p. 3467-3501, 2019. Acesso em: Maio 2022
- AHELEROFF, SHOHIN *et al.* **IoT-enabled smart appliances under industry 4.0: A case study**. Advanced Engineering Informatics, 2020.
- AJAY KUMA, RAVI S. L. S. T. **A big data driven sustainable manufacturing framework for condition-based maintenance prediction**. Journal of Computational Science, v. 27, p. 428–439, 2018.
- AKEN, JOAN E. VAN. **Management Research Based on the Paradigm of the Design Sciences: The Quest for Field - Tested and Grounded Technological Rules**. Journal of Management Studies, v. 41, n. 2, p. 219-246, 2004.
- ALVES, ELISEU; SOUZA, GERALDO D. S. E.; ROCHA, DANIELA D. P. **Lucratividade da agricultura**. Revista de Política Agrícola, v. 21, n. 2, 2012. Disponível em: <https://seer.sede.embrapa.br/index.php/RPA/article/view/96>. Acesso em: Abril 2022.
- ANDERSSON, CARIN; BELLGRAN, MINICA. **On the complexity of using performance measures: Enhancing sustained production improvement capability by combining OEE and productivity**. Journal of Manufacturing Systems, v. 35, p. 144-154, 2015.
- ANFAVEA. **Dados Estatísticos para Download: Séries mensais, a partir de janeiro/1960, de máquinas agrícolas e rodoviárias por segmento (tratores de rodas, tratores de esteiras, cultivadores motorizados (até 2016), colheitadeiras de grãos, colhedoras de cana, retroescavadeiras) de produção; vendas internas no atacado de nacionais, importados e total; exportações em unidades**. Disponível em: <https://anfavea.com.br/site/edicoes-em-excel/> . Acesso em: Abril 2021.
- ANSARI, FAZEL ; GLAWAR, ROBERT ; NEMETH, TANJA. **PriMa: a prescriptive maintenance model for cyber-physical production systems**. International Journal of Computer Integrated Manufacturing, v.32, p. 482-503, 2019.

BALONI, BEENA; PATHAK, YOGESH; CHANNIWALA, S.A. **Centrifugal blower volute optimization based on Taguchi method**. *Computers & Fluids*, v. 1, p. 72-78, 2015.

BAYAZIT, NIGAN. **Investigating Design: A Review of Forty Years of Design Research**. *Design Issues*, v. 20, n. 1, p. 16-29, 2004.

CALABRESE, MATTEO *et al.* **SOPHIA: An Event-Based IoT and Machine Learning Architecture for Predictive Maintenance in Industry 4.0**. *Information*, v. 11, p. 202, 2020.

CARBONI. **Fábrica de máquinas agrícolas da CNH Industrial no Brasil celebra 40 anos**. [s.n], 2015. Disponível em: <https://blogdacarboni.com.br/2015/10/26/fabrica-de-maquinas-agricolas-da-cn/>. Acesso em: Maio 2022.

CARVALHO, Gustavo D. G. D. *et al.* **Bibliometrics and systematic reviews: A comparison between the Proknow-C and the Methodi Ordinatio**. *Journal of Informetrics*, v. 14, n. 3, 2020. Disponível em: [www.sciencedirect.com/science/article/pii/S1751157719303682](http://www.sciencedirect.com/science/article/pii/S1751157719303682). Acesso em: Maio 2022.

CATTANEO, L *et al.* **Clarifying Data Analytics Concepts for Industrial Engineering**. *IFAC-PapersOnLine*, Belgrano, Italia, v. 51, n. 11, p. 820-825, 2018. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2405896318315672>. Acesso em: Outubro 2021.

CHEN, BAOTONG *et al.* **Smart Factory of Industry 4.0: Key Technologies, Application Case, and Challenges**. in *IEEE Access*, v. 6, p. 6505-6519, 2018.

DALENOGARE, LUCAS S. *et al.* **The expected contribution of Industry 4.0 technologies for industrial performance**. *International Journal of Production Economics*, v. 204, p. 383 - 394, 2018. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0925527318303372>. Acesso em: Outubro 2021.

DAVID SJÖDIN, Vinit P. M. K. J. W. **An agile co-creation process for digital servitization: A micro-service innovation approach**. *Journal of Business Research* v.1, n.12, p. 478–491, 2020.

DIEZ-OLIVAN, ALBERTO *et al.* **Data Fusion and Machine Learning for Industrial Prognosis: Trends and Perspectives towards Industry 4.0**. *Information Fusion* , v. 50, p.92-111, 2019.

DRESCH, ALINE; LACERDA, DANIEL P.; ANTUNES JR, JOSÉ ANTÔNIO V. **Design Science Research - A Method for Science and Technology Advancement**. Springer Cham, 2015.



ENGELMANN, BASTIAN *et al.* **Advances in Machine Learning Detecting Changeover Processes in Cyber Physical Production Systems**. Journal of Manufacturing and Materials Processing, v. 4, n. 4, 2020.

GE, ZHIQIANG *et al.* **Data Mining and Analytics in the Process Industry: The Role of Machine Learning**. IEEE Access, v. 5, p. 20590-20616, 2017. Disponível em: <https://ieeexplore.ieee.org/document/8051033>. Acesso em: Outubro 2021.

GUO, YUAN *et al.* **The internet of things-based decision support system for information processing in intelligent manufacturing using data mining technology**. Mechanical Systems and Signal Processing, v. 142, p. 106630, 2020. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0888327020300169>. Acesso em: Setembro 2021.

GUPTA, PARDEEP; VARDHAN, SACHIT. **Optimizing OEE, productivity and production cost for improving sales volume in an automobile industry through TPM: a case study**. International Journal of Production Research, v. 54, n. 10, p. 2976-2988, 2016.

HAN, JIAWEI; KAMBER, MICHELINE; PEI, JIAN. **Data Mining: Concepts and Techniques**. 3rd. Elsevier Science, 2011.

