

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO**  
**MESTRADO EM ENGENHARIA DE PRODUÇÃO**

**FABIANE FLORENCIO DE SOUZA**

**BIG DATA ANALYTICS COMO FERRAMENTA DE ADAPTAÇÃO DO TOTAL  
QUALITY MANAGEMENT NA INDÚSTRIA 4.0, APLICADO A UMA EMPRESA  
MULTINACIONAL DO RAMO AUTOMOBILÍSTICO**

**DISSERTAÇÃO**

**PONTA GROSSA**

**2021**

**FABIANE FLORENCIO DE SOUZA**

**BIG DATA ANALYTICS COMO FERRAMENTA DE ADAPTAÇÃO DO TOTAL  
QUALITY MANAGEMENT NA INDÚSTRIA 4.0, APLICADO A UMA EMPRESA  
MULTINACIONAL DO RAMO AUTOMOBILÍSTICO**

**Big Data Analytics as a tool for adapting Total Quality Management in Industry  
4.0, applied to a multinational automotive company**

Dissertação apresentada como requisito para  
obtenção do título de Mestre em Engenharia de  
Produção da Universidade Tecnológica Federal do  
Paraná (UTFPR).

Orientador: Prof. Dra. Regina Negri Pagani

**PONTA GROSSA**

**2021**



[4.0 Internacional](https://creativecommons.org/licenses/by-nc-sa/4.0/)

Esta licença permite remixe, adaptação e criação a partir do trabalho, para fins não comerciais, desde que sejam atribuídos créditos ao(s) autor(es) e que licenciem as novas criações sob termos idênticos.

Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.



**Ministério da Educação**  
**Universidade Tecnológica Federal do Paraná**  
**Câmpus Ponta Grossa**



FABIANE FLORENCIO DE  
SOUZA

**BIG DATA ANALYTICS COMO FERRAMENTA DE ADAPTAÇÃO DO TOTAL  
QUALITY MANAGEMENT NA INDUSTRIA 4.0, APLICADO A UMA EMPRESA  
MULTINACIONAL DO RAMO AUTOMOBILÍSTICO**

Trabalho de pesquisa de mestrado apresentado como requisito para obtenção do título de Mestra Em Engenharia De Produção da Universidade Tecnológica Federal do Paraná (UTFPR). Área de concentração: Gestão Industrial.

Data de aprovação: 07 de Dezembro de 2020

Prof.a Regina Negri Pagani, Doutorado - Universidade  
Tecnológica Federal do Paraná Prof Gilberto Zammar,  
Doutorado - Universidade Tecnológica Federal do Paraná  
Prof Giles Cesar Balbinotti, Doutorado - Renault do Brasil  
Prof.a Helyane Bronoski Borges, Doutorado - Universidade  
Tecnológica Federal do Paraná Prof Joao Luiz Kovaleski,  
Doutorado - Universidade Tecnológica Federal do Paraná

Documento gerado pelo Sistema Acadêmico da UTFPR a partir dos dados da Ata de Defesa em 07/12/2020.

Dedico este trabalho à Deus, à minha  
família, e a todos os professores e  
orientadores que tive até aqui.

## AGRADECIMENTOS

Essa folha não teria espaço suficiente para agradecer a todas as pessoas que me ajudaram e me motivaram a finalizar essa dissertação, mesmo assim gostaria de registrar alguns agradecimentos em especial.

Primeiramente, por Deus ter me dado a oportunidade para o ingresso nesse programa de pós-graduação, e por todo o amor demonstrado em me dar saúde e força para enfrentar cada momento.

Agradeço aos meus pais que nunca me deixaram faltar nada do que fosse essencial para meu bem-estar e desenvolvimento, amo vocês!

Aos professores que me ajudaram a agregar os conhecimentos necessários para a construção dessa pesquisa durante toda a minha caminhada acadêmica.

A minha orientadora Prof. Dra. Regina Negri Pagani, que com muito comprometimento e carinho, dedicou seu tempo para me orientar em cada passo dessa pesquisa. Agradeço em especial por todas as palavras de incentivo que foram essenciais para que eu acreditasse em meu potencial.

Ao Sr. Thomas Wszolek e ao Dr. Giles Balbinotti, que me orientaram dentro da empresa para que eu pudesse fazer contatos, obter dados e agregar conhecimentos que serão úteis durante toda minha vida.

A Fundação Araucária, por promover parcerias com empresas parceiras e disponibilizar meios para que novas pesquisas possam ser desenvolvidas, firmando laços entre Universidades e Indústrias.

A Universidade Tecnológica Federal do Paraná, por prover os recursos e a estrutura com excelência em ensino, para que essa dissertação fosse construída.

E a todos aqueles que contribuíram de forma direta ou indireta para a realização deste trabalho.

É melhor conseguir sabedoria do que  
ouro; é melhor ter conhecimento  
do que prata.  
(Provérbios, 16:16)

## RESUMO

SOUZA, Fabiane Florencio de. **Big Data Analytics como ferramenta de adaptação do Total Quality Management na Indústria 4.0, aplicado a uma empresa multinacional do ramo automobilístico.** 2020. 149 f. Dissertação (Mestrado em Engenharia de Produção) - Universidade Tecnológica Federal do Paraná, Ponta Grossa, 2020.

A Gestão da Qualidade Total representa uma estratégia de gerenciamento que visa o desenvolvimento da consciência de qualidade em todos os processos organizacionais. Para isso, indicadores de qualidade são definidos e acompanhados, para que planos de ação sejam desenvolvidos, alinhando todos os setores para um mesmo objetivo. Esses indicadores são alimentados por um grande número de dados, provenientes das tecnologias que a Indústria 4.0 trouxe consigo nessa nova fase industrial. Ao reunir todos esses dados de variadas tecnologias, têm-se o que é conceituado como um problema da *Big Data*, que necessita da *Big Data Analysis* capazes de analisar e promover a visualização desses dados de forma simples para que tomadores de decisão possam trabalhar com eles. Essa situação destaca a necessidade de uma adequação quanto as formas de acompanhar a qualidade dentro do contexto industrial, portanto, essa pesquisa tem como objetivo adaptar a gestão e o acompanhamento dos indicadores de qualidade de defeitos de produção, às mudanças tecnológicas advindas da I4.0 desenvolvendo, dessa forma, um maior envolvimento entre qualidade e tecnologia. Para isso, foi realizada uma Revisão Sistemática de Literatura, por meio da metodologia *Methodi Ordinatio*, resultando em um portfólio de artigos com relevância científica, o qual será fonte das coletas de dados para análise de conteúdo, além disso uma pesquisa de campo foi realizada na empresa multinacional do ramo automobilística para que o problema pudesse ser avaliado e desenvolvida a metodologia para construção de uma plataforma on-line. A combinação dessas estratégias de pesquisa resultou na plataforma on-line e-TQM para o acompanhamento da Gestão da Qualidade Total, automatizando o processo de obtenção, análise e disponibilização dos indicadores de defeitos na produção, agregando conhecimento sobre as técnicas e tecnologias para análise de grandes quantidades de dados, além de evidenciar a relação entre Indústria 4.0, Gestão da Qualidade Total e *Big Data Analytics*.

**Palavras-chave:** Gestão da Qualidade Total. *Big Data*. *Big Data Analytics*. Plataforma on-line. Indústria 4.0. Indústria Automotiva.

## ABSTRACT

SOUZA, Fabiane Florencio de. **Big Data Analytics as a tool for adapting Total Quality Management in Industry 4.0, applied to a multinational automotive company.** 2020. 149 p. Dissertation (Mestrado em Engenharia de Produção) - Federal University of Technology – Paraná, Ponta Grossa, 2020.

Total Quality Management represents a management strategy that aims to develop quality awareness in all organizational processes. For that, quality indicators are defined and monitored, so that action plans are developed, aligning all sectors to the same objective. These indicators are fed by a large number of data, coming from the technologies that Industry 4.0 brought with it in this new industrial phase. By gathering all this data from various technologies, there is what is conceptualized as a problem of Big Data, which needs Big Data Analysis able to analyze and promote the visualization of this data in a simple way so that decision-makers can work with them. This situation highlights the need for an adaptation as to the ways of monitoring quality within the industrial context, therefore, this research aims to adapt the management and monitoring of quality indicators of production defects, to the technological changes arising from I4.0 thus developing a greater involvement between quality and technology. For this, a Systematic Literature Review was carried out, using the Methodi Ordinatio methodology, resulting in a portfolio of articles with scientific relevance, which will be the source of data collections for content analysis. Also, field research was carried out at a multinational company in the automotive industry so that the problem can be evaluated and the methodology developed for building an online platform. The combination of these research strategies resulted in the e-TQM online platform for monitoring Total Quality Management, automating the process of obtaining, analyzing, and making available defects in production indicators, adding knowledge about the techniques and technologies for analysis of large amounts of data, in addition to highlighting the relationship between Industry 4.0, Total Quality Management and Big Data Analytics.

**Keywords:** Total Quality Management. Big Data. Big Data Analytics. Online platform. Industry 4.0. Automotive industry.



## LISTA DE FIGURAS

Figura 1 – Conceitos relacionados a Engenharia de Produção .....	22
Figura 2 – Localização geográfica das unidades da empresa .....	23
Figura 3 – Estrutura do trabalho.....	24
Figura 4 – Era da Inspeção .....	27
Figura 5 – Era do Controle da Qualidade .....	28
Figura 6 - Era da Garantia da Qualidade .....	29
Figura 7 - Era do Controle Total da Qualidade.....	30
Figura 8 - Era da Gestão da Qualidade Total.....	31
Figura 9 – Evolução da qualidade e as fases da indústria .....	32
Figura 10 – Fases da industrialização.....	39
Figura 11 – Indústria 4.0 e Gestão da Qualidade Total integrados (traduzido e revisado).....	42
Figura 12 – Progressão dos sistemas de suporte a tomada de decisão .....	52
Figura 13 – Construção de um dashboard .....	58
Figura 14 - Metodologia para a revisão de literatura .....	64
Figura 15 – Etapas para a construção do portfólio de artigos científicos .....	69
Figura 16 – Etapas para realização da pesquisa de campo.....	70
Figura 17 – MVP da plataforma on-line e-TQM.....	72
Figura 18 - Etapas para o desenvolvimento da plataforma on-line .....	73
Figura 19 – Quantidade de artigos publicados por ano no eixo 1 .....	77
Figura 20 – Quantidade de artigos publicados por ano no eixo 2 .....	79
Figura 21 - Fontes de geração de dados .....	81
Figura 22 - Técnicas e tecnologias para aquisição de dados.....	82
Figura 23 - Técnicas e tecnologias para armazenamento e gerenciamento de dados .....	83
Figura 24 - Técnicas e tecnologias para processamento de dados .....	85
Figura 25 - Técnicas e tecnologias para recuperação de dados .....	87
Figura 26 - Técnicas e tecnologias para analisar dados .....	88
Figura 27 - Técnicas e tecnologias para analisar e visualizar dados .....	89
Figura 28 - Grupos de indicadores de qualidade da empresa.....	91
Figura 29 - Processo realizado para acompanhar os indicadores de defeitos .....	93
Figura 30 – Passos para a publicação do dashboard .....	96
Figura 31 - Filtros da plataforma e-TQM .....	99
Figura 32 - Gráfico D-in e D-off diário .....	100
Figura 33 - Gráfico D-in e D-off mensal.....	101

Figura 34 - Gráfico D-in e D-off por posto de trabalho .....	101
Figura 35 - Gráfico elemento + Incidente .....	102
Figura 36 - D-in e D-off por departamento .....	102
Figura 37 - D-in por UET .....	103
Figura 38- D-in por Posto .....	103
Figura 39 - Ilustração do processo de geração e exibição dos indicadores na linha de produção .....	106
Figura 40 - Transferência de Tecnologia entre Usinas.....	106
Figura 41 - Antes e depois da proposta da plataforma e-TQM .....	107
Figura 42 - Ganhos obtidos em dias de trabalho.....	108
Figura 43 – Pessoas e dados como conexão entre I4.0, TQM e BDA .....	111
Figura 44 - Panorama geral dessa pesquisa.....	115

## LISTA DE QUADROS

Quadro 1 - Relação dos indicadores de qualidade com os focos do TQM.....	35
Quadro 2 - Definições de Indústria 4.0.....	40
Quadro 3 - Definições da Big Data.....	45
Quadro 4 - Os Vs da Big Data.....	46
Quadro 5 - Definições da Big Data Analytics .....	53
Quadro 6 - Etapas dos procedimentos metodológicos.....	62
Quadro 7 - Descrição dos indicadores D-in e D-off.....	92
Quadro 8 - Principais desafios em relação aos indicadores de qualidade .....	95
Quadro 9 – Solução proposta para os principais desafios dos indicadores .....	110

## LISTA DE TABELAS

Tabela 1 – Resultados das buscas nas bases de dados .....	66
Tabela 2 – Procedimentos de filtragem.....	67
Tabela 3 – Quantidade de artigos publicados por país no eixo 1.....	78
Tabela 4 – Relação da representatividade dos periódicos do eixo 1 .....	78
Tabela 5 – Quantidade de artigos publicados por país no eixo 2.....	79
Tabela 6 – Periódicos com maior fator de impacto presente no eixo 2 .....	80
Tabela 7 – Portfólio de artigos ordenados resultantes do eixo 1.....	146
Tabela 8 – Portfólio de artigos ordenados resultantes do eixo 2.....	149

## LISTA DE ABREVIATURAS, SIGLAS E ACRÔNIMOS

ABEPRO	Associação Brasileira de Engenharia de Produção
APIs	<i>Application Programming Interface</i>
BD	<i>Big Data</i>
BDA	<i>Big Data Analytics</i>
CEP	Controle Estatístico de Processo
Ci	Número de citação
Fi	Fator de impacto
FMEA	<i>Failure Mode Effect Analysis</i>
GPS	<i>Global Position System</i>
GTT	Gestão de Transferência de Tecnologia
HDFS	<i>Hadoop Distributed File System</i>
I4.0	Indústria 4.0
IoT	<i>Internet of Things</i>
JCR	<i>Journal Citation Reports</i>
JIT	<i>Just-In-Time</i>
JUSE	<i>Japanese Union of Scientists and Engineers</i>
KPIs	<i>Key Performance Indicators</i>
LATAM	Latina América
MVP	<i>Minimum Viable Product</i>
NVA	<i>No value added</i>
OE	Objetivo Específico
OG	Objetivo Geral
PDCA	<i>Ciclo Plan, Do, Check and Action</i>
PPGEP	Programa de Pós-Graduação em Engenharia de Produção
QFD	<i>Quality Functional Deployment</i>
SJR	<i>Scientific Journal Rankings</i>
SNIP	<i>Source Normalized Impact per Paper</i>
SPC	<i>Statistical Process Control</i>
SQL	<i>Structured Query Language</i>
TPS	<i>Toyota Production System</i>

TQM	<i>Total Quality Management</i>
TT	Transferência de Tecnologia
UET	<i>Unités Élémentaires de Travail</i>

## SUMÁRIO

<b>1 INTRODUÇÃO</b> .....	<b>17</b>
1.1 PROBLEMA DE PESQUISA .....	18
1.2 OBJETIVOS .....	19
1.2.1 Objetivo Geral (OG) .....	19
1.2.2 Objetivos Específicos (OE) .....	19
1.3 JUSTIFICATIVA .....	20
1.4 INSERÇÃO NA ENGENHARIA DE PRODUÇÃO .....	21
1.5 DELIMITAÇÃO DA PESQUISA .....	23
1.6 ESTRUTURA DO TRABALHO .....	24
<b>2 REFERENCIAL TEÓRICO</b> .....	<b>26</b>
2.1 GESTÃO DA QUALIDADE TOTAL .....	26
2.1.1 Indicadores de Qualidade .....	34
2.2 TRANSFERÊNCIA DE TECNOLOGIA .....	37
2.3 INDÚSTRIA 4.0 .....	38
2.3.1 Integrando a I4.0 a TQM .....	41
2.3.2 Integração de Ferramentas .....	43
2.4 BIG DATA .....	44
2.4.1 Características da Big Data .....	46
2.4.2 Categorias de Processamento .....	50
2.4.3 Big Data Analytics .....	52
2.5 PLATAFORMAS ON-LINE .....	55
2.5.1 Dashboard .....	57
2.6 CONSIDERAÇÕES SOBRE A SEÇÃO .....	58
<b>3 METODOLOGIA</b> .....	<b>60</b>
3.1 CARACTERIZAÇÃO DA PESQUISA .....	60
3.2 ORGANIZAÇÃO DA PESQUISA .....	61
3.3 ELABORAÇÃO DA REVISÃO SISTEMÁTICA DE LITERATURA .....	63
3.3.1 Análise Bibliométrica .....	69
3.3.2 Análise de Conteúdo .....	70
3.4 PESQUISA DE CAMPO .....	70
3.4.1 Análise das Informações Coletadas na Pesquisa de Campo .....	71
3.5 METODOLOGIA DO DESENVOLVIMENTO DA PLATAFORMA ON-LINE .....	72
3.5.1 Análise dos Resultados Alcançados .....	74
3.6 CONSIDERAÇÕES SOBRE A SEÇÃO .....	74