HASTIE, TREVOR; TIBSHIRANI, ROBERT; FRIEDMAN, JEROME. **The elements of statistical learning: data mining, inference, and prediction**. New York: springer, 2009.

HEVNER, ALAN R. *et al.* **Design Science in Information Systems Research**. MIS Quarterly, v. 28, n. 1, p. 75-105, 2004.

IBGE. **LSPA - Levantamento Sistemático da Produção Agrícola**. Disponível em: <https://www.ibge.gov.br/estatisticas/economicas/agricultura-e-pecuaria/9201-levantamento-sistemico-da-producao-agricola.html?edicao=20757&t=publicacoes>. Acesso em: Abril 2021.

JAIN, ABHISHEK ; BHATTI, RAJBIR ; SINGH, HARWINDER. **OEE enhancement in SMEs through mobile maintenance: A TPM concept**. International Journal of Quality & Reliability Management, v. 32, p. 503-516, 2015.

KHAN, WAZIR Z. *et al.* **Industrial internet of things: Recent advances, enabling technologies and open challenges**. Computers & Electrical Engineering, v. 81, p. 106522, 2020.

KNAFLIC, COLE N. **Storytelling com Dados: Um guia sobre visualização de dados para profissionais de negócios**. Alta Books. Brasil, 2019. Disponível em: [https://books.google.com.br/books/about/Storytelling\\_com\\_Dados.html?id=qvKjDwAAQBAJ&source=kp\\_book\\_description&redir\\_esc=y](https://books.google.com.br/books/about/Storytelling_com_Dados.html?id=qvKjDwAAQBAJ&source=kp_book_description&redir_esc=y). Acesso em: Outubro 2022.

KUSIAK, ANDREW. **Smart manufacturing**. International Journal of Production Research, v. 56, n. 1-2, p. 508-517, 2018.

LACERDA, DANIEL P. *et al.* **Design Science Research: método de pesquisa.** *Gestão & produção*, v.20, n. 4, p. 741-761, 2013.

LISBOA, MAYCON *et al.* **Improve Industrial Performance Based on Systematic Analyses of Manufacturing Data.** *IFAC-PapersOnLine*, v. 54, n. 1, p. 709-716, 2021.

MADHAB, JENA C.; MISHRA, SARAT K.; MOHARANA, MOHARANA. **Application of Industry 4.0 to enhance sustainable manufacturing.** *Environ Prog Sustainable Energy*, v. 39, n. 1, p. 113360, 2020.

MANSON, NEIL J. Is operations research really research? *Orion*, v. 22, n. 2, p. 155-180, 2006.

MARCH, SALVATORE T.; SMITH, GERALD F. **Design and natural science research on information technology.** *Decision Support Systems*, v. 15, n. 4, p. 251-266, 1995.

MARKPLACERURAL, SITE, 2021 . Acesso em: Setembro 2021.

MARR, B. **Big Data: Using SMART Big Data, Analytics and Metrics To Make Better Decisions and Improve Performance.** John Wiley & Sons. NY, 2015. Disponível em: [https://books.google.com.br/books?id=p\\\_glBgAAQBAJ](https://books.google.com.br/books?id=p\_glBgAAQBAJ). Acesso em: Setembro 2021.

MITCHELL, T. **Machine Learning.** McGraw-Hill Science. Ithaca, NY, 1997. Disponível em: <https://www.cin.ufpe.br/~cavmj/Machine%20-%20Learning%20-%20Tom%20Mitchell.pdf>. Acesso em: Junho 2020.

MOENS, PIETER *et al.* **Scalable Fleet Monitoring and Visualization for Smart Machine Maintenance and Industrial IoT Applications.** *MDPI and ACS Style*, v. 20, n. 15, p.4308, 2020.

MONICO, JOÃO F. G. *et al.* **Acurácia e precisão: revendo os conceitos de forma acurada.** *Boletim de Ciências Geodésicas*, v. 15, n. 3, p. 469-483, 2009. Disponível em: <https://www.redalyc.org/articulo.oa?id=393937709010>. Acesso em: Maio 2020.

MORAES, CÍCERO C.; CASTRUCCI, PLÍNIO D. L. **Engenharia de automação industrial.** Editora LTC. Rio de Janeiro, 2017.

NEWHOLLAND, SITE. **Colheitadeiras – CR, MODELO, CR 10.90.** [s.n], 2021. Disponível em: <https://agriculture.newholland.com/lar/pt-br/equipamento/produtos/colheitadeiras/cr/modelos>. Acesso em: Fevereiro 2021.

OSTROWSKI, JOÃO ; MENYHÁRT, JÓZSEF. **Enhancing maintenance with a data-driven approach.** *International Review of Applied Sciences and Engineering*, v.10 , n. 2, p. 135–140, 2019.

PANDZA, KRSTO; THORPE, RICHARD. **Management as Design, but What Kind of Design?** An Appraisal of the Design Science Analogy for Management, v. 21, n. 1, p. 171-186, 2010.

PEFFERS, KEN *et al.* **A design science research methodology for information systems research.** Journal of management information systems, v. 24, n. 3, p. 45-77, 2007.

PERES, RICARDO S. *et al.* **IDARTS – Towards intelligent data analysis and real-time supervision for industry 4.0.** Computers in Industry, v. 101, p. 138-146, 2018.

PROVOST, FOSTER; FAWCETT, TOM. **Data Science for Business: What you need to know about data mining and data-analytic thinking.** O'Reilly Media, Inc. Sebastopol, California, 2013. Disponível em: [https://books.google.com.br/books?id=EZAtAAAAQBAJ&lr=&hl=pt-BR&source=gbs\\_navlinks\\_s](https://books.google.com.br/books?id=EZAtAAAAQBAJ&lr=&hl=pt-BR&source=gbs_navlinks_s). Acesso em: Maio 2020.

QVIST-SORENSEN, PETER. **Applying IIoT and AI - Opportunities, Requirements and Challenges for Industrial Machine and Equipment Manufacturers to Expand Their Services.** Central European Business Review, v. 9, p. 46-77, 2020.

RADANLIEV, PETAR *et al.* **Artificial intelligence in cyber physical systems.** AI & SOCIETY, 2020.

RAFIQUE, DANISH; VELASCO, LUIS. **Machine Learning for Network Automation: Overview, Architecture, and Applications [Invited Tutorial].** Journal of Optical Communications and Networking, v. 10, n. 10, p. D126-D143, 2018.

ROMME, A GEORGES L. **Making a difference: Organization as design.** Organization science, v. 14, n. 5, p. 558-573, 2003.

SAMUEL, A.L. **Some Studies in Machine Learning Using the Game of Checkers.** II—Recent progress. Annual review in automatic programming, p. 1-36, 1959.

SEIN, MAUNG K. *et al.* **Action Design Research.** MIS Quarterly, v. 35, n. 1, p. 37-56, 2011.

SHROUF, FADI.; ORDIERES, JOAQUIN.; MIRAGLIOTTA, GIOVANNI. **Smart factories in Industry 4.0: A review of the concept and of energy management approached in production based on the Internet of Things paradigm.** 2014 IEEM International Industrial Engineering and Engineering Management, p. 697-701, 2014. Disponível em: <https://ieeexplore.ieee.org/document/7058728>. Acesso em: Maio 2020.

SIMON, HERBERT ALEXANDER. **The Sciences of the Artificial.** 3rd. The MIT Press, 1996.

TAKEDA, HIDEAKI; VEERKAMP, PAUL; YOSHIKAWA, HIROYUKI. **Modeling Design Process.** AI Magazine, v. 11, n. 4, p. 37, 1990.

TAN, LU; WANG, NENG. **Future internet: The Internet of Things**. 2010 3rd international conference on advanced computer theory and engineering (ICACTE). IEEE, p. V5-376-V5-380, 2010. Disponível em: <https://ieeexplore.ieee.org/document/5579543>. Acesso em: Maio 2020.

TRAINI, EMILIANO *et al.* **Machine learning framework for predictive maintenance in milling**. IFAC PapersOnLine, v. 52, n.13 , p. 177–182, 2019.

TURNER, CHRIS *et al.* **Intelligent decision support for maintenance: An overview and future trends**. International Journal of Computer Integrated Manufacturing, v. 32, n. 10, p. 936-959, 2019.

VAISHNAVI, VIJAY; KUECHLE, BILL. **Design Research in information Systems**. Desrist.org, 2004. Disponível em: <http://www.desrist.org/design-research-in-information-systems>. Acesso em: Setembro 2021.

VIEIRA FILHO, JOSÉ EUSTÁQUIO R.; FISHLOW, ALBERT. **Agricultura e indústria no Brasil: inovação e competitividade**. IPEA. Brasília, 2017. Disponível em: <http://repositorio.ipea.gov.br/handle/11058/7682>. Acesso em: Maio 2021.

VIEIRA FILHO, JOSÉ EUSTÁQUIO R.; GASQUES, JOSÉ G. **Uma jornada pelos contrastes do Brasil: cem anos do Censo Agropecuário**. IPEA. Brasília, 2020. Disponível em: <http://repositorio.ipea.gov.br/handle/11058/10339>. Acesso em: Maio 2021.

VLACHOPOULOS, JOHN; STRUTT, DAVID. **Polymer processing**. Materials science and technology, v. 19, n. 9, p. 1161-1169, 2003.

WAGIRE, ANIRUDDHA ; RATHORE, AJAY PAL S.; JAIN, RAKESH. **Analysis and synthesis of Industry 4.0 research landscape: Using latent semantic analysis approach**. Journal of Manufacturing Technology Management, p. 31-51, 2019.

WANG, SHIJIN *et al.* **Big Data enabled Intelligent Immune System for energy efficient manufacturing management**. Journal of Cleaner Production, v. 195, p. 507-520, 2018.

XU, HANSONG *et al.* **A Survey on Industrial Internet of Things: A Cyber-Physical Systems Perspective**. IEEE Access, v. 6, p. 78238-78259, 2018.

XU, LI D.; HE, WU; LI, SHANCANG. **Internet of Things in Industries: A Survey**. IEEE Transactions on Industrial Informatics, v. 10, n. 4, p. 2233-2243, 2014. Disponível em: <https://ieeexplore.ieee.org/document/6714496>. Acesso em: Setembro 2021.

YUNIAWAN, DANI; ITO, TERUAKI; BIN, MOHAMAD E. **OEE Measurement by Taguchi Method with Simulation**. Proceedings of International Symposium on Scheduling, p. 1-4, 2013. Disponível em: <http://ci.nii.ac.jp/naid/110009952861>. Acesso em: Setembro 2021.

YUNIAWAN, DANI; ITO, TERUAKI; BIN, MOHAMAD E. **Calculation of overall equipment effectiveness weight by Taguchi method with simulation.** Concurrent Engineering, v. 21, n. 4, p. 296-306, 2013.

ZHANG, WEITING; DONG YANG, HONGCHAO W. **Data-Driven Methods for Predictive Maintenance of Industrial Equipment: A Survey.** IEEE SYSTEMS JOURNAL, n. 3, v. 13, p. 2213-2217, 2019.

ZHANG, YINGFENG *et al.* **A big data analytics architecture for cleaner manufacturing and maintenance processes of complex products.** Journal of Cleaner Production, v. 142, n. 2, p. 626-641, 2017. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0959652616310198>. Acesso em: Outubro 2021.

ZHE, LI; YI, WANG; KE-SHENG, WANG. **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.