<b>4 ANÁLISE E DISCUSSÃO DOS RESULTADOS</b> .....	<b>76</b>
4.1 RESULTADOS DA REVISÃO DE LITERATURA.....	76
4.1.1 Resultados da Análise Bibliométrica .....	76
4.1.2 BIG DATA ANALYTICS E SUAS TECNOLOGIAS .....	80
4.1.2.1 Geração de dados.....	80
4.1.2.2 Aquisição de dados.....	82
4.1.2.3 Armazenamento e gerenciamento de dados .....	83
4.1.2.4 Processamento de dados .....	85
4.1.2.5 Recuperação de dados .....	86
4.1.2.6 Análise e visualização de dados .....	87
4.2 PESQUISA DE CAMPO NA EMPRESA MULTINACIONAL DO RAMO AUTOMOBILÍSTICO .....	89
4.2.1 Indicadores de Qualidade da Empresa .....	90
4.3 DESENVOLVIMENTO DA PLATAFORMA E-TQM.....	95
4.3.1 Ganhos do Projeto .....	107
4.3.1.1 Ganhos quantitativos .....	108
4.3.1.2 Ganhos qualitativos.....	109
4.3.2 Big Data Analytics na Integração entre I4.0 e TQM .....	111
4.4 CONSIDERAÇÕES SOBRE A SEÇÃO .....	115
<b>5 CONSIDERAÇÕES FINAIS</b> .....	<b>117</b>
5.1 ANÁLISE DOS OBJETIVOS .....	117
5.2 CONSIDERAÇÕES GERAIS .....	119
5.3 SUGESTÕES PARA TRABALHOS FUTUROS .....	121
<b>REFERÊNCIAS</b> .....	<b>123</b>



## 1 INTRODUÇÃO

A *Total Quality Management* (TQM), traduzido para o português como Gestão da Qualidade Total, é um sistema de gerenciamento que se concentra na melhoria contínua por meio de ferramentas e técnicas. Representa uma combinação de ferramentas de qualidade e gestão, que tem como objetivo o crescimento da organização e a redução de perdas por desperdício (KUMAR; SHANMUGANATHAN, 2019).

Em função de suas características, possui potencial para aumentar o desempenho de organizações (DEMING, 2018; ZWAIN *et al.*, 2017), além de conduzir a um desenvolvimento de produtos e serviços com qualidade, custos mínimos e entregas pontuais (QASRAWI *et al.*, 2017).

Para mensurar todos os fatores que afetam o ambiente organizacional, são utilizados os indicadores de qualidade ou performance, conhecidos também como *Key Performance Indicators* (KPIs). Esses indicadores são quantificáveis e capazes de fornecer aos gestores diversos dados, sendo eles financeiros ou não, com a finalidade de avaliar o desempenho de uma organização e acompanhar o progresso dos objetivos predeterminados em um planejamento (SABBAGH *et al.*, 2018).

Os indicadores desempenham um papel essencial no rastreamento do progresso da organização e servem como base para tomada de decisões importantes e comparações internas e externas (SARI, 2015).

Nos últimos anos a quantidade de dados disponíveis para serem acompanhados pelos indicadores aumentou consideravelmente, sendo essa imensa quantidade de dados conhecida como um problema da *Big Data* (BD), em função de os dados serem gerados em alta velocidade, necessitando ser analisados o mais próximo possível do tempo real (WASIM *et al.*, 2019).

Por isso, as ferramentas da *Big Data Analytics* (BDA) começaram a ser empregadas com o intuito de se extrair informações dessa expressiva quantidade de dados (ACETO; PERSICO; PESCAPE, 2019), beneficiando as organizações com uma vantagem competitiva aprimorada, resultando em decisões mais corretas e oportunas (BAG *et al.*, 2020). A BD e a BDA são termos relacionados à Indústria 4.0 (I4.0), e representam muito bem essa nova fase industrial, que é baseada em dados e na inovação tecnológica (GHOBAKHLOO, 2018).

Nesse contexto, a Indústria 4.0 (I4.0) representa um grande desafio para que os diversos setores da indústria se adaptem a todas as mudanças propostas, não sendo diferente para a área da qualidade (DURANA *et al.*, 2019), relacionando-se também a necessidade de uma maior integração entre todas as áreas da indústria, abrangendo o envolvimento das pessoas em todo o processo (BAGOZI *et al.*, 2019). Assim, surge a problemática deste estudo definido pelo problema de pesquisa.

## 1.1 PROBLEMA DE PESQUISA

A I4.0 promoveu a inserção de diversas ferramentas tecnológicas ao contexto industrial, como sensores, robôs e Inteligência Artificial (IA), com o objetivo de automatizar, controlar e acompanhar processos, movendo diferentes setores da indústria a se adequarem a essa nova fase. Dentre esses setores, destaca-se o setor da gestão da qualidade, que pode adequar-se a essas mudanças para explorar os recursos disponíveis e aprimorar a forma como a qualidade é gerenciada diante da grande quantidade de dados gerados por diferentes tecnologias.

Para que esses dados sejam traduzidos em informações úteis para o acompanhamento da TQM, análises precisam ser realizadas, visando proporcionar visualizações gráficas para um melhor entendimento da situação por parte dos tomadores de decisão.

Entretanto, no caso da empresa multinacional do ramo automobilístico, objeto desse estudo, foi observado que a análise dos indicadores de defeitos na produção é realizada manualmente pelos supervisores de produção, que não possuem uma plataforma adequada para trabalhar com esses dados.

Dessa forma, os supervisores de produção precisam acessar a base de dados em que os defeitos de produção se encontram e extraí-los, em seguida, esses dados são inseridos em uma planilha eletrônica e os gráficos e tabelas são elaborados para auxiliarem no desenvolvimento do plano de ação semanal, que promove ações para evitar que os defeitos identificados continuem a ocorrer nas próximas semanas.

Todo esse processo, acarreta uma série de dificuldades, como: trabalho repetitivo, falta de atualização diária dos dados, imprecisão na interpretação dos dados, falta de padronização de gráficos e análises e imprecisão na priorização das ações corretivas, entre outros fatores.

Essa problemática pode ainda representar o desafio de outras indústrias, devido a I4.0 ser caracterizada como uma nova fase que ainda se encontra em desenvolvimento, desta forma, surge a pergunta-problema desta pesquisa: *Como adaptar a gestão e o acompanhamento dos indicadores de qualidade, às mudanças da I4.0, desenvolvendo um maior envolvimento entre qualidade e tecnologia?* Neste cenário erigem-se os objetivos desta pesquisa.

## 1.2 OBJETIVOS

### 1.2.1 *Objetivo Geral (OG)*

Propor uma forma de adaptar a gestão e o acompanhamento dos indicadores de qualidade de uma empresa multinacional automobilística, às mudanças tecnológicas advindas da Indústria 4.0 (I4.0).

### 1.2.2 *Objetivos Específicos (OE)*

- OE1: Realizar um levantamento dos procedimentos, técnicas e ferramentas de manipulação da *Big Data*;
- OE2: Compreender como são analisados e disponibilizados os indicadores TQM utilizados pela indústria automobilística, objeto deste estudo, para o acompanhamento dos defeitos na produção;
- OE3: Desenvolver uma plataforma on-line para gerir e acompanhar os indicadores de defeitos na produção da empresa automobilística.

### 1.3 JUSTIFICATIVA

A relação entre gerenciamento de qualidade e desempenho da organização é alvo de estudos desde o início dos anos 80 e seus resultados mostram que gerenciar a qualidade influencia positivamente na performance organizacional (SABBAGH *et al.*, 2018).

Inserido nesse cenário encontram-se os indicadores de qualidade, que possuem muita notoriedade, visto que a partir deles são realizados os planejamentos para futuras tomadas de decisões, bem como o acompanhamento de metas estipuladas.

A possibilidade de estudar indicadores reais de uma empresa multinacional do ramo automobilístico, integrando a teoria e a prática, apresenta uma grande oportunidade, e constitui o conceito nomeado na Educação 4.0 como *learning-by-doing* (HARIHARASUDAN; KOT, 2018), que visa obter conhecimento e compreensão por meio da aplicação prática da teoria.

Esse trabalho se justifica devido à necessidade de adequar a gestão da qualidade às mudanças ocasionadas pelas tecnologias da I4.0. Com essa adequação, tarefas repetitivas e que não agregam valor, passarão a serem feitas de forma automática, permitindo que atividades mais relevantes possam ser realizadas, alcançando assim, maior qualidade de tempo no ambiente de trabalho.

Além de propor uma solução para um problema real que, após concluído e validado, poderá ser objeto de Transferência de Tecnologia (TT) dentro da organização, esse trabalho também contribui com a academia, já que a parte teórica reúne informações relevantes sobre tratamento da BD, técnicas da BDA para manipulação, disponibilização e visualização desses dados, contribuindo para o aumento do conhecimento sobre o tema no ambiente acadêmico. Além disso, a maior contribuição teórica é a evidenciar o relacionamento entre I4.0, TQM e BDA, dentro do contexto industrial. Portanto, esta pesquisa se justifica pelas seguintes contribuições:

- a) Contribuição teórico científica: Estudos anteriores abordaram as

relações entre o a I4.0 e a qualidade, como os de Durana *et al.*, (2019), Sader, Husti e Daróczy (2019), Asif (2020), Goecksa *et al.*, (2020) e Yadav *et al.*, (2020), entretanto, ainda é escassa a literatura que considere esse relacionamento, com a finalidade de adequar a TQM ao novo cenário industrial, baseando-se em um problema real. Sendo assim, este trabalho contribui preenchendo uma lacuna teórico-científica existente no entrelaçar destes temas. De igual forma, também contribui, reunindo ferramentas para manipular BD, bem como técnicas da BDA.

b) Contribuição com a sociedade: Com o uso de ferramentas corretas o trabalho de manipulação de grande quantidade de dados torna-se menos custoso e cansativo para os colaboradores da indústria. Por consequência, é possível aumentar o tempo produtivo e diminuir a execução de trabalhos repetitivos e tediosos.

c) Contribuição com inovação tecnológica na indústria: Essa pesquisa contribui para uma maior integração no cenário industrial por meio de uma plataforma on-line que disponibiliza dados de defeitos de produção em apenas um ambiente, caminhando alguns passos em direção a um dos objetivos da I4.0, o de conexão total da organização.

#### 1.4 INSERÇÃO NA ENGENHARIA DE PRODUÇÃO

De acordo com a Associação Brasileira de Engenharia de Produção (ABEPRO) (2020), é uma competência da Engenharia de Produção “o projeto, a implantação, a operação, a melhoria e a manutenção de sistemas produtivos integrados de bens e serviços, envolvendo homens, materiais, tecnologia, informação e energia”. Para produzir, é necessário utilizar o conhecimento científico e tecnológico, mas mais do que isso, é preciso integrar fatores de diversas naturezas, com atenção para critérios de qualidade, eficiência e custos, para citar alguns deles.

Todos esses fatores, quando tratados com profundidade e de forma integrada, representam elevação na competitividade de um país (ABEPRO, 2020).

Sendo assim, a integração é um conceito notado na Engenharia de Produção para que um bem e/ou serviço possam ser produzidos.

Levando isso em consideração, esse trabalho busca integrar diferentes conceitos relacionados a Engenharia, conforme demonstrado na Figura 1, com a finalidade de adequar a forma de gestão de indicadores de qualidade às mudanças tecnológicas promovidas pela I4.0, aplicando-o em uma situação real, como mostrado no estudo de caso, na Seção 4, que poderá servir como fonte de estudos futuros sobre esses temas, abordados neste trabalho.

**Figura 1 – Conceitos relacionados a Engenharia de Produção**



Fonte: Elaborado pela autora (2020)

Este trabalho está diretamente relacionado à linha de pesquisa do Programa de Pós-Graduação em Engenharia de Produção (PPGEP), que é Gestão Industrial, bem como também voltado para a linha de Pesquisa do Grupo de Pesquisa Gestão da Transferência de Tecnologia, ao qual a autora está vinculada.

## 1.5 DELIMITAÇÃO DA PESQUISA

A pesquisa de campo foi realizada presencialmente na empresa multinacional do ramo automobilístico localizada em São José dos Pinhais, no Estado do Paraná, durante o período de novembro de 2019 a novembro de 2020, com o acompanhamento de um gestor da empresa. Nesse período, foi possível ter acesso aos dados dos indicadores de qualidade de defeitos na produção, das quatro unidades da empresa na América Latina, que estão localizadas nos seguintes países: Argentina, Brasil, Chile e Colômbia, conforme demonstra a Figura 2.

**Figura 2 – Localização geográfica das unidades da empresa**



Fonte: Dados da Empresa (2020)

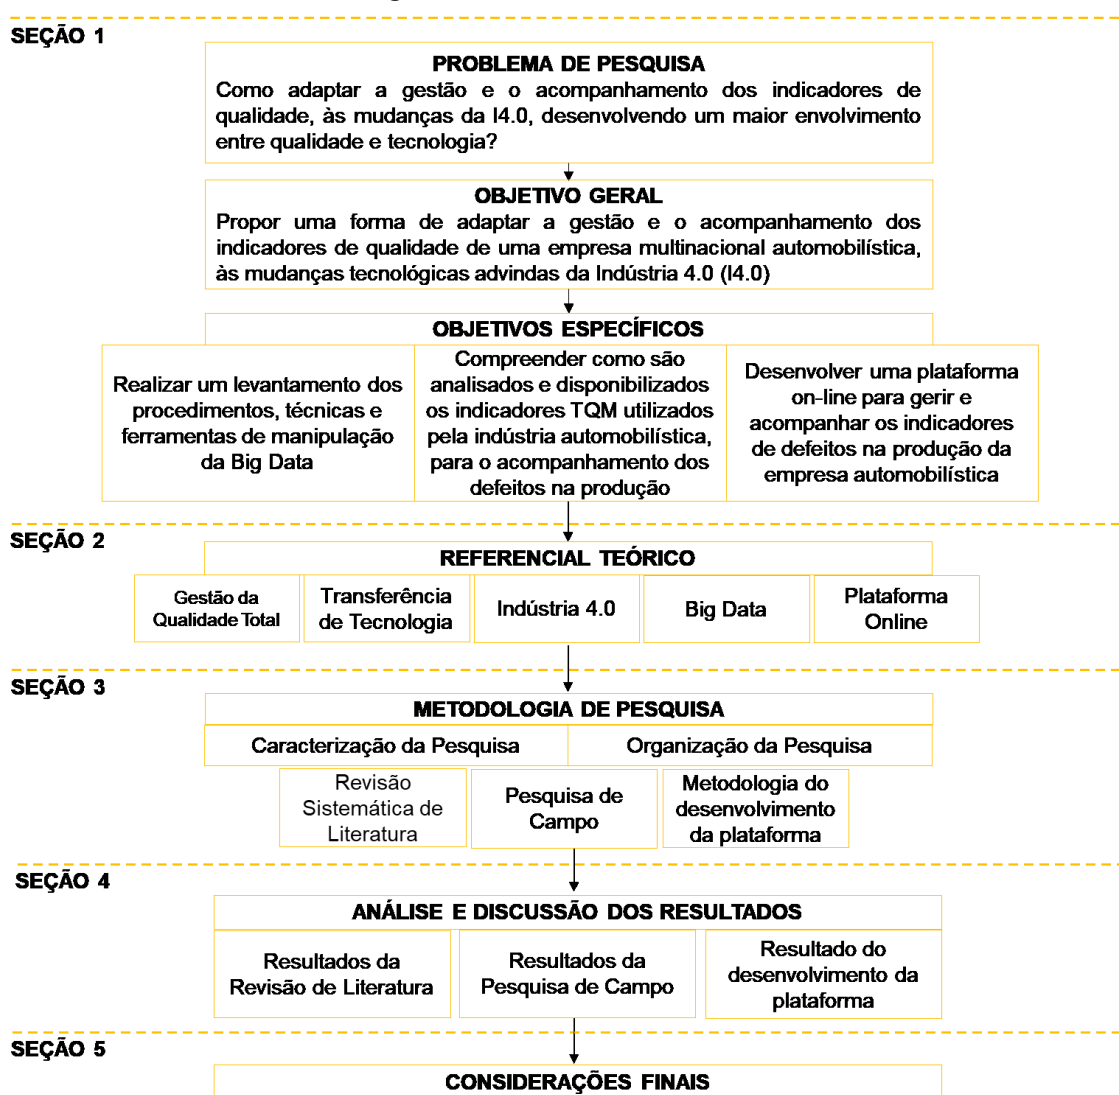
Cada unidade pode ter uma ou mais usinas, sendo que cada usina possui um foco quanto a produção do veículo. O Brasil, país em que o projeto piloto da

plataforma on-line será desenvolvido e testado, contempla 3 usinas, sendo uma de produção do motor, uma de produção da carroceria e uma de montagem do veículo.