## APÊNDICE 1 – LISTA DE ARTIGOS PESQUISADOS NA REVISÃO

n.	Título do Artigo	Citações	Autores	Ano	Fonte
1	Data Mining and Analytics in the Process Industry: The Role of Machine Learning	381	Ge Z., Song Z., Ding S.X., Huang B.	2017	Scopus
2	Smart Factory of Industry 4.0: Key Technologies, Application Case, and Challenges	306	Chen B., Wan J., Shu L., Li P., Mukherjee M., Yin B.	2017	Scopus
3	A Survey on Information and Communication Technologies for Industry 4.0: State-of-the-Art, Taxonomies, Perspectives, and Challenges	302	Aeeto, G. Persico, V. Pescapé, A	2019	Web Science
4	A Survey on Industrial Internet of Things: A Cyber-Physical Systems Perspective	153	Xu, HS; Yu, W; Griffith, D; Golinie, N	2018	Web Science
5	Intelligent decision support for maintenance: an overview and future trends	144	Turner, CJ; Emmanouilidis, C; Tomiyama, T; Twari, A; Roy, R	2019	Web Science
6	Security of smart manufacturing systems	104	Tuptuk, N; Hailes, S	2018	Web Science
7	Artificial intelligence in cyber physical systems	82	Radanilev, P; De Roure, D; Van Kleek, M; Santos, O; Ani, U	2019	Web Science
8	On the complexity of using performance measures: Enhancing sustained production improvement capability by combining OEE and productivity	49	Andersson C., Bellgran M.	2015	Scopus
9	Advances in Machine Learning Detecting Changeover Processes in Cyber Physical Production Systems	48	Engelmann, B; Schmitt, S; Miller, E; Brautigam, V; Schmitt, J	2020	Web Science
10	OEE enhancement in SMEs through mobile maintenance: A TPM concept	38	Jain A., Bhatti R.S., Singh H.	2015	Scopus
11	Optimizing OEE, productivity and production cost for improving sales volume in an automobile industry through TPM: A case study	34	Gupta P., Vardhan S.	2016	Scopus
12	Big Data enabled Intelligent Immune System for energy efficient manufacturing management	26	Wang S., Liang Y.C., Li W.D., Cai X.T.	2018	Scopus
13	Strategic maintenance technique selection using combined quality function deployment, the analytic hierarchy process and the benefit of doubt approach	22	Bardya R., Dey P.K., Ghosh S.K., Petridis K.	2018	Scopus
14	Ranking of barriers for effective maintenance by using TOPSIS approach	21	Singh R.K., Gupta A., Kumar A., Khan T.A.	2016	Scopus
15	Smart manufacturing	21	Kusiak, A	2018	Web Science
16	Privacy Preservation in Industrial IoT via Fast Adaptive Correlation Matrix Completion	21	Lalos, A.S; Vachos, E; Berberidis, K; Fournaris, AP; Koulamas, C	2020	Web Science
17	Comparison between multi-class classifiers and deep learning with focus on industry 4.0	20	Miškuf M., Zolotová I.	2016	Scopus
18	Application of Industry 4.0 to enhance sustainable manufacturing	20	Jena M.C, Mishra S.K., Moharana H.S.	2020	Scopus
19	Visual Management System to Manage Manufacturing Resources	15	Steenkamp L.P., Hagedorn-Hansen D., Oosthuizen G.A.	2017	Scopus
20	Enabling of Predictive Maintenance in the Brownfield through Low-Cost Sensors, an IIoT-Architecture and Machine Learning	13	Strauß P., Schmitz M., Wöstmann R., Deuse J.	2019	Scopus
21	Implementation of a large-scale platform for cyber-physical system real-time monitoring	12	Canizo M., Conde A., Charramendieta S., Minon R., Cib-Fuentes R.G., Onieva E.	2019	Scopus
22	Online Fault-monitoring in Machine Tools Based on Energy Consumption Analysis and Non-invasive Data Acquisition for Improved Resource-efficiency	10	Emec-S., Krüger J., Seliger G.	2016	Scopus
23	Quantification of machine performance through Overall Equipment Effectiveness	10	Ramlan R., Ngadiman Y., Omar S.S., Yassin A.M.	2015	Scopus

Note: Nem todos os artigos foram utilizados na dissertação, todas que foram citadas foram incluídas nas referências bibliográficas

## **ANEXO 1 - ANÁLISE TAGUCHI PARA EXPERIMENTO DE USINAGEM**

## Experimento aplicando o método Taguchi com avaliação de efeito OEE em equipamentos de usinagem CNC

Mestrando: **Maycon Lisboa** (e-mail [maycon.lisboa@ufpr.br](mailto:maycon.lisboa@ufpr.br))

Dr.Professor: **Ramon Sigifredo Cortes Paredes** (e-mail [ramon@ufpr.br](mailto:ramon@ufpr.br))

### ABSTRACT

Este trabalho visa como objetivo principal desenvolver um estudo para identificar o efeito no indicador de OEE, serão avaliadas as três referências que compõe o indicador, disponibilidade, desempenho e qualidade. Cada referência do KPI influencia a tomada de decisão, que por sua vez acionada um determinado departamento para identificar e sanar as anomalias que interferem na performance de produção. Como a produção é o objetivo final, cada área de suporte é acionada quando existe uma perda produtiva ligada a um desses três elementos, para entender a influência do OEE, um estudo em uma linha de usinagem, foi construído um modelo para simular os 3 efeitos na implementação de medição do OEE. O método adotado foi o de Taguchi e os resultados mostram que os elementos OEE quando classificados corretamente podem ajudar a identificar a influência da escolha das variáveis no resultado de OEE. Além de poder ajudar na escolha dos parâmetros mais adequados do processo e para formação de um sistema de análise de dados para desenvolvimento de análises de tomada de decisões na linha de produção de máquinas CNC.