## 1.6 ESTRUTURA DO TRABALHO

Este estudo está organizado em seis seções, conforme ilustra Figura 3, em que é possível visualizar a organização e estrutura do trabalho de forma completa.

**Figura 3 – Estrutura do trabalho**



Fonte: Elaborado pela autora (2020)



Esta Seção 1 faz a Introdução ao estudo, com uma breve contextualização do problema de pesquisa, os objetivos gerais e específicos, a justificativa para a construção do trabalho, sua inserção na Engenharia de Produção, a delimitação da pesquisa e, por fim, a estrutura do trabalho.

Na Seção 2, o Referencial Teórico é exposto, abrangendo os temas principais da pesquisa, sendo eles: Gestão da Qualidade Total, Transferência de Tecnologia, Indústria 4.0, *Big Data* e Plataformas On-line.

A Metodologia é descrita na Seção 3, demonstrando as etapas necessárias para o desenvolvimento da pesquisa, bem como a caracterização e organização da mesma, seguida da metodologia do estudo de caso e da metodologia para construção da plataforma on-line.

A Seção 4 discorre sobre a Análise e Discussão dos Resultados. Por fim, a Seção 5 apresenta as Considerações Finais e as sugestões para abordagens futuras.

## 2 REFERENCIAL TEÓRICO

A construção do referencial teórico dessa pesquisa tem como intuito abordar definições importantes que são mencionadas no decorrer do trabalho. O conceito de Gestão da Qualidade Total (TQM) é discutido juntamente com os indicadores de qualidade envolvidos nesse contexto. Como se trata de um dos temas centrais do trabalho, sua fundamentação é essencial para a construção da pesquisa. Seu vínculo com a Transferência de Tecnologia (TT) é apresentada em seguida.

A Indústria 4.0 (I4.0) foi o tema abordado na segunda subseção, juntamente com o conceito de integração de ferramentas. Essa temática deixa explícita a necessidade de maior envolvimento entre qualidade e tecnologias buscada pela I4.0 no contexto industrial, o que vem de encontro com o objetivo deste trabalho.

Em seguida, o conceito da *Big Data (BD)* e *Big Data Analytics (BDA)* são explorados para maior entendimento, além de explicitar como a grande quantidade de dados está relacionada aos assuntos da I4.0 e ao mesmo tempo, faz parte também da gestão da qualidade.

Por fim, uma abordagem teórica sobre Plataformas On-line e *dashboards* é apresentada, descrevendo suas funções dentro do cenário apresentado nesse trabalho. Sendo assim, a união de todos esses tópicos embasa o conteúdo para o alcance do Objetivo Geral dessa pesquisa.

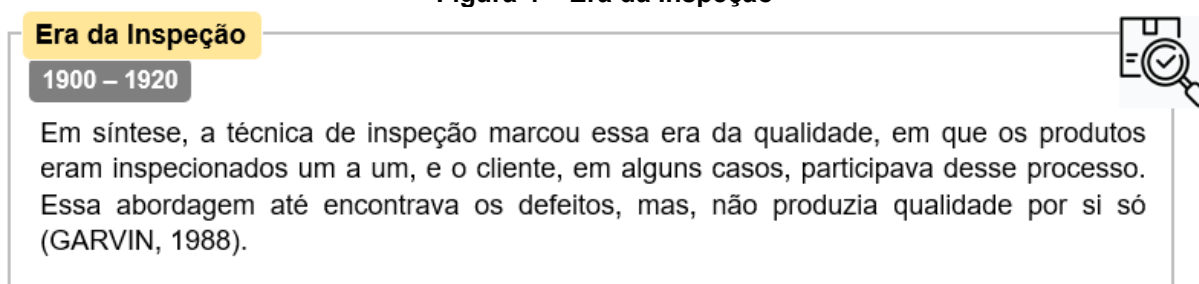
### 2.1 GESTÃO DA QUALIDADE TOTAL

A Qualidade tem sido um tema extensivamente abordado na literatura e, portanto, muitos autores buscaram defini-la. Feigenbaum (1961) postula que a qualidade não significa somente “melhor”, mas “o melhor para o uso e para o preço de venda”, enquanto Crosby (1984) considera que a qualidade deve ser definida como a característica de conformidade com os requisitos. Juran (1988) ressalta que qualidade é “adequação ao uso”, reconhecendo que um produto ou serviço deve ser

produzido tendo em mente as necessidades dos clientes.

Ao longo da história, essas definições se tornaram cada vez mais abrangentes e as Eras da Qualidade foram incorporadas ao tema (HAMID *et al.*, 2019). Mas, antes de discorrer sobre o conceito mais atual de qualidade, a TQM, uma contextualização histórica do surgimento e evolução do tema será apresentado. A Era que inaugurou essa linha do tempo foi a da Inspeção, descrita na Figura 4.

**Figura 4 – Era da Inspeção**



**Fonte: Elaborado pela autora (2020)**

Em 1900, Frederick Winslow Taylor, conhecido como o pai da Administração científica, enfatizou a importância da inspeção de qualidade nas indústrias, procedimento que ficou conhecido como a primeira era da qualidade ou era da inspeção da qualidade, iniciando assim, os primeiros estudos sobre a gestão da qualidade industrial, com foco principalmente no produto final (FOSTER, 2001; GARVIN, 1988).

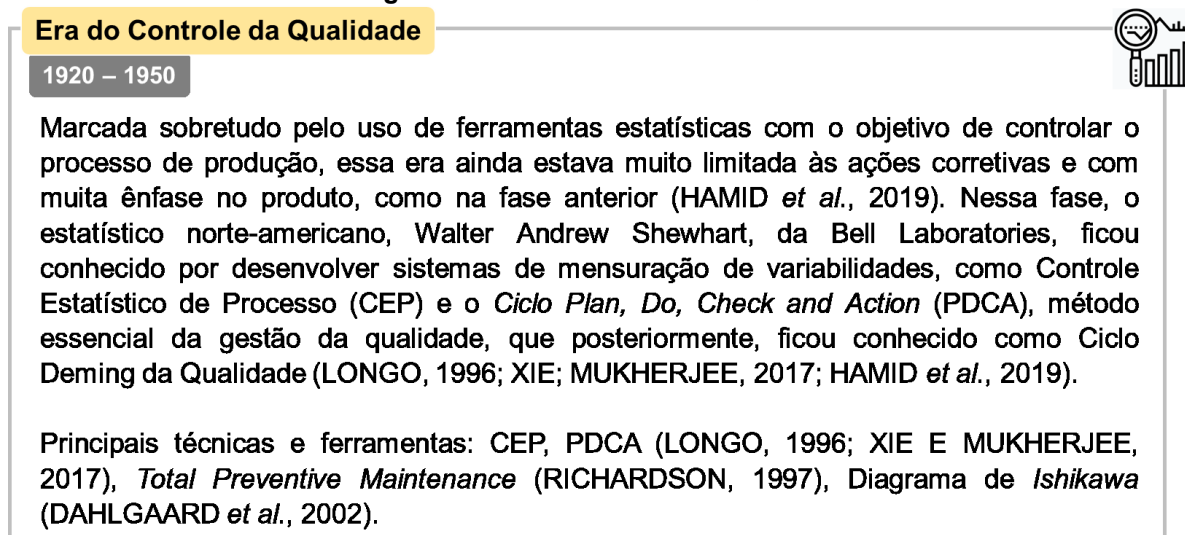
O enfoque da gestão estava na especialização do trabalho, ou seja, cada colaborador tem sua própria tarefa definida. Esse princípio pode ser notado quando Henry Ford introduziu a separação de tarefas e a produção em massa na indústria de automóveis Ford Motor Company (HAMID *et al.*, 2019).

Henry Ford contribuiu muito para a melhoria da qualidade na produção em massa com o *Just-In-Time*, sistema que tem como objetivo produzir a quantidade exata de um produto, de forma rápida, com o mínimo de estoque e sem comprometer a qualidade final (TOMAC; RADONJA; BONATO, 2019).

O tema, continuou a ser estudado ao longo dos anos, tornando-se um assunto de permanente pesquisa em todo o mundo (ONDRA; TUČEK; RAJNOHA, 2018; GUNASEKARAN; SUBRAMANIAN; NGAI, 2019). E por volta do ano de 1920,

iniciou-se uma segunda fase, chamada de Era do Controle Estatístico ou Era do Controle de Qualidade, resumida na Figura 5.

Figura 5 – Era do Controle da Qualidade



Fonte: Elaborado pela autora (2020)

Em 1938, o estatístico, William Edwards Deming, publicou um manual sobre a qualidade, titulado: *The Quality Improvement Handbook*, disseminando o ciclo *Plan, Do, Check and Action* (PDCA) de Walter Andrew Shewhart, que mais tarde, no ano de 1951, tornou-se um dos sistemas mais abrangentes para medição de padrões de qualidade desenvolvido durante esse período (HAMID *et al.*, 2019).

Os 14 pontos propostos por William Edwards Deming sobre gerenciamento de qualidade, ou o modelo de Deming de gerenciamento de qualidade, um conceito central na implementação do gerenciamento de qualidade total, representam um conjunto de práticas de gerenciamento para ajudar as empresas a aumentar sua qualidade e produtividade (ASQa, 2020).


Enquanto isso, no Japão, Kaoru Ishikawa desenvolveu o Diagrama de *Ishikawa* ou Diagrama de Causa e Efeito, como uma ferramenta de solução de problemas de gerenciamento em 1943 (DAHLGAARD-PARK *et al.*, 2012; ISHIKAWA, 1985), que faz parte das sete ferramentas da qualidade, juntamente com o Gráfico de Pareto, Histogramas, Folhas de Verificação, Gráficos de dispersão, Fluxogramas e as Cartas de Controle (ISHIKAWA, 1985; ASQb, 2020).

Portanto, essa Era ficou conhecida pela verificação por amostragem realizada por departamentos especializados, que enfatizavam a busca por defeitos depois do produto concluído (GARVIN, 1988). Por volta de era 1950, começava a Era da Garantia da Qualidade, conforme Figura 6.

Figura 6 - Era da Garantia da Qualidade

**Era da Garantia da Qualidade**

1950 – 1980



Joseph Moses Juran é considerado um dos grandes pensadores da revolução da qualidade no Japão, durante essa era, onde realizou diversas conferências e consultorias a partir da década de 50. Joseph Moses Juran aponta em seus estudos e pesquisas que o gerenciamento para a qualidade envolve três processos gerenciais básicos: Planejamento da Qualidade, Controle da Qualidade e Melhoria da Qualidade, conhecidas como a Trilogia de Juran (TEJANINGRUM, 2019).

Principais técnicas e ferramentas: *Failure Mode Effect Analysis* (FMEA) (GOWER, 1990), *Statistical Process Control* (SPC) (GARVIN, 1988), (RICHARDSON, 1997), Kaizen (IMAI, 1986; DAHLGAARD *et al.*, 2002), Kanban (GOWER, 1990), Jidoka (DAHLGAARD *et al.*, 2002), Just-In-Time (JIT) (GOWER, 1990).

Fonte: Elaborado pela autora (2020)

Segundo Ishikawa (1985), garantir a qualidade do produto, é um meio para que o cliente possa comprá-lo com confiança e usá-lo por um longo período com satisfação. Enquanto que para Dale (2015), a garantia da qualidade é um sistema baseado em prevenção, que por consequência melhora a qualidade do produto e do serviço e aumenta a produtividade da organização, colocando a ênfase no design do produto, serviço e processo.

Nessa fase é notado que o foco do gerenciamento da qualidade mudou do produto para processo (HAMID *et al.*, 2019), indicando uma maior abrangência do conceito de qualidade. Em seguida teve início a era do Controle da Qualidade Total, representada na Figura 7, caracterizada pelo controle sistemático do gerenciamento de qualidade. Foi então que o foco mudou do processo para o sistema, dessa forma, os limites da qualidade se expandiram e atingiram todo o processo produtivo (HAMID *et al.*, 2019).

Figura 7 - Era do Controle Total da Qualidade

**Era do Controle Total da Qualidade**

1960 – 1990



Feigenbaum, observou que o controle total da qualidade se tornou um sistema eficaz para desenvolver a qualidade em todos os processos industriais, de maneira econômica e com satisfação totalmente do cliente (FEIGENBAUM, 1961).

Principais técnicas e ferramentas: *Total Quality Control* (FEIGENBAUM, 1961), Diagrama de Ishikawa (ISHIKAWA, 1985), *Toyota Production System* (TPS) (WOMACK et al., 1990), *Quality Functional Deployment* (QFD) (GARVIN, 1988; WORLD BANK, 2000), Poka Yoke (SHIMBUN, 1988) e *Crosby Zero Defects* e *The Absolutes* (CROSBY, 1984).

Fonte: Elaborado pela autora (2020)

Feigenbaum publicou o livro *Total Quality Control*, em 1961, em que defendia uma abordagem total da qualidade, exigindo o envolvimento de todas as funções, não apenas de fabricação, no processo de controle da qualidade (HAMID et al., 2015).

Seguindo esse pensamento, em 1960, Philip Bayard Crosby idealizou o conceito de Defeitos Zero, e em seguida, criou a lista com os fundamentos da gestão da qualidade, que ele chama de "Os Absolutos".

Essa Era buscou controlar o processo produtivo e integrar toda a empresa, o que se mostrou diferente das demais Eras, pois não focava somente no defeito no produto final, mas na possibilidade de evitar que isso ocorresse (GARVIN, 1988).

Por fim, a atual Era da qualidade, resumida na Figura 8, tem como característica o gerenciamento da qualidade total, que julga ser essencial a cooperação de todos em uma organização para produzir produtos e serviços de valor, que atendam e superem as necessidades e expectativas dos clientes (DALE, 2015).


Figura 8 - Era da Gestão da Qualidade Total

**Era da Gestão da Qualidade Total**

1980 – Hoje

A era da TQM é a primeira a abranger as pessoas como parte essencial do processo, diferente das demais eras, essa busca a excelência dos negócios por meio da sincronia entre todas as pessoas da organização (HAMID *et al.*, 2019). Com o início da era da digitalização, a TQM está se integrando à I4.0, na qual o envolvimento com a tecnologia avança em várias áreas que, em conjunto, permitem inovação, novos insights, conectividade entre pessoas e entre pessoas e máquinas (JACOB, 2017).

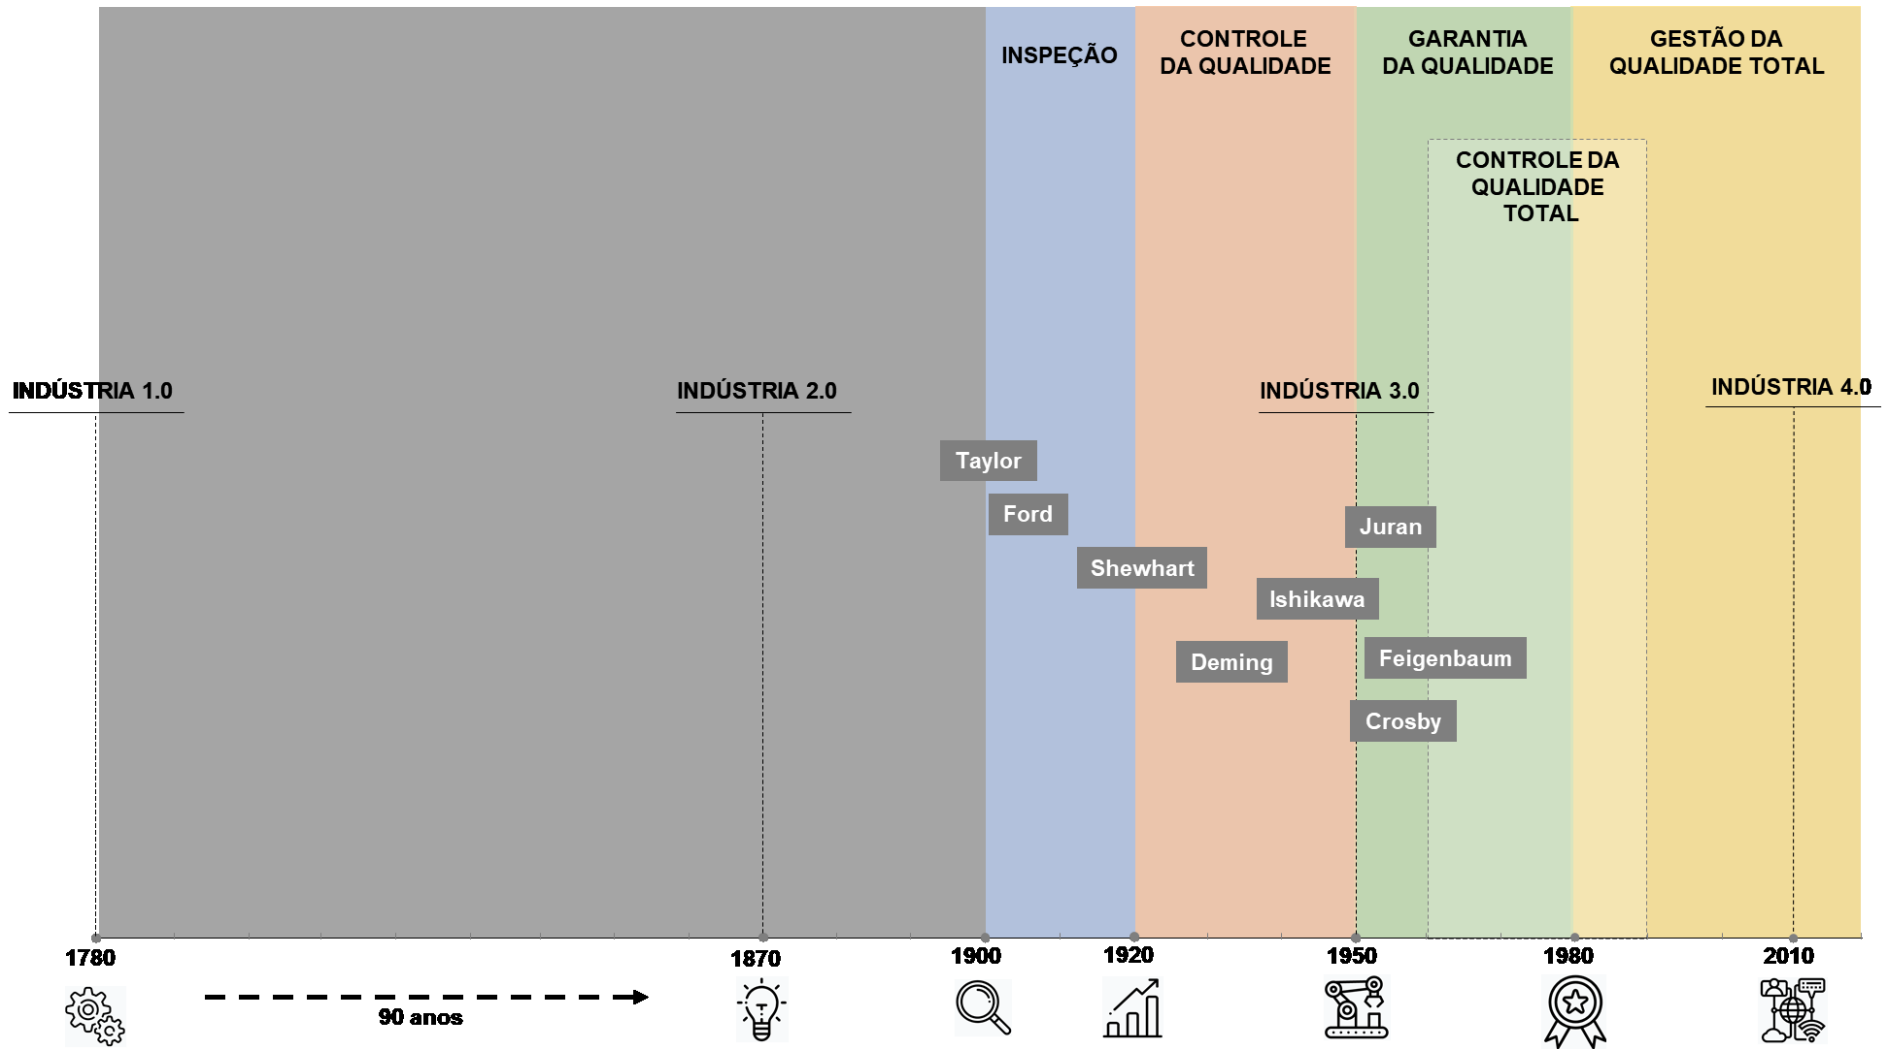
Principais técnicas e ferramentas: *Total Quality Management Philosophy* (FOSTER, 2001), *5S* (IMAI, 1986), *14 Points* (CROSBY, 1984), *Lean Manufacturing* (WOMACK *et al.*, 1990), *Six Sigma* (ECKES, 2005), *Business Excellence Model* (DAHLGAARD *et al.*, 2002), *Smart Environment for Quality Management* (JACOB, 2017; LEE *et al.*, 2014; VIJAYKUMAR *et al.*, 2015).



Fonte: Elaborado pela autora (2020)

Para ter uma visão geral dessa evolução, a Figura 9, apresenta uma linha do tempo da qualidade, desde o seu início até a Era da TQM, com a inserção das fases industriais em seu cenário, bem como os principais autores relacionados a qualidade.

Figura 9 – Evolução da qualidade e as fases da indústria



Fonte: Elaborado pela autora (2020)



A Era atual da Qualidade visa integrar todas as funções de uma organização, com a finalidade de alcançar a melhoria contínua em serviços, bens e produtos, e seus três princípios mais enfatizados, são: melhoria contínua, envolvimento entre os colaboradores e satisfação do cliente, envolvendo ainda o design de processos, produtos e serviços, relacionamento com fornecedores e *benchmarking* (BEHESHTI; LOLLAR, 2003; BOULTER; BENDELL; DAHLGAARD *et al.*, 2013; SADIKOGLU; ZEHIR, 2010; DEMING, 2018).

Compreende três principais componentes: valores, ferramentas e metodologias, cujo objetivo é aumentar a satisfação do cliente interno e externo usando uma quantidade reduzida de recursos. E possui como ferramentas as matrizes ou diagramas específicos e metodologias que consistem em uma sequência de atividades (KLEFSJÖ *et al.*, 2008).

Portanto, sendo considerado como um sistema, ferramenta, estratégia de negócio ou filosofia (HACKMAN; WAGEMAN, 1995; REED; LEMAK; MONTGOMERY, 1996; DAHLGAARD; DAHLGAARD-PARK, 2006; DEMING, 2018), a TQM pode ser apontado como um fator de vantagem competitiva no meio organizacional (POWELL, 1995; ALOFAN; CHEN; TAN, 2020).

Visando demonstrar a importância atribuída a essa forma de gestão, prêmios foram criados para avaliar organizações de acordo com seu nível de desenvolvimento em TQM.

Dentre eles, pode-se citar o *Deming Prize*, no Japão; o *Malcolm Baldrige National Quality Award*, nos Estados Unidos da América; e o *European Quality Award*, na Europa (ABDULLAH *et al.*, 2012; GÓMEZ-LÓPEZ; LÓPEZ-FERNÁNDEZ; SERRANO-BEDIA, 2015).

Apesar do grande reconhecimento dessa prática de gestão, é importante ressaltar que sua implantação não é tão simples. É preciso levar em consideração que a TQM, não pode ser meramente inserido nas estruturas do gerenciamento já existente em uma organização.

Muitas vezes, é necessário que haja um redesenho total do processo, uma redefinição dos papéis gerenciais, aprendizado de novas habilidades entre os colaboradores e a reorientação de todas as metas estabelecidas anteriormente (SOUSA; A VOSS, 2002; CÂNDIDO; SANTOS, 2011).

Existem várias abordagens para aplicar os princípios de TQM em qualquer organização (SADER; HUSTI; DARÓCZI, 2019), mas embora o gerenciamento da

qualidade tenha se tornado popular nas décadas de 1980 e 1990, as empresas do século XXI, na Era da I4.0, ainda estão buscando se adequar ao conceito (GUNASEKARAN; SUBRAMANIAN; NGAI, 2019).

O contexto I4.0 e seu entrelaçamento com a TQM será abordado mais adiante. Agora é interessante conhecer mais a fundo sobre os indicadores de qualidade que constituem a TQM.

### 2.1.1 *Indicadores de Qualidade*

Quando uma organização adota o uso do sistema TQM em seu gerenciamento, os indicadores de qualidade são citados na literatura como apoio ao acompanhamento do desempenho (SUH; KWON, 2006; CHAE, 2009; ANIL; SATISH, 2016), ou seja, o acompanhamento TQM é realizado por meio desses indicadores, que podem ser compostos por números, dados, *status*, entre outras formas de mensurar o nível de diversos processos dentro da organização.

Além disso, os indicadores são considerados uma ferramenta útil de *benchmarking*, usado para determinar o quão bem as empresas estão mantendo seus objetivos e detectar os pontos de melhorias existentes (SMITH, 2014), fornecendo capacidade de detectar problemas, ainda em sua fase inicial, para que a partir disso, medidas possam ser tomadas a fim de evitar a ampliação do problema (SABBAGH *et al.*, 2018).

Os indicadores de qualidade precisam estar alinhados aos focos da TQM, que abrangem o foco no cliente, o suporte de alta gerência, o relacionamento, a promoção de autonomia, o *feedback* e o gerenciamento de processos, conforme descrito no Quadro 1.

**Quadro 1 - Relação dos indicadores de qualidade com os focos do TQM**

FOCOS DA TQM	RELAÇÃO COM OS INDICADORES
<b>Foco no cliente</b>	Tem como premissa que os clientes são alvos móveis, que precisam ser constantemente examinados, identificados e satisfeitos. O desenvolvimento de um sistema de atendimento ao cliente bem-sucedido pode ser considerado um dos objetivos mais urgentes para uma organização (SHROFF, 2019). Portanto, os indicadores relacionados a esse cenário, devem estar alinhados à realidade.
<b>Suporte de alta gerência</b>	Zabadi (2013) argumentou que a alta gerência tem a capacidade de criar visão e promover mudanças que estão no centro da implementação bem-sucedida da TQM. As principais razões para a falha na melhoria da qualidade em uma organização são devidas à indiferença e à falta de envolvimento e comprometimento do suporte da alta gerência (SHROFF, 2019). Logo, a visualização dos indicadores pela alta gerência é essencial para a gestão da organização
<b>Relacionamento</b>	O relacionamento entre funcionário e supervisor é um elemento central da afiliação do funcionário à organização. Além disso, uma das principais fontes de rotatividade de funcionários está relacionada a questões de gerenciamento da organização. Diante disso, o desenvolvimento de práticas operacionais de comunicação e o respeito ao trabalho dos funcionários levam a melhores relacionamentos entre os gerentes e seus funcionários (SHROFF, 2019);
<b>Promoção de autonomia</b>	Muito amplamente, o sucesso da TQM depende da eficiência e eficácia de seus funcionários na organização para executar o processo de melhoria (MANDAL, 2009). Por isso, a promoção da autonomia significa compartilhar com funcionários não gerenciais o poder e a autoridade para tomar e implementar decisões (SHROFF, 2019);
<b>Melhoria contínua</b>	A melhoria contínua de toda a organização constitui um princípio básico da TQM, que representa o processo de definir e separar sistematicamente as principais causas de deficiência de desempenho, apurando e melhorando os produtos, serviços e sistemas organizacionais para produzir uma melhoria gradual em direção à qualidade total (SHROFF, 2019). Dessa forma, os indicadores devem expressar que a organização está realmente tendo uma melhora contínua em seus processos, e caso não, determinar um plano de ação para isso;
<b>Feedback</b>	Esse processo possibilita monitorar e determinar as etapas corretivas necessárias para o próximo estágio de melhoria. Consistentemente, ao implementar a política de feedback, o funcionário e o empregador podem ajudar no processo de refino, design e redesenho, o que leva a um esforço de melhoria contínua na organização, que costuma ser praticada no final de cada semestre ou ano. Portanto, as ferramentas de feedback são essenciais para a resolução bem-sucedida de conflitos (SHROFF, 2019), da mesma forma que indicadores podem ser criados para mensurar até que ponto esses feedbacks estão sendo atendidos.
<b>Gerenciamento de processos</b>	É o meio de garantia, controle, planejamento, administração das atividades necessárias para alcançar um alto nível de desempenho e transformação de entradas como materiais, dinheiro, informações e dados em saídas como informações, produtos, serviços, por isso, a TQM é orientado ao processo (SHROFF, 2019), e os indicadores são utilizados nesse monitoramento.

**Fonte: Elaborado pela autora (2020)**

Choisne, Grosbois e Kumar (2009), em seu trabalho, aplicaram um questionário para saber até que ponto os indicadores são positivamente influenciados pela implementação da TQM e chegaram à conclusão que, em termos

gerais, a TQM ajudou a melhorar os indicadores principais, especialmente os relacionados a satisfação do cliente, as relações com os funcionários e as operações.

Velimirović, Velimirović e Stanković (2011), investigaram os indicadores e a dificuldade de medir o desempenho nas concessionárias TOYOTA, como parte do processo organizacional que implica na orientação para o cliente. Pouco depois, Biondi *et al.* (2013), desenvolveram um modelo que busca avaliar o desempenho das concessionárias de carros, em termos de participação no mercado. Como resultado, o tópico de gerenciamento de desempenho desperta grande interesse tanto de acadêmicos quanto de profissionais (SABBAGH *et al.*, 2018).

Um grande desafio ao integrar toda a cadeia de valor, de acordo com o conceito da I4.0, é o monitoramento dos indicadores dos processos o mais próximo do tempo real. Isso é difícil porque, na maioria das organizações, os processos e sistemas analíticos operam isoladamente, como demonstrado por Vukšić, Bach, Popovič *et al.* (2013).

Dentro da indústria, os indicadores de qualidade, desempenham um papel decisivo para o sucesso da organização, mas para estabelecer esses indicadores é necessária a definição de objetivos operacionais e um planejamento a longo prazo.

Para gerenciamento dos indicadores e dos objetivos, com foco na indústria automotiva, são utilizadas as ferramentas de qualidade, visto que, o mercado consumidor procura o veículo com o melhor custo-benefício (PACHECO; MARTINS, 2015).