**Keywords:**OEE,Simulation, Taguchi, data analysis

### 1. INTRODUÇÃO

Em uma linha de produção a eficácia dos equipamentos depende de vários aspectos que influenciam na produtividade e o OEE (*Overall Equipment Effectiveness*) é um Indicador chave de desempenho (KPI) que é amplamente utilizado nas

linhas de produção. OEE é uma é um indicador que mede a eficácia dos equipamentos através de 3 referencias DISPONIBILIDADE, PERFORMANCE e QUALIDADE, poderosas Medições que quando combinadas demonstram a real capacidade de produção. A Eficácia geral do equipamento (OEE) é uma hierarquia de métricas para medir o desempenho da máquina de produção na indústria de manufatura (RAMLAN, NGADIMAN, *et al.*, 2015)

O aumento do OEE e da produtividade e a redução do custo de produção resultaram no dobro da receita de vendas e no triplo do lucro em um período de três anos (GUPTA e VARDHAN, 2016). OEE é usado como um dos KPI para tomar decisões sobre como melhorar os problemas da máquina e para apoiar o programa Total Productive Maintenance (TPM) (GUPTA, VARDHAN e AL HAQUE, 2015).

Segundo Balogh Z. *et al.*(2018) estabelecer uma infraestrutura de IoT para a coleta da grande quantidade de dados de chão de fábrica, através de algoritmos de análise de dados, modelos de manutenção preditiva e técnicas de previsão, para realizar a avaliação e previsão da saúde dos equipamentos antes de acionar uma intervenção, realizando avaliações preventivas de ocorrência de possíveis falhas e consequentemente podendo realizar as intervenções de manutenção/qualidade planejada e sem interferências bruscas no sistema de produção (BALOGH, GATIAL, *et al.*, 2018). Neste estudo é proposto um experimento visa obter uma relação entre as variáveis que influenciam o processo de usinagem e impacto na OEE. Neste estudo, as medições de OEE serão realizados em conjunto com o resultado experimento de Taguchi.



### 1.1 Justificativa

Como a necessidade de acompanhar a eficiência através do indicador de OEE, melhorar a produtividade e reduzir o custo em processo de usinagem, para isso deve-se descobrir uma combinação das variáveis de entrada que resultariam em valores ótimos, obter a melhor combinação de parâmetros em busca de valores ótimos.

### 1.2 Objetivo

Método Taguchi é uma ferramenta estatística poderosa para a concepção de um experimento utilizando tabelas de matriz ortogonais, essa matriz ortogonal depende do número de fatores e níveis que são utilizados para estudar os efeitos dos parâmetros envolvidos, por este motivo foi escolhido para entender os efeitos dos parâmetros na qualidade do produto, mas também avaliar o OEE resultante de acordo com as variáveis envolvidas.

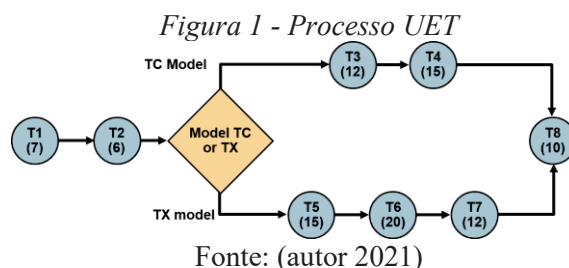
## 2. METODOLOGIA DE PESQUISA

A metodologia de Taguchi foi escolhida para observar a influência do OEE no modelo de desenvolvido para coleta dos dados do Centro de Usinagem CNC. O estudo foi realizado em uma empresa de fabricação de equipamentos agrícolas, situada na região Sul do Brasil, e que possui uma linha de produção de Transmissões de tratores e colheitadeiras, sendo o processo de usinagem dos eixos de transmissões (UET) o objeto do estudo.

Com foco na a influência das variáveis de usinagem com os elementos dos OEE, Disponibilidade, Performance e Qualidade, este estudo buscou, através da metodologia de planejamento experimental de arranjos ortogonais de TAGUCHI e avaliar quais parâmetros exercem maior influência no UET, Matriz ortogonal foi considerado como adequada para atingir o objetivo deste estudo.


## 3. PLANEJAMENTO DO EXPERIMENTO

O processo UET divide-se em dois tipos de processos: TC e TX. O fluxo do processo para ambos os tipos de produtos fabricados é mostrado na Figura 1. Ambos os tipos de são processados primeiro por meio das etapas T1 e T2. O processo de divide pelas etapas T3 e T4 para os Modelos TX, enquanto o modelo TC é processada pelas etapas T5, T6 e T7. Ambas as peças terminam na estação de inspeção (T8). Os números entre parênteses indicam os minutos que essa atividade leva para ser processada.



Este estudo se concentra apenas na linha de manufatura TX, deixando o estudo disponível para aplicação na linha TC posteriormente caso desejado pela empresa.

O processo TX consiste em três processos; processo de usinagem (T5), estação de Inspeção (T6) e processo de marcação/Tipagem (T7). O layout do Processo TX é mostrado com maiores detalhes na Figura 2.



### 3.1 Processo UET


Os parâmetros do processo TX detalhadamente seguem: em consideração a demanda o processo TX está relacionado ao modelo que têm como capacidade declarada de 17 unidades ao dia com 8,8 horas de trabalho por dia, esta declaração é apresentada para a área comercial e sendo essa considerada para o estudo.

No Processo T5 temos o processo de USINAGEM LONGITUDINAL que será alvo do

estudo, é uma peça que para efeito de estudo será chamada de EIXO PRINCIPAL (EP).

O EP é uma peça que faz conexão de um sistema de transmissão, a peça que será estudada é observada na Figura 3.

Figura 3 – Eixo Principal



Fonte: (autor 2021)

O Processo é da USINAGEM do corpo longitudinal de comprimento 132mm e com diâmetro de 45mm.