Dessa forma, a expectativa do mercado e da empresa é refletida através dos indicadores, que possibilitam identificar desperdícios e oportunidades de melhoria, bem como desvios em relação aos objetivos da organização.

Além disso, os indicadores podem ser utilizados como forma de acompanhar o processo de Transferência de Tecnologia, mensurando quais foram os impactos desse processo para o receptor final.

## 2.2 TRANSFERÊNCIA DE TECNOLOGIA

A Transferência de Tecnologia (TT) é um termo que surgiu em meados da década de 40, nos Estados Unidos, a partir de incentivos oriundos do governo (SALAHALDEEN, 1995). É compreendida como um processo de disseminação ou retenção de tecnologias, conhecimento aplicável e/ou resultado de sua implementação, gerando produtos ou outros elementos, entre os envolvidos, que podem ser indústrias, indivíduos, instituições ou entidades (SILVA; KOVALESKI; PAGANI, 2019).

Para que o conceito de TT possa ser amplamente compreendido, é importante salientar que o termo tecnologia não se limita uma máquina ou equipamento, pois dependendo da natureza e finalidade da aplicação, um produto ou outro elemento, também pode ser considerado como uma tecnologia (SILVA; KOVALESKI; PAGANI, 2018).

Dessa forma, a TT consiste em um processo de compartilhamento de tecnologia entre a parte que fornece (fornecedor) e a que recebe (receptor), de acordo com os objetivos das partes envolvidas, por meio de diferentes mecanismos, sendo eles comerciais ou não.

Segundo Bolotan *et al.* (2016), o desempenho da TT tem um impacto positivamente forte na TQM. Isso porque, as empresas, que estão constantemente envolvidas em um ambiente competitivo, precisam melhorar seus custos, qualidade e prazos para atender e até exceder as necessidades e expectativas de seus clientes, e para isso, o processo de TT pode ser utilizado para atualizar as tecnologias de uma organização, e melhorar assim seus índices de qualidade total.

Essa abordagem está alinhada com o aumento da competitividade e da qualidade relacionados ao conceito da I4.0. E para que as organizações se adaptem, é necessário que processos internos e externos de TT sejam realizados.

Os processos internos da TT são aqueles em que a indústria é limitada a seus recursos, e, portanto, a transferência de conhecimento é acontece entre seus próprios colaboradores experientes e funcionários recém-contratados. Nesse formato, quando uma indústria limita seu TT a processos internos, pode enfrentar

dificuldades para permanecer no mercado (SILVA; KOVALESKI; PAGANI, 2018).

Quanto aos processos externos, a organização irá interagir com recursos de fornecedores, instituições de pesquisa, governo, entre outras organizações que até então não havia entrado em contato. Segundo Hung e Tang (2008), com a transferência externa de tecnologia, as indústrias economizam recursos e investimentos em pesquisa e desenvolvimento que seriam inviáveis de outra maneira e obtêm vantagens competitivas.

Para Zhao, Tian e Zillante (2014), a tecnologia é um dos principais elementos na formação e desenvolvimento de cadeias de suprimentos e se torna fundamental para obter vantagem competitiva nas indústrias. No entanto, a maneira como o processo de TT é conduzido se torna crucial para a eficácia da transferência e para o sucesso organizacional.

No cenário da I4.0, a escassez de estudos sobre TT pode ser facilmente observada (SILVA; KOVALESKI; PAGANI, 2018), portanto, a subseção seguinte pretende apresentar a literatura sobre a I4.0, para na Seção 5 demonstrar a relação entre ambos.

## 2.3 INDÚSTRIA 4.0

A quarta revolução industrial, conhecida como I4.0, representa mais um marco que está mudando fundamentalmente as indústrias, compelindo todos os setores a avançarem para a fase da I4.0 (MOHELKA; SOKOLOVA, 2018; HAMID *et al.*, 2019).

Essas fases de industrialização ocorrendo desde o século 18, sendo a primeira fase iniciada no final desse século até o início do século 20, e foi marcada pela dependência da potência da água e do vapor, sendo um de seus principais símbolos a invenção do tear mecânico em 1784 (YÜLEK, 2018).

A segunda fase da revolução industrial, datada do final do século 19 ao início dos anos setenta, foi baseada na produção em massa e na divisão do trabalho. Sendo lembrada principalmente, pela implantação da linha de montagem

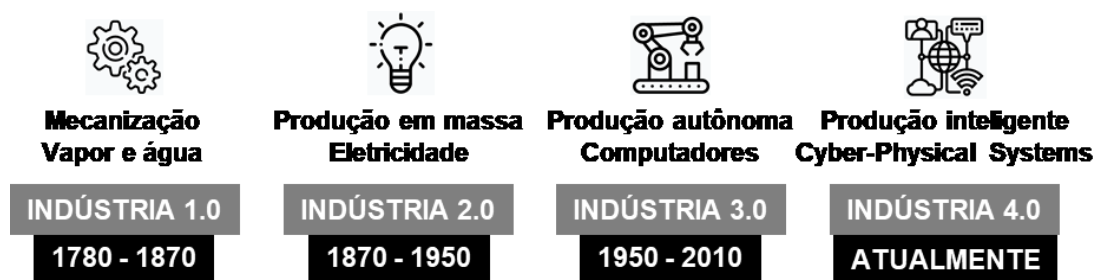
em 1870 e a necessidade de energia elétrica (YÜLEK, 2018).

Em seguida, por volta de 1950, iniciou-se a terceira fase, caracterizada pela dependência da eletrônica e da Tecnologia da Informação e Comunicação (TIC), sendo representada pelo controlador lógico programável em 1969 (YÜLEK, 2018).

Com a introdução da mecanização, eletricidade e digitalização, atualmente está acontecendo uma transição em direção a uma indústria interconectada e automatizada, citada como I4.0, sendo apontada como a quarta etapa da industrialização (ACETO; PERSICO; PESCAPE, 2019).

A I4.0 apresenta diversas outras nomenclaturas, dependendo do país onde seja abordada: *Smart Manufacturing*, *Fourth Industrial Revolution*, *Smart Industry* e *Integrated industry* (HERMANN; PENTEK; OTTO, 2016; SILVA; KOVALESKI; PAGANI, 2019). Essa revolução industrial é baseada principalmente em tecnologias como *Cyber-Physical Systems*, (integração de computação, comunicação e controle), *Big Data Analytics* (técnicas para extrair informações de uma enorme quantidade de dados) e Internet of Things (IoT) (caracterizado pela presença generalizada de uma variedade de objetos interconectados), e outras tecnologias relacionadas a essas (ACETO; PERSICO; PESCAPE, 2019). As fases da industrialização podem ser observadas na Figura 10.

Figura 10 – Fases da industrialização



Fonte: Elaborado pela autora (2020)

Após o surgimento do termo I4.0, muitos autores acrescentaram definições que complementam seu sentido e englobam tecnologias utilizadas nessa nova fase industrial. O Quadro 2, apresenta a visão de alguns autores sobre esse conceito.

Quadro 2 - Definições de Indústria 4.0

AUTOR	DEFINIÇÃO
Hitpass (2017)	A Indústria 4.0 denota a Quarta Revolução Industrial, um termo introduzido em 2011 na Hannover Messe, uma das maiores feiras do mundo, e desde então amplamente utilizado pela indústria e pelos governos alemães.
Tortorella e Fettermann (2017)	Indústria 4.0 é um conceito amplo que abrange uma variedade de sistemas, tecnologias, princípios e procedimentos projetados para tornar os processos de produção mais autônomos, dinâmicos, flexíveis e precisos.
Müller <i>et al.</i> (2018)	O conceito da Indústria 4.0 refere-se à aplicação da tecnologia Internet das Coisas na indústria de manufatura, portanto, também conhecida como Internet Industrial das Coisas em um contexto internacional.
Kamble, Gunasekaran e Gawankar (2018)	O termo Indústria 4.0 compreende uma variedade de tecnologias para permitir o desenvolvimento da cadeia de valor, resultando em tempos de produção menores, além de melhorar a qualidade do produto e o desempenho organizacional.
Dalenogare <i>et al.</i> (2018); Frank <i>et al.</i> (2019)	A Indústria 4.0 foi proposta como um novo estágio de maturidade industrial baseado na conectividade fornecida pela Internet das Coisas (IoT) industrial e no uso de várias tecnologias digitais, como computação em nuvem, <i>Big Data</i> e inteligência artificial.
Asif (2020)	Indústria 4.0, baseada na integração de tecnologias de informação e comunicação, <i>Internet of Things</i> , robótica, fabricação aditiva e inteligência artificial, visa desenvolver operações autônomas e dinâmicas para permitir a produção em massa de produtos altamente personalizados.

Fonte: Dados da pesquisa (2020)

Apesar da variedade de definições relacionados a I4.0, os pesquisadores continuam buscando uma definição adequada para essa fase industrial. No estudo mais recente de Ghobakhloo (2018) sobre o conceito da quarta revolução industrial, argumentou-se que a I4.0 poderia ser definida com base em suas tendências de tecnologia e princípios de *design* subjacentes.

As tendências tecnológicas fazem referência às inovações tecnológicas agregadas ao cenário industrial, facilitando o surgimento das novas tecnologias industriais (GHOBAKHLOO; FATHI, 2019).

Os princípios de *design*, dizem respeito a possibilidade de os fabricantes preverem o progresso da adaptação da I4.0 e planejarem a criação de procedimentos e soluções adequadas e necessárias para esse processo de transição (SANTOS *et al.*, 2017; VOGEL-HEUSER; HESS, 2016), dessa forma, o



setor 4.0 altera significativamente produtos e sistemas de produção, processos, operações e serviços (DURANA *et al.*, 2019).

Dalenogare *et al.* (2018) consideram a I4.0 como um novo estágio industrial no qual a integração do processo de fabricação vertical e horizontal e a conectividade do produto podem ajudar as empresas a alcançar um nível mais alto de desempenho industrial.

Dentro do paradigma da I4.0, os fabricantes buscam um sistema de produção descentralizado, integrado, automatizado e avesso a resíduos, que ofereça suporte à personalização de produtos nas condições de produção em massa altamente flexível (GHOBAKHLOO; FATHI, 2019).

A I4.0 é uma oportunidade para o movimento da qualidade ainda mais relevante. Isso representa um desafio significativo para os profissionais que trabalham com a qualidade, enfatizando a necessidade de se adaptar às inovações tecnológicas, à moderna análise de dados e ao ecossistema de empreendedorismo que caracteriza esse período (ZONNENSHAIN; KENETT, 2020).

Dessa forma a I4.0 representa uma grande oportunidade de integrar diversas tecnologias ao setor indústria, não apenas como coadjuvantes como visto em outras fases indústrias, mas como protagonistas capazes de automatizar diversos processos, otimizando o trabalho humano.

### 2.3.1 Integrando a I4.0 a TQM

Sader, Husti e Daróczy (2019), acreditam que a I4.0 poderia ser utilizada como uma facilitadora essencial para a TQM, especialmente integrando as técnicas 4.0 às melhores práticas da qualidade total, como por exemplo, fazer previsões corretas com base em BD. Essa é uma nova face da qualidade para o serviço ao cliente e precisa ser tratada pela TQM (EREVELLES *et al.*, 2016).

A I4.0 e a TQM compartilham de um mesmo objetivo, ou seja, melhorar o desempenho do processo, mas através de diferentes trajetórias.

No entanto, apesar dos desenvolvimentos do setor 4.0, os modelos de gerenciamento de qualidade permaneceram estagnados e falharam em acompanhar

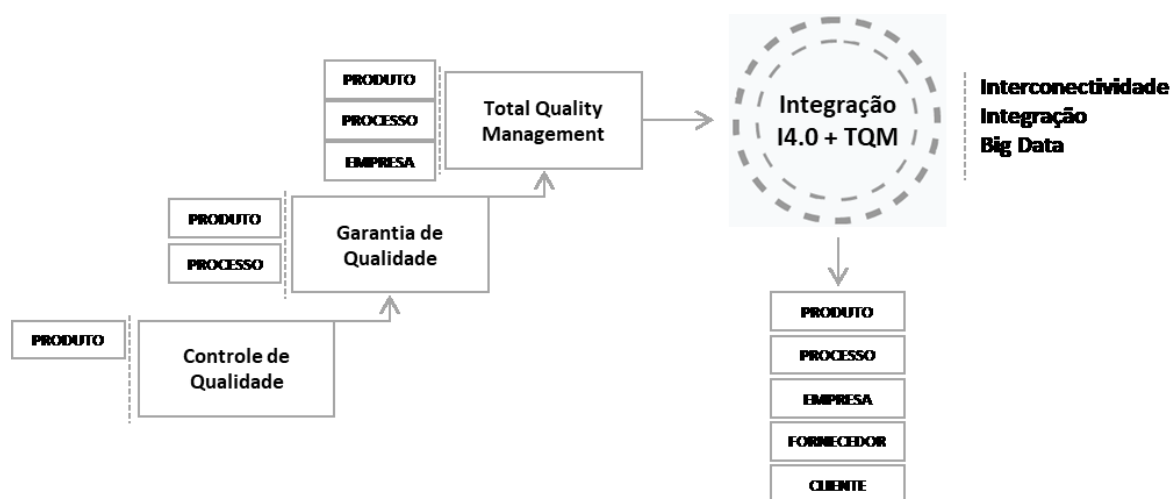
esses avanços (ASIF, 2020), o que caracteriza mais um desafio nessa área.

Atualmente, com o mercado cada vez mais competitivo com tantas opções, as demandas dos clientes compõem as organizações a se concentrarem na qualidade.

Isso faz com que essas empresas, direcionem seus esforços para criar vantagem competitiva no quesito da qualidade, com produtos e serviços que atendam ou superem as necessidades dos clientes (GÓMEZ-LÓPEZ; LÓPEZ-FERNÁNDEZ; SERRANO-BEDIA, 2015; BOLATAN *et al.*, 2016; ANTAL, 2020), portanto, estudos nessa área são sempre necessários.

A Figura 11 esquematiza a perspectiva mais ampla para integrar os recursos da I4.0 às práticas de TQM, onde interconectividade, integração e BD podem aprimorar o gerenciamento da qualidade, dessa forma, a I4.0 pode fornecer um suporte para uma implementação bem-sucedida dos princípios de TQM (SADER; HUSTI; DARÓCZI, 2019).

**Figura 11 – Indústria 4.0 e Gestão da Qualidade Total integrados (traduzido e revisado)**



**Fonte: Adaptado de Sader, Husti e Daróczi (2019)**

Nesse cenário, a I4.0 pode ser reconhecida como uma grande oportunidade para o desenvolvimento e melhoria da competitividade, embora o estado dos preparativos para sua implementação varie amplamente, dependendo do país, setor ou até de uma empresa para outra (SLUSARCZYK, 2018). É possível perceber que

o gerenciamento do setor 4.0 requer um novo conjunto de habilidades, ética no trabalho e sistemas de gerenciamento proporcionais, que acompanhem todas essas mudanças (WORLD ECONOMIC FORUM, 2018), e que integrem diferentes ferramentas dentro de uma mesma organização como estudado a seguir.

### 2.3.2 Integração de Ferramentas

Um dos principais conceitos da I4.0 é a integração de ferramentas, e contempla três diferentes eixos: integração horizontal, integração vertical e integração de ponta a ponta (ZHOU; LIU; ZHOU, 2015; FATORACHIAN; KAZEMI, 2018; ACETO; PERSICO; PESCAPE, 2019; SADER; HUSTI; DARÓCZI, 2019), descritos a seguir:

- *Integração horizontal*: diz respeito à cooperação entre empresas ao longo da cadeia de valor, permite que o ambiente de fabricação se torne colaborativo durante as etapas do desenvolvimento até a produção, resultando em uma fabricação mais eficiente e eficaz (BRETTEL *et al.*, 2014);
- *Integração vertical*: refere-se às unidades de negócios inteligentes em rede; por exemplo: *smart industry*, logística inteligente, *marketing* inteligente e serviços, em que as unidades de produção estão coordenando e se comunicando sem problemas (MRUGALSKA; WYRWICKA, 2017), e
- *Integração de ponta a ponta*: é a integração geral de todo o regime de produção, executando um sistema descentralizado, no qual todas as entidades participantes têm acesso em tempo real às informações e o controle é distribuído instantaneamente ao chão de produção (BRETTEL *et al.*, 2014).

Ao sintetizar esses conceitos temos que: (i) integração horizontal, caracteriza a cooperação entre empresas ao longo da cadeia de valor; (ii) integração vertical, se refere à ampla automação dentro de uma única empresa; e por fim, (iii) integração de ponta a ponta, promove conexões entre todos os participantes habilitados digitalmente (máquina-máquina, humano-máquina,

humano-humano), dentro da organização (ZHOU; LIU; ZHOU, 2015; FATORACHIAN; KAZEMI, 2018; ACETO; PERSICO; PESCAPE, 2019).

A I4.0 busca o desenvolvimento tecnológico dos sistemas de produção industriais, resultando em uma maior integração de todas essas tecnologias, como: da IoT, *Cyber Physical Systems*, *Big Data*, Inteligência Artificial e *Cloud Computing*. Essa integração e interconexão de troca de dados e informações entre diferentes sistemas ajudam as organizações a alcançarem um nível mais alto de excelência, eficiência e eficácia em seus negócios (SADER; HUSTI; DARÓCZI, 2019).

Mais especificamente, na visão da I4.0, espera-se que os *Cyber-Physical Systems* permitam a transição de uma "cadeia de valor" linear para uma "rede de valor" automatizada e altamente dinâmica, incluindo sistemas de produção, infraestruturas e clientes, concluindo idealmente a automação de todo o processo de produção (ACETO; PERSICO; PESCAPE, 2019).

É evidente que esse nível de integração entre os diferentes componentes de uma fábrica inteligente, por exemplo: máquinas, dispositivos e recursos humanos, e a maneira como eles se comunicam e aprendem uns com os outros dependem significativamente da infraestrutura de aquisição e gerenciamento de dados, tais como tecnologias em nuvem e BDA. Esse grupo de tendências de tecnologia da I4.0 permite coletar, armazenar e analisar um enorme fluxo de dados de processos, produção e cadeia de suprimentos o mais próximo do tempo real possível (GHOBAKHLOO, 2018). Com essa integração, a organização tende a caminhar para uma conexão de todas as áreas, e essa dissertação apresenta uma parte para que isso seja possível, visto que disponibilizar o acesso aos indicadores em apenas uma plataforma, integra diversos outros, além de melhor aproveitar os a BD da organização.

## 2.4 BIG DATA

O termo *Big Data* é usado para descrever o crescimento exponencial de dados nos últimos anos (BAJABER *et al.*, 2016; YU *et al.*, 2017). Seu significado é

bastante diversificado, não sendo possível indicar uma definição única aceita por todos os autores. De qualquer forma, pode ser compreendido como dados que não podem ser processados pela maioria dos sistemas disponíveis atualmente, por serem grandes demais (FISHER *et al.*, 2012). Outros autores complementam essa definição conforme Quadro 3.

**Quadro 3 - Definições da Big Data**

AUTOR	DEFINIÇÃO
Hu <i>et al.</i> (2014)	O termo captura o cenário atual de explosão de dado, ou seja, muitos dados sendo gerados em um curto espaço de tempo.
Otero e Peter (2015)	Big data foi definido como dados com alto volume, velocidade e variedade, que apresentam imprevisibilidade em sua geração.
Kitchin (2014); Manogaran e Lopez (2018)	Representa um enorme volume de dados, com alta velocidade, diversidade e variedade.
Verma e Singh (2017)	Dados gerados de forma excessiva são chamados de "Big Data" e compreendem padrões valiosos que não são percebidos facilmente e são necessárias "análises avançadas" para descobrir esses padrões.
Manogaran e Lopez (2018)	Dados advindos de dispositivos móveis, redes sociais, sensores e outros, em grande volume que necessitam de técnicas e ferramentas específicas para seu processamento.
Rhadika e Kumari (2019)	Refere-se a dados gravados em vários dispositivos eletrônicos com propriedades como enorme volume e velocidade, tipos diferentes de dados, inconsistências no fluxo de dados e formatos diferentes.
Wasim <i>et al.</i> (2019)	Big Data refere-se aos dados gerados continuamente a partir de várias fontes de dados, como dispositivos de <i>Internet of Things</i> (IoT), aplicativos móveis, sensores incorporados, cliques na web e outros.

**Fonte: Dados da pesquisa (2020)**

Sendo assim, a BD pode ser considerado como a nova fase dos dados, que agora estão sendo gerados com muita velocidade e por diversos dispositivos inseridos em ambientes como indústrias, hospitais, escolas e até mesmo no cotidiano de muitas pessoas, através de celulares, assistentes virtuais, *smartwatches*, e muitos outros.

Fundamentalmente, BD não significa apenas um grande volume de dados. Esse termo possui outras características que o diferenciam dos conceitos de *massive data* e *very large data* (HU *et al.*, 2014), e são conhecidos como os Vs da BD, que são descritos na subseção seguinte.

### 2.4.1 Características da Big Data

Desde 1997, muitas características foram adicionadas a BD. As primeiras características foram: volume, variedade e velocidade compondo os 3Vs, que foram familiarizadas por Gartner (2011). As outras características foram sendo acrescentadas, e na literatura é possível encontrar autores que apontem até 7 Vs, para atribuir características que distinguem a BD dos demais conjuntos de dados conhecidos até hoje. No Quadro 4, essas características e os autores relacionados são compilados.

**Quadro 4 - Os Vs da Big Data**

<b>Vs</b>	<b>AUTOR</b>	<b>CARACTERÍSTICAS</b>
<b>3 Vs</b>	Jagadish <i>et al.</i> (2014); Acharjya e Ahmed (2016); Mauro, Greco e Grimaldi (2016); Wasim <i>et. al.</i> (2019)	Volume   Velocidade   Variedade
<b>4 Vs</b>	Halevi e Moed (2012); Buhl <i>et al.</i> (2013); Acharjya e Ahmed (2016)	Volume   Velocidade   Variedade Veracidade
<b>5 Vs</b>	Anshari <i>et al.</i> (2019); Dubey <i>et al.</i> (2019); Mohamed <i>et al.</i> (2019)	Volume   Velocidade   Variedade Veracidade   Valor
<b>6 Vs</b>	Saggi e Jain (2018)	Volume   Velocidade   Variedade Veracidade   Valor   Valência
	Ali e Abdullah (2019)	Volume   Velocidade   Variedade Veracidade   Valor   Variabilidade
	Qader, Ameen e Ahmed (2020)	Volume   Velocidade   Variedade Veracidade   Valor   Volatilidade
<b>7 Vs</b>	Rijmenam (2013); Seddon e Currie (2017)	Volume   Velocidade   Variedade Veracidade   Variabilidade   Visualização Valor
	Ali e Abdullah (2019)	Volume   Velocidade   Veracidade Valor   Variabilidade   Viralidade   Viscosidade

**Fonte: Dados da pesquisa (2020)**

As características são mencionadas por esses autores em seus trabalhos,

com o intuito de elucidar sobre as particularidades da BD. Em seguida, cada um desses atributos é descrito de acordo com as definições disponíveis na literatura.

- *Volume*: uma das principais características da BD. Trata-se da grande quantidade de dados gerados por diferentes fontes, que chegam continuamente além dos recursos que máquinas individuais conseguem suportar (MOHAMED *et al.*, 2019). A literatura não aponta objetivamente um tamanho que defina se um conjunto de dados é ou não considerado BD, pois esses valores se alteram constantemente. Em 2005, a classificação de *terabytes* era aceita como BD. A partir de 2010, *exabyte* tornou-se mais uma terminologia empregada para essa definição, e em 2017, o termo *zettabyte* também foi incluído (XU; DUAN, 2018). Do ponto de vista estatístico, quanto maior o tamanho da amostra, mais alinhado com a realidade o resultado se torna (ANSHARI *et al.*, 2019; DUBEY *et al.*, 2019). Entretanto, embora pareça que a BD permita coletar mais dados para encontrar informações mais úteis, nem sempre isso é verdade, pois esses dados podem ser ambíguos ou até mesmo anormais (TSAI *et al.*, 2015), o que pode dificultar a análise;
  
- *Velocidade*: é a taxa de crescimento e a rapidez com que os dados são reunidos para serem analisados, e com os recentes avanços tecnológicos, o tempo o qual os dados são produzidos, capturados, agregados, processados e transmitidos, tende a ser cada vez menor (ANSHARI *et al.*, 2019; DUBEY *et al.*, 2019). Devido a isso diferentes tipos de processamentos devem ser empregados de acordo com a necessidade do conjunto de dados em questão (WASIM *et al.*, 2019), pois toda essa velocidade aponta para a necessidade de gerar resultados o mais próximo do tempo real possível, visando aproveitar ao máximo todas as informações que podem ser extraídas (ACHARJYA; AHMED, 2016). Essa alta taxa de entrada de dados não estruturados e não homogêneos, ficou conhecido como a segunda característica mais lembrada da BD. O mercado financeiro e empresas de publicidade são exemplos de áreas que lidam com esse problema diariamente e enfrentam desafios principalmente devido a lentidão e alto custo do processamento desses dados

(SAGGI; JAIN, 2018);

- *Variedade*: geralmente, a BD apresenta diferentes formas e tipos. Isso pode ser explicado devido a origem desses dados, que são produzidos por diversos dispositivos (ANSHARI *et al.*, 2019; DUBEY *et al.*, 2019; WASIM *et al.*, 2019). Além disso, pode consistir em dados estruturados, semiestruturados e não estruturados. Dados estruturados têm um formato específico de dados e possuem uma estrutura. O gerenciamento desses dados é facilmente possível usando um padrão do tipo *SQL language*, geralmente vista em sistemas de gerenciamento de banco de dados relacional. Alguns exemplos desse tipo de dado são: *string*, numeral e datas. Os dados não estruturados não seguem nenhum formato específico, são gerados em diferentes formatos, como vídeos, texto, informações de tempo e localização geográfica. Devido a isso, o rápido desenvolvimento e gerenciamento de tais dados coloca sérios desafios à capacidade computacional existente (SIVARAJAH *et al.*, 2017);
- *Veracidade*: refere-se à extensão em que os dados podem ser considerados confiáveis e de qualidade, dada a confiabilidade de sua origem. Como por exemplo, ao receber dados de sensores instalados em uma fábrica, alguns dispositivos podem estar comprometidos, resultando em dados que não representam a realidade (MOHAMED *et al.*, 2019). Em 2014, a veracidade dos dados já era apontada como um desafio dentro da BD, por enfrentar dúvidas, imprecisões, invenções, confusão e evidências equivocadas nos dados (SIVARAJAH *et al.*, 2017). Essa imprevisibilidade é inerente em alguns dados e requer uma análise mais profunda para obter previsões que possam ser realmente consideradas confiáveis (ANSHARI *et al.*, 2019; DUBEY *et al.*, 2019);
- *Valor*: demonstra até que ponto a BD gera valor econômico percepções e/ou benefícios através de sua extração e transformação, e está intimamente ligado a área analítica. Busca reunir informações de dados e traduzi-las em



vantagens. Denota à extensão em que se pode obter *insights* ou benefícios economicamente valiosos por extração ou transformação desses dados (ANSHARI *et al.*, 2019; DUBEY *et al.*, 2019). Essa característica representa um dos principais desafios da *Big Data*, o de extrair valor de uma grande quantidade de dados, sem que ocorram perdas para os usuários finais. Esse valor é muito importante em análises dos setores industriais (SAGGI; JAIN, 2018). Pesquisadores da BD consideram o valor como um recurso essencial, pois em algum lugar desses dados há informações valiosas, chamadas de *extracting golden data*, que são dados de que podem render análises muito específicas sobre um determinado cenário (ZASLAVSKY; PERERA; GEORGAKOPOULOS, 2012; SIVARAJAH *et al.*, 2017). Independentemente do número de dimensões usadas para descrever a BD, as organizações ainda enfrentam desafios de armazenar, gerenciar e extrair predominantemente valor dos dados de maneira econômica (ABAWAJY, 2014);

- *Variabilidade*: refere-se a dados cujo significado é alterado constantemente e rapidamente, muito comum no mercado de ações e em dados financeiros. Entre os sete pilares da *Big Data*, a variabilidade é considerada uma característica extremamente essencial. Os volumes de dados gerados por máquinas e humanos constituem muito maiores e suas taxas de mudança e variabilidade são cada vez maiores. A variabilidade também está relacionada a realização de análises de sentimentos, que pretende interpretar até mesmo as emoções relacionadas aos usuários (SIVARAJAH *et al.*, 2017). Para realizar uma análise de sentimento adequada, é preciso que os algoritmos entendam o contexto e decifrem o significado exato de uma palavra nesse mesmo contexto (ZHANG *et al.*, 2015). No entanto, isso ainda é muito desafiador (SIVARAJAH *et al.*, 2017);
- *Visualização*: Tornar compreensível toda essa vasta quantidade de dados de uma maneira fácil de entender e ler, é um grande desafio. Com as análises e

visualizações corretas, os dados brutos podem ser utilizados, caso contrário, os dados brutos permanecem essencialmente inúteis. Nesse caso, visualizações implicam em gráficos complexos que podem incluir muitas variáveis de dados e permanecer compreensíveis e legíveis (RIJMENAM, 2013; SEDDON; CURRIE, 2017). Visualizar pode não ser a parte mais tecnicamente difícil, mas é a parte mais desafiadora. Felizmente, aparecem cada soluções e iniciativas para enfrentar esse desafio, capazes de ajudarem as organizações a responderem perguntas que anteriormente não sabiam como (RIJMENAM, 2013; SEDDON; CURRIE, 2017).

Por fim, a valência, outra característica atrelada ao conceito da BD, refere-se à conectividade da BD na forma de gráficos (SIVARAJAH *et al.*, 2017). A viralidade, por sua vez, descreve a rapidez com que as informações se espalham pela rede (ALI; ABDULLAH, 2019), enquanto que a viscosidade serve como medida para verificar como os dados estão fluindo no processamento (ALI; ABDULLAH, 2019).

O último V se refere à volatilidade, e diz respeito à duração da utilidade dos dados armazenados, ou seja, por quanto tempo esses dados serão realmente úteis (QADER; AMEEN; AHMED, 2020).

Pouco se encontra na literatura sobre valência, viralidade, viscosidade e volatilidade. Esses três últimos termos ainda são relativamente novos no contexto e isso pode explicar essa falta de material.

#### 2.4.2 *Categorias de Processamento*

As categorias de processamento mais aplicadas nesse contexto da BD, são o *Streaming processing*, e o *Batch processing* (HU *et al.*, 2014; SIVARAJAH *et al.*, 2017; SAGGI; JAIN, 2018). O *Streaming processing*, atua no processamento de fluxo dos dados e tem como ponto de partida que o valor potencial dos dados depende da atualização dos mesmos, sendo assim, os dados devem ser processados o mais rápido possível para obter seus resultados.

Nesse paradigma, os dados chegam em um fluxo rápido que carrega um

volume enorme de dados. A teoria e a tecnologia do *streaming processing* são estudadas há décadas e principalmente usado para aplicativos *on-line* atualizados em milissegundos (HU *et al.*, 2014; SIVARAJAH *et al.*, 2017; SAGGI; JAIN, 2018).

O *Batch processing* faz o processamento de diferentes lotes de dados, e tem como características armazenar os dados primeiro e depois analisá-los. O MapReduce se tornou o modelo dominante de *batch processing*. Sendo seu propósito primeiro dividir os dados em pequenos pedaços e em seguida, processá-los em paralelo e de maneira distribuída para gerar resultados intermediários. O resultado final é obtido agregando todos os resultados intermediários. Esse modelo agenda recursos de computação próximos ao local dos dados, o que evita a sobrecarga de comunicação da transmissão de dados (HU *et al.*, 2014; SIVARAJAH *et al.*, 2017; SAGGI; JAIN, 2018).

Desde a década de 1980, alguns problemas de grande volume de dados já existiam, como os dados do genoma humano e da física de partículas, por exemplo, o que demonstra que esse tema não surgiu recentemente. Contudo, nos últimos anos o assunto tem se tornado cada vez mais conhecido, e as técnicas existentes estão se tornando cada vez mais maduras para obter informações a partir desse problema (XU; DUAN, 2018).