Equipamento utilizado é um centro de usinagem vertical NLX 2000 – DMG MORI.

### 3.2 Plano de Controle

**Diâmetro final:** 45 mm (0, -0,025mm), ou seja, máximo do diâmetro será 45,000 e mínimo 44,975 mm,

Nota: O diâmetro do eixo foi medido utilizando-se um Micrômetro Externo Digital 25-50mm 0,001mm - classe A, com medições realizadas em quatro posições em três planos conforme Figura 4.

Figura 4 – Medição do eixo



Fonte: (autor 2021)

A **cilindricidade** foi avaliada a tolerância é a metade da tolerância de diâmetro. Isto se refere ao sistema de medição em dois pontos do cilindro.



**O comprimento do corpo usinado cilíndrico:** é de 132 +/- 0,1mm, medido com Paquímetro

Mitutoyo de Profundidade ABSOLUTE 200mm 0,01mm.

**Rugosidade:** N7 ou Ra 1,6µm sendo aceitável até N9 Ra 6,3 µm

Nota: processo de medição foi realizado com a peça estabilizada em bancada de medição com o rugosímetro Mitutoyo SURFTEST-301. Sendo feitas 2 posições (1 e 2) onde para cada posição foram tomadas 3 medidas de pontos diferente da mesma posição distribuídas num giro de 120°, conforme Figura 5.

Figura 5 – Medição do eixo Ra µm



Fonte: (autor 2021)

### 3.3 Taguchi Metodologia

#### a) Definição dos parâmetros

Para definir os parâmetros de entrada foi avaliado a variável de Saída que apresenta maior relevância para o processo que é a Rugosidade e para efeito de qualidade geral o OEE, no elemento Q = qualidade foram considerado as medidas do diâmetro, comprimento e rugosidade, teremos um melhor detalhamento no Capítulo 3.4, entretanto para conseguirmos comparar o efeito das variáveis, com a resposta Rugosidade e OEE, foram considerados:





- A. Velocidade de Corte (vc)
- B. Avanço da Ferramenta (f)

- C. Profundidade (P)
- D. Tipo de Inserto (TI)
- E. Refrigeração (R)
- F. Material (M)

b) Definição dos Níveis

Para cada um desses fatores foi considerado 2 níveis conforme vemos na Tabela 1

*Tabela 1 – Tabela de Fatores e Níveis*

Tabela 1 - Fatores e Níveis			1	2	
Fator	Definição da característica		Nível 1	Nível 2	
A	Velocidade de Corte (VC) m/min	Para nível 1: valores recomendado pelo Fabricante da Pastilha, Para o Nível 2	70,00	84,00	
		Para nível 2: valores com 15% acima do recomendado pelo fabricante			
Fator	Definição da característica		Nível 1	Nível 2	
B	Avanço da Ferramenta (f) mm	Para nível 1: valores recomendado pelo Fabricante da Pastilha, Para o Nível 2	0,12	0,18	
		Para nível 2: valores com 50% acima do recomendado pelo fabricante, Acelerar o máximo possível avanço de Corte			
Fator	Definição da característica		Nível 1	Nível 2	
C	Profundidade (P) mm	Para nível 1: valores recomendado pelo Fabricante da Pastilha, Para o Nível 2	0,65	1,3	
		Para nível 2: valores com 21% acima do recomendado pelo fabricante, valor máximo admitido pela ferramenta (Ângulo KAPR)			
Fator	Tipo Inserto/Ferramenta (TI)	Método	Nível 1	Nível 2	
D		Pastilha tipo Três Cantos 35°		TNGM 16 04 04R-K 4325	
		Ferramenta de suporte TIPO CABEÇA DE CORTE			TNGM160404R-UX T32500
		Aresta de corte reta			
Fator	Definição da característica		Nível 1	Nível 2	
E	Refrigeração (R) LUBRAX OP38	Para nível 1: o experimento foi realizado sob condições mínima recomendada Fluido, menor custo e impacto ambiental. Já para o Nível 2 o experimento foi realizado sob condições de uso abundante com o fluido refrigerante do tipo LUBRAX OP38 EM.	5% lubrificação	15% lubrificação	
		Para nível 2: valores com 15%			
Fator	Material	TRANSMISSION GEARS	Modelo	Nível 1	Nível 2
F	Material Ø45 x 132 mm (final)		1- Main shaft assy.	P2.1.Z.AN - Baixa liga (elementos de liga <=5%)	P2.3.Z.AN - Baixa liga (elementos de liga <=5%)
		Subgrupo de materiais		<=0,25% C	>0,55% C
		Processo de manufatura (peça Bruta)		laminado	Trefilado a frio
		Tratamento térmico		recozido	
		Força de corte específica, K <sub>c1</sub> (N/mm <sup>2</sup> )		175 HB	260 HB
m <sub>s</sub>		1700	2020	0,25	

Fonte: (autor 2021)

c) Arranjos Ortogonais de Taguchi


Com os parâmetros de entrada definidos e com variáveis respostas que serão otimizadas.

**Rugosidade Média (Ra) e OEE.**: A rugosidade da superfície (Ra) do Eixo EP é um critério importante em termos da qualidade, para o estudo foi considerada como sendo a mais importantes dos

parâmetros na usinagem do eixo EP visto que as demais medidas geométricas e suas tolerâncias serão avaliadas no quesito Qualidade do OEE.

Com a definição dos parâmetros, dependentes e independentes, escolheu-se a melhor configuração do arranjo ortogonal de Taguchi L16 de 16 experimentos com 15 fatores e 2 níveis. O método Taguchi L16 possui uma interação entre os fatores Ortogonais conforme vemos na Figura 6.