Todos os dias, grandes quantidades de dados de fontes diversas são geradas com muita velocidade, o que se torna um desafio para acadêmicos e profissionais, pois a capacidade de organizações em transformar esses dados em informações valiosas pode fazer a diferença entre o sucesso e o fracasso dos negócios (SIVARAJAH *et al.*, 2017; KAUFFMANN *et al.*, 2019).

Isso também implica que a maioria dos métodos tradicionais de mineração de dados ou análise de dados desenvolvidos para um processo centralizado de análise de dados pode não ser capaz de ser aplicada diretamente a BD (FISHER *et al.*, 2012).

Nesse cenário, a BDA está se tornando uma técnica adotada por muitas organizações com o objetivo de obter esses dados e transformá-los em informações valiosas (SIVARAJAH *et al.*, 2017; KAUFFMANN *et al.*, 2019).

### 2.4.3 Big Data Analytics

A *Big Data Analytics* (BDA) está intimamente relacionado à tomada de decisões, portanto, antes de conceituar esse termo, é interessante conhecer sistemas e técnicas usadas anteriormente ao fenômeno da BD, como os sistemas de suporte à decisão na década de 1970, conhecidos como os primeiros sistemas nessa área (POWER, 2008; WATSON, 2009).

Na década de 1990, Howard Dresner, analista da Gartner, empresa mundial em consultoria e pesquisa em tecnologia da informação, popularizou o termo *Business Intelligence* (BI), definida como uma ampla categoria de aplicativos, tecnologias e processos para coletar, armazenar, acessar e analisar dados para ajudar na tomada das melhores decisões (WATSON, 2009).

Com essa definição, o termo BI pode ser visto como um termo genérico para todos os aplicativos que suportam a tomada de decisões, que evoluíram a partir dos sistemas de suporte a decisão. Por sua vez, o termo *Data Analytics*, pode ser considerado uma evolução do BI, em termos de terminologia. Esse novo termo buscava abranger a entrada de algoritmos, redes neurais e *machine learning* na análise de dados (WATSON, 2009).

Após o início da era da BD, a BDA é o termo que vem sendo utilizado para abranger o processo de tomada de decisão, as análises de negócio, as tecnologias agregadas e a necessidade de processamento de uma grande quantidade de dados (CHEN; CHIANG; STOREY, 2012). A progressão dos sistemas de suporte a decisão até a chegada da BDA é ilustrada na Figura 12.



Fonte: Elaborado pela autora (2020)

Visualizando a progressão dos sistemas de suporte a tomada de decisão, é possível perceber que a necessidade de analisar dados não é um desafio recente, pois já existiam sistemas que realizavam essa tarefa desde meados do ano de 1970. Essa tendência se manteve no decorrer dos anos, porém, mudando um pouco da sua abordagem para uma visão mais preditiva, buscando entender os dados atuais para saber o que pode ou não ocorrer em um futuro próximo, até chegar a era da BD que oferece uma quantidade imensa de dados para que as mais variadas análises possam ser realizadas.

Nesse contexto, a BDA tem como principal objetivo processar dados de alto volume, velocidade, variedade e veracidade usando métodos inteligentes e técnicas computacionais (KAKHANI; KAKHANI; BIRADAR, 2015). Portanto, a BDA refere-se às técnicas utilizadas para examinar, processar, descobrir e expor padrões ocultos subjacentes, relações interessantes e outras ideias relacionadas ao contexto (IQBAL *et al.*, 2020). Outros autores também atribuem conceitos a BDA, conforme Quadro 5.

**Quadro 5 - Definições da Big Data Analytics**

AUTOR	DEFINIÇÃO
Chen, Chiang e Storey (2012)	BDA envolve técnicas, tecnologias, sistemas, práticas, metodologias e aplicativos que analisam uma grande quantidade de dados para ajudar uma organização a entender melhor seus negócios, mercado e tomar decisões oportunas.
Hu <i>et al.</i> (2014)	BDA é o processo de usar algoritmos de análise executados em plataformas de suporte poderosas para descobrir potenciais ocultos em <i>big data</i> , como padrões ocultos ou correlações desconhecidas.
Lee, Yoon e Kim (2017)	BDA é um conjunto de processos para recuperar os dados corretos a partir de dados de alto volume, alta velocidade e grande variedade; identificação de padrões nos dados; e melhorando as decisões de negócios com base nos resultados.
Saggi e Jain (2018)	BDA tornou-se uma prática moderna em inteligência de negócios que consiste em grande quantidade de conjuntos de dados e técnicas analíticas avançadas.
Ajayi <i>et al.</i> (2020)	BDA é intelectualmente rica e toma emprestado de campos relacionados, como estatísticas, mineração de dados, análise de negócios e descoberta de conhecimento a partir de dados.

**Fonte: Dados da pesquisa (2020)**

As características da BD também se aplicam a BDA (SAGGI; JAIN, 2018), ou seja, volume, variedade e demais Vs, são atributos levados em consideração na hora da análise. Além disso, assim como a BD, no requisito tempo de processamento a BDA também pode ser categorizado nos mesmos dois padrões, que são o *Batch processing* e o de *Streaming processing* (HU *et al.*, 2014; SIVARAJAH *et al.*, 2017; SAGGI; JAIN, 2018).

A BDA precisa minerar efetivamente conjuntos de dados maciços, com rapidez, incluindo a modelagem, visualização, previsão e otimização desses dados, de modo que *insights* inerentes possam ser revelados para melhorar a tomada de decisões e adquirir vantagens adicionais (HU *et al.*, 2014). É um examinador de grandes conjuntos de dados variados para descobrir padrões ocultos, correlações ainda não conhecidas, tendências de mercado, preferências dos clientes, entre outras informações úteis (ABELL *et al.*, 2017).

Em empresas e indústrias, o papel da BDA é bem reconhecido no aprimoramento da eficiência e na orientação dos processos de decisão, visto que essa análise de dados é usada para descobrir futuras ameaças e novos problemas que possam ocorrer futuramente na produção de uma indústria, por exemplo (KAMBATLA *et al.*, 2014; LI *et al.* 2017; VAIDYA *et al.*, 2018).

Com o crescimento da BD, aumenta a necessidade de as empresas desenvolverem recursos da BDA para recuperar informações significativas dos dados (BELHADI *et al.*, 2019), e alguns estudos sugerem que empresas com alta capacidade da BDA resultam em um melhor desempenho sustentável (BELHADI *et al.*, 2019; KAMBLE; GUNASEKARAN; DHONE, 2019).

Grandes empresas da área da tecnologia, como Amazon, Facebook, Google, Netflix e Uber (VAHN, 2014; SCHILDT, 2016), cujos dados a serem gerenciados e salvos são gigantescos, adotaram em suas atividades operacionais diárias de integração da BDA, o que resultou em maior capacidade em análise de dados para essas organizações (WAMBA *et al.*, 2020).

A Amazon, por exemplo, utiliza o Cluster Amazon, caracterizado por um grupo de servidores que trabalham conectados para realizar várias tarefas em bancos de dados distribuídos em diferentes servidores, sendo esse serviço usado na

BDA para aumentar a eficiência dos negócios (VERMA; SETHI; JAI, 2018).

Entretanto, a BDA é apenas uma análise que descobre informações da BD, sendo o envolvimento do conhecimento humano na tomada de decisão imprescindível. Essa cooperação é conhecida como *Humans-in-the-loop* dentro da I4.0 (DRAGICEVIC *et al.*, 2019), que busca garantir o envolvimento de pessoas habilitadas, com foco no ser humano, aliando humanos e máquinas (SCHWAB, 2017).

Sendo assim, um aspecto que deve ser levado em conta é que o método utilizado para a BDA deve extrair conhecimento dos dados de maneira interpretável, ou seja, as técnicas computacionais utilizadas para executar esta tarefa devem tornar os padrões implícitos, existentes nos dados, transparentes para quem os utiliza conseguir compreendê-los (IQBAL *et al.*, 2020). Neste trabalho, por exemplo, a BDA resulta em uma plataforma *on-line* com gráficos expostos no *dashboard* que deixam o processo de análise, por parte do responsável, mais clara e intuitiva.

Apesar de muitos autores abordarem a temática da BDA, devido a rápida mudança de tecnologias, se faz necessário realizar a revisão sistemática de métodos, técnicas e ferramentas analíticas inovadoras para tomar decisões criteriosas em vários domínios (SAGGI; JAIN, 2018).

Portanto, não há dúvida de que na era da BD, o desafio está em como armazenar, pesquisar e analisar a enorme quantidade de dados sendo gerada a cada segundo, sendo um dos principais obstáculos para os pesquisadores da BD encontrar a plataforma da BDA apropriada (ALI; ABDULLAH, 2019).

## 2.5 PLATAFORMAS ON-LINE

O termo plataforma *on-line*, compreende uma grande diversidade de serviços disponíveis na *Internet*, como: vendas, mecanismos de busca, mídias sociais, lojas de aplicativos, sistemas de pagamento e serviços de comunicação, entre outras. Dessa forma, uma plataforma *on-line* pode ser definida como um serviço digital que visa facilitar as interações entre dois ou mais indivíduos, pontos,

conjuntos e esferas através do serviço da *Internet* (OECD, 2019).

Devido a essa grande diversidade de uso, as plataformas on-line estão inseridas em boa parte das atividades cotidianas de muitas empresas, na troca de e-mails, comunicação entre colaboradores e acesso a informações (OECD, 2019).

Há também o caso em que o produto ou serviço da empresa é uma plataforma *on-line*. Scarcella (2020) pontua que o rápido crescimento do comércio eletrônico, se deu pelo uso dessas plataformas. E esse crescente uso por empresas ficou conhecido como a economia de plataforma.

Apple, Amazon, Microsoft e Facebook, quatro das dez empresas mais valiosas do mundo, atingem parte de seu valor de mercado por meio de suas plataformas *on-line* (HAGIU; ALTMAN, 2017).

Empresas de sucesso implementaram seus negócios, nessas plataformas com o objetivo de aproveitar totalmente o que a tecnologia oferece em termos de interações e devido a isso, cada vez mais fornecedores de serviços utilizam essa ferramenta (CHANG *et al.*, 2019).

De forma geral, esse sistema de relações algorítmicas é mutuamente benéfico, tanto para o detentor da plataforma, quanto para seus usuários.

Além disso, as plataformas contam com uma vasta gama de ferramentas de *software* e *Application Programming Interface* (APIs) abertas que servem para implementar a capacidade de conectar e implantar rapidamente novos serviços *on-line* (PEREPELKIN *et al.*, 2019).

No âmbito da TQM, as plataformas são consideradas uma ferramenta poderosa para o gerenciamento estatístico de processos por meio de gráficos de controle de qualidade e gerenciamento eletrônico de diferentes processos de melhoria da qualidade (FUENTES *et al.*, 2012).

Aliado a isso, as tecnologias de fabricação digital e o desenvolvimento de sistemas inteligentes de gerenciamento da qualidade, podem reduzir significativamente o custo da qualidade (BARATA; CUNHA, 2017).

Portanto, quando uma plataforma *on-line* é utilizada no contexto de indicadores de qualidade, que tratam de uma grande quantidade de dados é interessante utilizar visualizações em formato de *dashboards* para que esses dados



possam ser visualizados de forma organizada e descomplicada (VAN HORNE *et al.*, 2017; ROSEWELL *et al.*, 2017)

### 2.5.1 *Dashboard*

A visualização de dados é imprescindível no cenário da BD. Portanto, tornar os resultados complexos de análises de dados compreensíveis e interpretáveis para os seres humanos é um princípio indispensável (MAKKIE *et al.*, 2019). Para isso, os *dashboards* fornecem uma visão geral de sistemas complexos para muitas aplicações desde que surgiram, em meados da década de 1970, e foram usadas como ferramentas de apoio à decisão (GRAY; OBRIEN; HÜGEL, 2016).

Um *dashboard* pode ser descrito de maneira resumida, como uma exibição de informações predominantemente visuais, usadas para monitorar as condições atuais de um determinado assunto, que exigem uma resposta oportuna para desempenhar uma função específica, e essa definição implica em visualizações de página única e de dados atualizados (SARIKAYA *et al.*, 2019). Pode, ainda, monitorar dados e facilitar a compreensão do mesmo, pois inclui elementos infográficos e visualizações narrativas (WEXLER *et al.*, 2017), que produzem significado semântico (DRUCKER, 2014).


Nesse contexto, um *dashboard* é uma importante ferramenta de gerenciamento estratégico que usa indicadores de qualidade para traduzir a missão e a estratégia de uma organização em um conjunto de medidas de desempenho integradas, que resultam em ações relacionadas aos indicadores. As medidas de desempenho devem fornecer uma imagem completa do progresso de uma organização em relação à sua missão e objetivos (KOURTIT; NIJKAMP, 2018).

Devido a existência de muitos fluxos de dados diferentes sendo gerados em tempo real, durante a última década, os *dashboards* tornaram-se muito adequados para dar visualização a esse cenário (GRAY; OBRIEN; HÜGEL, 2016).

Para isso, precisam atingir três objetivos gerais: aumentar a eficiência e diminuir a variabilidade do processo de análise, atender às necessidades da equipe analítica e, ao mesmo tempo, estar acessível a diversos usuários (STADLER *et al.*,

2016).

A Figura 13 exemplifica tecnicamente as partes necessárias para a construção de um *dashboard*. Contando com uma ou mais bases de dados, que são transformadas em relatórios visuais, geralmente gráficos que posteriormente são disponibilizados em um único ambiente a fim de serem analisados.



Fonte: Elaborado pela autora (2020)

Essa exibição de dados, em forma de *dashboard*, é uma das principais ferramentas para BI e BDA, visto que fornece uma visualização de dados, geralmente em forma de gráficos ou tabelas, que ajudam o tomador de decisão a tomar uma decisão mais assertiva, além de analisar as tendências e criar indicadores (MURNAWAN; SAMIHARDJO; NUGRAHA, 2020).

A explosão da análise de dados nos últimos 30 anos e a era da BD, torna cada vez mais difícil capturar, formatar e visualizar os dados, por isso, os *dashboards* se tornaram uma maneira popular de disponibilizar rapidamente conjuntos de dados importantes.

## 2.6 CONSIDERAÇÕES SOBRE A SEÇÃO

Essa Seção apresentou os principais temas abordados nessa pesquisa. Ressaltando alguns autores que definiram a I4.0 e demonstraram sua relação com a TQM, deixando em aberto a necessidade de pesquisas futuras nessa área. Foram

destacadas as principais características da BD de acordo com a literatura, demonstrando que autores atribuem diferentes características a esses dados que formam os Vs da BD, usados para entender melhor o que engloba essa era de produção de dados em massa.

A BDA é uma técnica muito utilizada dentro da BD por grandes empresas que desejam entender os dados e transformá-los em conhecimento acionável para a tomada de decisão. Por sua vez, as plataformas *on-line* são utilizadas como ferramentas que auxiliam todo o processo de tomada de decisão, fornecendo visualizações e acesso a dados de forma centralizada, com o auxílio de *dashboards*, resultantes da análise da BD.

### 3 METODOLOGIA

Essa Seção apresenta o caminho metodológico seguido para a construção da pesquisa. A pesquisa científica é um processo que envolve perguntas e investigação, cujo objetivo é ampliar o conhecimento humano. Por ser um processo complexo, a pesquisa científica pode ser caracterizada de diversas formas, apresentadas a seguir.

#### 3.1 CARACTERIZAÇÃO DA PESQUISA

Do ponto de vista de sua natureza, a pesquisa caracteriza-se como aplicada. Conforme Gil (1999) a pesquisa aplicada produz conhecimentos para a execução na prática e direcionado à solução de problemas específicos. Assim, este trabalho investiga formas de integrar a tecnologia à gestão de qualidade na indústria automobilística. Após sua devida divulgação por meio de publicações científicas, este trabalho de pesquisa poderá também ser aplicado por outras empresas.