*Figura 6 - Arranjo de Taguchi L16*



Fonte: Gráfico linear L16 de Taguchi (autor 2021)

**3.4 OEE método de medição.**


Para efeito de medição do OEE foi considerado os elementos D = Disponibilidade, P = Produtividade e Q = Qualidade

Como o estudo pretende avaliar os efeitos das variáveis sobre a produtividade, foi considerado uma rigorosa avaliação dos tempos e avaliação da qualidade dos fatores de controle.

a) Realizações dos Ensaios

Para o experimento foi adotado disponibilizar 3 amostras para cada ensaio do experimento perfazendo um total de 48 amostras (16x3). Cada experimento foi considerado com o fluxo que segue na Figura 7.

*Figura 7 - Fluxo do ensaio*



Fonte: (autor 2021)

Para análise da qualidade levou-se em consideração o índice o desvio médio aritmético Ra ( $\mu\text{m}$ ) com parametro de Índice de Qualidade da Superfície.

Figura 8 - Índice de Qualidade da Superfície

Classe de rugosidade	Desvio Médio Aritmético Ra ( $\mu\text{m}$ )	Índice de qualidade da Superfície	
N7	0,5	100%	
	1,4	100%	
	1,6	100%	
N8	1,9	92%	
	2,7	84%	
	3,2	71%	
	3,7	63%	
	4,3	42%	
N9	4,8	26%	
	5,4	18%	
	5,9	10%	
	6,3	0%	
		scrap	

NOTA: APLICÁVEL NO EIXO EP  
Rugosidade < 1,6 Ponto ótimo

Fonte: (autor 2021)

#### 4. RESULTADOS

Através de análise dos dados obtidos foram realizadas análises que segue o roteiro:

- Análise gráfica dos dados,
- Análise das variâncias (ANOVA)
- Análise de Taguchi e ranqueamento dos dados
- Teste de Comparação de médias

As análises foram feitas utilizando o software MINITAB RELEASE 18 e apresentados em forma de tabela e gráficos.

A interpretação do valor-p é necessária para a compreensão deste trabalho uma vez que em cada umas das análises realizadas quando o valor-p de um determinado fator é menor que 0,05 (com uma confiança de 95%, valor este utilizado em todas as análises a seguir), interpreta-se que o efeito de tal fator possui significância, ou seja, quando p é menor que 0,05 o fator é considerado de influência com relação a variável resposta analisada.


Os gráficos que serão apresentados têm como objetivo confirmar a análise feita com o valor-p, observando-se a amplitude e inclinação das curvas presentes no gráfico.

Os fatores foram avaliados quando significativos através da ANOVA, escolhe-se o nível que apresenta o menor valor de rugosidade e de maior OEE, para se estabelecer análises futuras e direcionamentos mais profundos sobre custo x performance x qualidade.

#### 4.1 Análise da relação Ra vs OEE

Na figura.9 podemos observar que a relação do OEE com a Rugosidade apresenta um comportamento linear, pois quanto mais a Rugosidade aumenta o OEE diminui, mostrando que existe influência da Rugosidade, e observando os elementos do OEE separadamente Observamos que o elemento “Q”= qualidade é o que têm a maior influência.

Figura 9 - Gráfico de dispersão X;Y



Fonte: (autor 2021)


#### 4.2 Experimento Taguchi

Resumo do experimento

- Matriz de Taguchi  $L16(2^6)$
- Fatores: 6
- Ensaios: 16
- Colunas da matriz  $L16(2^{15})$ : 2 3 5 4 6 1

#### 4.3 Análise Taguchi: Ra (rugosidade) versos Fatores

Figura 10 - Gráfico Ranqueamento RA



Fonte: (autor 2021)

Na Figura 10 e apresentado a influência de cada fator que exerce sobre a variável resposta Rugosidade (Ra) em relação à média e possível observar a amplitude entre no nível Tipo de Inserto em comparação aos demais fatores. O fator Material mostra uma influência, mas não tão significativa quanto o tipo de inserto. No gráfico da Figura 10 quanto maior a amplitude, maior será o efeito dos fatores sobre a variável resposta.

Observando o gráfico da Figura 10 também podemos considerar que utilizar o tipo de inserto TN-R-UX temos uma grande chance de a rugosidade sair dos padrões desejados abaixo de 1,6 Ra, e podemos dizer que o material com dureza maior influência sendo que o Material P2.1.AN apresenta uma rugosidade melhor.

Figura 11 - Análise Variância - Ranqueamento RA

**Análise de Variância para Médias**

Fonte	GL	SQ Seq	SQ (A <sub>j</sub> )	QM (A <sub>j</sub> )	F	P
Velocidade de Corte (VC)	1	0,05695	0,05695	0,05695	5,81	0,250
Avanço da Ferramenta (f)	1	0,04133	0,04133	0,04133	4,22	0,288
Profundidade (P)	1	0,12625	0,12625	0,12625	12,88	0,173
Tipo de Inserto	1	5,72065	5,72065	5,72065	583,74	<b>0,026</b>
Refrigeração	1	0,11045	0,11045	0,11045	11,27	0,184
Material	1	0,34861	0,34861	0,34861	35,57	0,106
Erro de Resíduos	1	0,00980	0,00980	0,00980	0	
<b>Total</b>	<b>7</b>	<b>6,41405</b>				

**Tabela de Resposta para Médias**

Nível	Velocidade de Corte (VC)	Avanço da Ferramenta (f)	Profundidade (P)	Tipo de Inserto	Refrigeração	Material
1	2,561	2,404	2,602	1,631	2,594	2,268
2	2,392	2,548	2,351	3,322	2,359	2,685
Delta	0,169	0,144	0,251	1,691	0,235	0,417
Posto	5	6	3	1	4	2


Fonte: (autor 2021)

Observando a tabela ANOVA da Figura 11 podemos comprovar através da análise do *p-value* que Tipo de inserto é altamente significativo, seguido do Material, porém o material ainda não

exerce uma influência significativa pois o *p-value* ficou 0,106 e o valor é maior que nosso nível de significância que é 0,05, ou 5%.

#### 4.4 Análise Taguchi: OEE versus Fatores

Figura 12 - Gráfico Ranqueamento OEE



Fonte: (autor 2021)

Para a análise do efeito OEE, e seguindo a mesma análise realizada para a rugosidade, foi avaliado o gráfico de médias e podemos avaliar que o Tipo de Inserto teve a maior Influência, já era esperado visto que na análise do gráfico de dispersão Figura 9 pode ser observado a grande relação entre a Rugosidade versus OEE e em especial o elemento Qualidade.

Figura 13 - Análise Variância - Ranqueamento OEE

**Análise de Variância para Médias**

Fonte	GL	SQ Seq	SQ (A <sub>j</sub> )	QM (A <sub>j</sub> )	F	P
Velocidade de Corte (VC)	1	0,000323	0,000323	0,000323	5,09	0,266
Avanço da Ferramenta (f)	1	0,000197	0,000197	0,000197	3,10	0,329
Profundidade (P)	1	0,004687	0,004687	0,004687	73,83	<b>0,074</b>
Tipo de Inserto	1	0,116928	0,116928	0,116928	1841,79	<b>0,015</b>
Refrigeração	1	0,000560	0,000560	0,000560	8,82	0,207
Material	1	0,006695	0,006695	0,006695	105,45	<b>0,062</b>
Erro de Resíduos	1	0,000063	0,000063	0,000063		
<b>Total</b>	<b>7</b>	<b>0,129453</b>				

**Tabela de Resposta para Médias**

Nível	Velocidade de Corte (VC)	Avanço da Ferramenta (f)	Profundidade (P)	Tipo de Inserto	Refrigeração	Material
1	0,8205	0,8219	0,8027	0,9478	0,8185	0,8558
2	0,8332	0,8318	0,8511	0,7060	0,8352	0,7980
Delta	0,0127	0,0099	0,0484	0,2418	0,0167	0,0579
Posto	5	6	3	1	4	2

Fonte: (autor 2021)

Já na análise de ANOVA Figura 12 podemos observar que além da variável Tipo de Inserto as variáveis Profundidade de Material possuem um valor *p-value* muito próximo de 0,05, sendo um indicativo para possíveis investigações.

## 5. CONCLUSÃO

Vários estudos sobre fatores que influenciam a usinagem já foram desenvolvidos, porém neste estudo tivemos o objetivo de identificar estes fatores que influenciam substancialmente o processo de usinagem, que possuem inúmeras combinações para execução de um processo sustentável, podemos observar que o tipo de inserto influencia o processo de qualidade da rugosidade das peças usinada, porém temos que levar em consideração os custos envolvidos e pensar quais alternativas são mais viáveis.

Neste estudo por meio da fundamentação teórica, e experimental podemos verificar a importância em se tratar adequadamente a otimização de processos que tenham um caráter multivariado.

Foram apresentadas as etapas necessárias para a aplicação do método Taguchi, bem como a identificação de todos os parâmetros essenciais utilizados para observar os parâmetros ótimos, utilização da metodologia Taguchi mostra que quando organizados os fatores e realizando o experimento organizado e bem fundamentado podemos observar quais fatores mais influenciam no processo.

Porém este estudo teve um objetivo além de avaliar os parâmetros do processo de usinagem, mas também avaliar a produtividade em função dos parâmetros definidos, observar o OEE é uma forma de tentar trazer a reflexão que devemos considerar a otimização do processo, porém temos que garantir produtividade que é um requisito tão importante quanto a qualidade.

Esta relação de qualidade e Produtividade foi abordada neste estudo e a otimização conjunta deve ser o objetivo quando utilizar da metodologia para encontrar o ponto ótimo.

Ficou evidenciado que neste experimento os Elementos Disponibilidade e Produtividade não tiveram um desenho experimental bem delineado, sugerindo para trabalhos futuros, propor uma pesquisa mais profunda sobre o assunto otimização de múltiplas respostas em função da Produtividade.

## 6. REFERÊNCIAS

BALOGH, Z. *et al.* Reference Architecture for a Collaborative Predictive Platform for Smart Maintenance in Manufacturing. **IEEE 22nd International Conference on Intelligent Engineering Systems (INES)**, p. 000299-000304, 2018.

GUPTA, ; VARDHAN. Optimizing OEE, productivity and production cost for improving sales volume in an automobile industry through TPM: a case study. **International Journal of Production Research**, v. 54, n. 10, p. 2976-2988, 2016. ISSN: 00207543.

GUPTA, G.; VARDHAN, ; AL HAQUE, M. S. Study of success factors of TPM implementation in Indian industry towards operational excellence: An overview. **Conference of 5th International Conference on Industrial Engineering and Operations Management, IEOM**, p. 1-6, 2015.

PAREDES, R. S. C. **O MÉTODO TAGUCHI/PROJETO ROBUSTO**. PPGEM - UFPR. Curitiba, p. 22. 2021.

RAMLAN, R. *et al.* Quantification of machine performance through Overall Equipment Effectiveness. **2015 International Symposium on Technology Management and Emerging Technologies (ISTMET)**, p. 407-411, 2015.

SUCHARSKI, G. ; COSTA, P. B.; N'TCHALÁ, F. **APLICAÇÃO DO PLANEJAMENTO EXPERIMENTAL DE TAGUCHI NA OTIMIZAÇÃO DE PARÂMETROS DE PESQUISA**. PPGEM - UFPR. Curitiba, p. 29. 2021.

YUNIAWANT, D.; MOHAMAD, ; ITO,. OEE Measurement by Taguchi Method with Simulation. **Conference: International Symposium on Scheduling 2013 (ISS2013)**, Tokyo, v. No-13-202, p. 1A-1, 2013.