Do ponto de vista de sua abordagem, a pesquisa caracteriza-se como qualitativa, pois tem como objetivo interpretar e descrever um processo de disponibilização de dados (SILVA; MENEZES, 2005). A pesquisa qualitativa propicia o entendimento de determinado evento, sendo estudados os aspectos relevantes relacionados a este, por meio de perspectivas de pessoas e discussões científicas (GODOY, 1995).

Quanto aos seus objetivos, a pesquisa é classificada como exploratória, pois conforme Gil (2008), a pesquisa exploratória busca proporcionar maior familiaridade com o problema em estudo, construindo hipóteses e envolvendo levantamento bibliográfico e de experiências práticas, visando conhecer melhor a variável de estudo, seus significados, suas implicações, entre outros aspectos.

Quanto aos procedimentos técnicos, pode ser classificada como um estudo

de caso, pois envolve o estudo profundo de um tópico de maneira que permita o seu amplo e detalhado conhecimento (GIL, 1991), que de acordo com Yin (2001), pode também ser conceituado como a busca pela compreensão e interpretação mais intensas dos fatos e acontecimentos específicos, e embora não possam ser generalizados, os resultados obtidos podem disseminar o conhecimento adquirido.

Após a classificação da pesquisa, foram definidos os procedimentos para atingir cada Objetivo Específico, permitindo cumprir o objetivo geral, bem como responder ao problema da pesquisa. Os procedimentos seguidos para a pesquisa são descritos na seção seguinte.

### 3.2 ORGANIZAÇÃO DA PESQUISA

Visando oferecer uma melhor compreensão da trajetória percorrida para a realização deste trabalho, o Quadro 6 traz uma síntese dos procedimentos seguidos em cada etapa. Nas Subseções seguintes, cada uma dessas etapas será fundamentada de acordo com a literatura, e os procedimentos apresentados em detalhe.

Quadro 6 - Etapas dos procedimentos metodológicos

PARTES	ETAPAS	PROCEDIMENTOS	PRINCIPAIS AUTORES	OBJETIVOS ATINGIDOS
<b>PARTE I REVISÃO DE SISTEMÁTICA DE LITERATURA</b>	1ª Etapa – Revisão de literatura	<ul style="list-style-type: none"> <li>- Bibliometria;</li> <li>- Leitura sistemática e análise de conteúdo;</li> <li>- Definição do problema e pergunta de partida;</li> <li>- Pesquisa exploratória sobre técnicas de manipulação e exibição de dados.</li> </ul>	Pagani; Kovaleski e Resende (2015; 2017)	Definido o problema de pesquisa e realizado o levantamento das técnicas e tecnologias para manipulação da <i>Big Data</i> e <i>Big Data Analysis</i> (OE1).
<b>PARTE II PESQUISA DE CAMPO</b>	2ª Etapa - Pesquisa de campo na empresa multinacional do ramo automobilístico	<p>Observação assistemática para:</p> <ul style="list-style-type: none"> <li>- Identificar quais são os indicadores de defeitos na produção;</li> <li>- Identificação de como são realizados os procedimentos para coleta e disponibilização de dados;</li> <li>- Identificação dos sistemas e outros mecanismos disponíveis para auxiliar nesse processo.</li> </ul>	Caregnato e Mutti (2006), Cappelle, Melo e Gonçalves (2003) e Campos (2004)	Compreendidos os indicadores TQM para a detecção dos defeitos que são utilizados pela indústria automobilística, objeto deste estudo, além levantar os requisitos da plataforma (OE2).
	3ª Etapa - Análise das informações coletadas na pesquisa de campo	<ul style="list-style-type: none"> <li>- Análise de discurso dos supervisores de produção e equipe de qualidade.</li> <li>- Análise documental dos relatórios de qualidade, além da visualização dos sistemas utilizados.</li> </ul>		
<b>PARTE III DESENVOLVIMENTO DA PLATAFORMA ON-LINE</b>	4ª Etapa - Desenvolvimento da plataforma on-line	<ul style="list-style-type: none"> <li>- Definição dos requisitos de funcionalidade da plataforma, por meio do conceito Mínimo Produto Viável (MVP);</li> <li>- Utilização de <i>software</i> para análise e visualização de dados e implementação da plataforma on-line.</li> </ul>	Ko e Chang (2017), Tripathi <i>et al.</i> (2019), Tableau (2020).	Proposta a adaptação às mudanças tecnológicas da I4.0 a gestão e o acompanhamento dos indicadores de defeitos na produção da indústria automobilística (OE3 e OG).
	5ª Etapa - Análise dos resultados alcançados	<ul style="list-style-type: none"> <li>- Avaliação dos ganhos do projeto;</li> <li>- Explicação sobre o relacionamento entre os temas dessa pesquisa.</li> </ul>	Lô e Diochon (2019)	

Fonte: Elaborado pela autora (2020)

Os procedimentos metodológicos desta pesquisa foram realizados em três etapas: (1) metodologia para a construção do portfólio de artigos para o desenvolvimento teórico da pesquisa, (2) pesquisa de campo exploratória para identificar os indicadores, e (3) metodologia para o desenvolvimento da plataforma *on-line*.

### 3.3 ELABORAÇÃO DA REVISÃO SISTEMÁTICA DE LITERATURA

Para realizar a construção do portfólio de artigos científicos para a Revisão Sistemática de Literatura, foi empregada a *Methodi Ordinatio* (Pagani, Kovaleski e Resende, 2015; 2017).

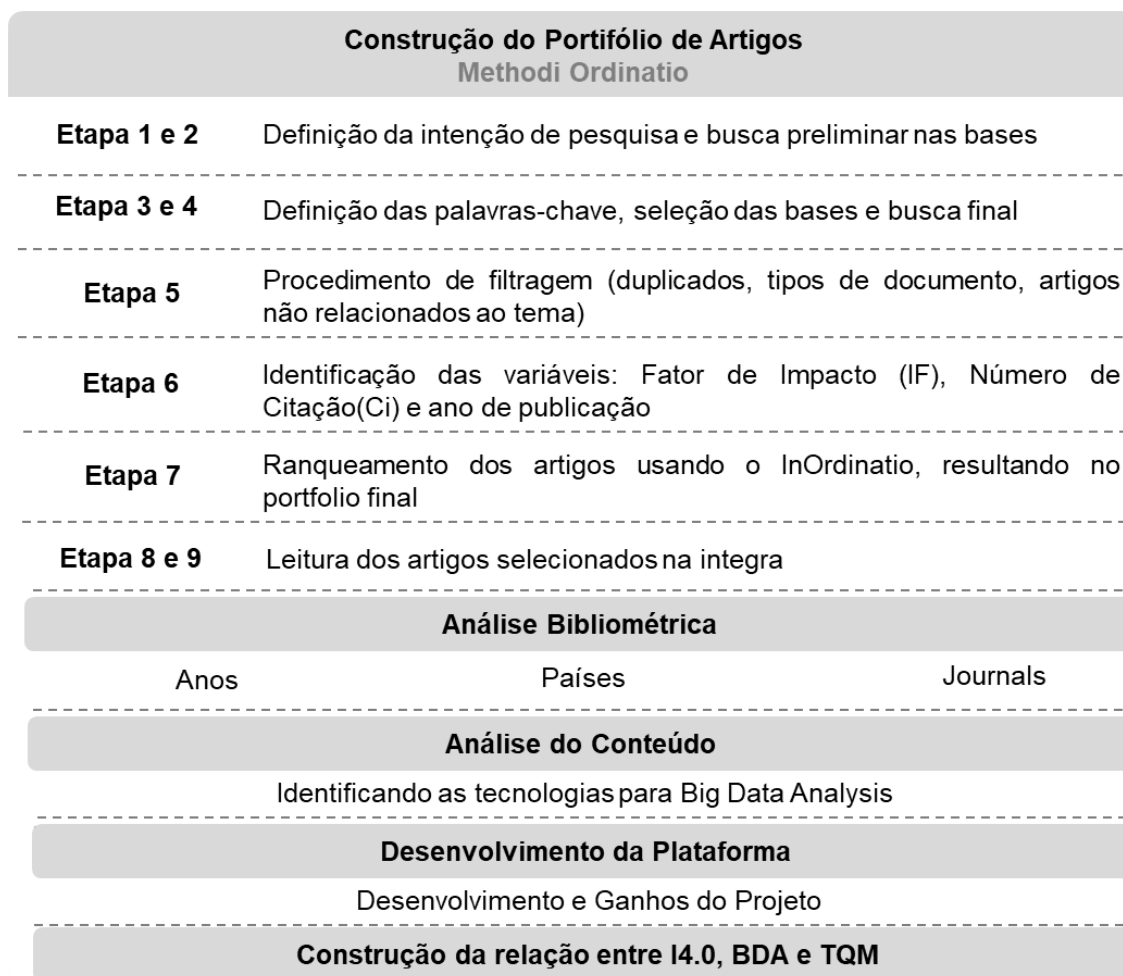
Trata-se de uma ferramenta de decisão multicritério que permite a ordenação de artigos considerando três variáveis: Ano de publicação, Fator de impacto (Fi) e Número de citação (Ci) do artigo. A partir da ponderação das três variáveis ocorre a ordenação de um portfólio de artigos, por meio da equação *InOrdinatio*, que indica a relevância científica do artigo.

Por meio dessa ordenação de artigos é possível classificar os trabalhos individualmente, o que, diante da grande quantidade de artigos resultantes da pesquisa, proporciona uma maneira de selecionar os trabalhos mais adequados com crivo científico, otimizando a tarefa do pesquisador sem comprometer a qualidade científica.

A comunidade científica considera essa combinação de fatores relevantes, como detalhado em Pagani, Kovaleski e Resende (2015; 2017), e validado por outros autores (GAO; MELERO; SESE, 2019; SOUZA *et al.*, 2019; CORSI *et al.*, 2020).

Para melhor compreensão da revisão de literatura, foi elaborada a Figura 14, que resume os procedimentos seguidos.

**Figura 14 - Metodologia para a revisão de literatura**



**Fonte: Elaborado pela autora (2020)**

Deste modo, este estudo utilizará essa metodologia para a construção do portfólio de artigos científicos permitindo a revisão sistemática de literatura. Considerando o protocolo proposto por Pagani, Kovaleski e Resende (2015; 2017), as etapas para a presente pesquisa foram construídas, e são detalhadas a seguir.

*Etapa 1* – Estabelecimento da intenção de pesquisa: neste estudo, a intenção de pesquisa baseou-se na busca por processos, ferramentas, modelos e outras informações sobre a manipulação e disponibilização de uma grande quantidade de dados.

*Etapa 2* – Pesquisa exploratória preliminar de palavras-chave em bancos de dados: a busca sobre a temática foi realizada em três banco de dados: Scopus, Web



of Science, Science Direct e IEEE Xplore.

*Etapa 3* – Na realização das buscas nas bases de dados, não foi utilizado recorte temporal visando abranger o início dos estudos que apresentam a junção dos temas TQM e I4.0. Algumas configurações foram adotadas, sendo elas:

- *Scopus*: Pesquisa por título, resumo e palavras-chave, selecionando somente artigos e revisões, utilizando o operador (\*) ao fim das palavras;
- *Web of Science*: Pesquisa por tópico, selecionando somente artigos e revisões, utilizando o operador (\*) ao fim das palavras;
- *Science Direct*: Pesquisa por título, resumo e palavras-chave, selecionando somente artigos e revisões. A base não permite a utilização do operador booleano (\*), e
- *IEEE Xplore*: Pesquisa por *All Metadata*, selecionando publicações em *Journals*, utilizando o operador (\*) ao fim das palavras.

*Etapa 4* – Busca final nas bases de artigos: realizada a partir da definição das combinações de palavras chaves e das bases de dados, sendo o resultado obtido conforme Tabela 1. Nessa etapa foram definidos 4 eixos de pesquisa, sendo o eixo 1 sobre big data analysis e plataformas, o eixo 2 abordando qualidade e indústria 4.0, o eixo 3 integrando qualidade, indústria e big data analysis, e o eixo 4 tratando sobre qualidade, indústria 4.0 e transferência de tecnologia.

Tabela 1 – Resultados das buscas nas bases de dados

		COMBINAÇÕES DE PALAVRAS CHAVE	Scopus	Web Of Science	Science Direct	IEEE	TOTAL
EIXO 1	1	("dashboard" OR "platform") AND "big data analy*"	558	300	81	75	1014
	2	("platform" OR "dashboard") AND "performance indicat*" AND "big data analy*"	1	2	0	0	3
EIXO 2	3	("total quality management" OR "quality management") AND "industr* 4.0"	23	19	5	0	47
	4	("total quality management" OR "quality management") AND "integrated industr*"	2	1	0	0	3
EIXO 3	5	("quality management" OR "total quality management") AND "big data analy*" AND "industry 4.0"	0	0	0	0	0
	6	("quality management" OR "total quality management") AND "big data analy*" AND "integrated industry"	0	0	0	0	0
EIXO 4	7	("quality management" OR "total quality management") AND "technology transfer" AND "industry 4.0"	0	0	0	0	0
	8	("quality management" OR "total quality management") AND "technology transfer" AND "integrated industry"	0	0	0	0	0
		<b>TOTAL DE ARTIGOS</b>			<b>1.067</b>		

Fonte: Elaborado pela autora, com base em dados da Scopus, Web of Science, Science Direct e IEEE Xplore (2020)

As combinações dos Eixos 3 e 4 não retornaram nenhum documento, evidenciando uma lacuna na literatura que pode ser explicada devido a multidisciplinariedade da pesquisa desse trabalho ou pela falta de divulgação de pesquisas que relatem essas ações em indústrias.

*Etapa 5 – Procedimentos de filtragem:* com o objetivo de selecionar apenas artigos diretamente relacionados ao tema de pesquisa e eliminar trabalhos em duplicidade, foram aplicados critérios de filtragem: eliminação de artigos em duplicidades, utilizando o gerenciador de referências Mendeley; exclusão por tipo de documento (artigos de conferência e congresso), também utilizando o gerenciador de referências; eliminação por conteúdo. O resultado obtido nesse processo foi, conforme Tabela 2.

Tabela 2 – Procedimentos de filtragem

PROCEDIMENTO DE FILTRAGEM	COMBINAÇÕES					
	EIXO 1		EIXO 2		EIXO 3	
	1	2	3	4	1	2
Eliminação de duplicatas	372	1	12	0	0	0
Eliminação por tipo de documento	96	0	9	1	0	0
Eliminação por leitura de título	132	0	13	2	0	0
Eliminação por leitura de resumo	255	0	3	0	0	0
Eliminação por leitura completa	89	0	0	0	0	0
<b>Total de artigos eliminados</b>	<b>944</b>	<b>1</b>	<b>37</b>	<b>3</b>	<b>0</b>	<b>0</b>
<b>Restante de artigos por combinação no portfólio</b>	<b>70</b>	<b>2</b>	<b>10</b>	<b>0</b>	<b>0</b>	<b>0</b>
<b>Total de artigo no portfólio</b>	<b>82</b>					

Fonte: Elaborado pela autora (2020)

A exclusão por conteúdo se deu, primeiramente, por meio da leitura de título e palavras chave, e em caso de dúvida por meio da leitura do resumo ou artigo completo. Após as exclusões o Eixo 3 ficou com zero documentos, apresentando mais uma lacuna da literatura proveniente da combinação desses temas.

*Etapa 6* – Identificando o fator de impacto, ano e número de citações: o fator de impacto selecionada para atribuir a importância ao periódico foi o JCR (*Journal Citation Reports*), caso a revista não apresente essa métrica, a sequência de métricas adotadas foram: CiteScore, *Scientific Journal Rankings* – SJR e *Source Normalized Impact per Paper* – SNIP.

Se o periódico não apresenta nenhuma dessas métricas, o valor atribuído ao Fi do artigo é zero. O ano de publicação é coletado no próprio artigo e por fim, o número de citações (Ci), que é encontrado no Google Scholar.

*Etapa 7* – Classificando os artigos: Essa fase busca classificar cada artigo de acordo com sua relevância científica, por meio da equação 1, denominada InOrdinatio:

$$InOrdinatio = (IF/1000) + \alpha * [10 - (\text{AnoPesquisa} - \text{AnoPublicação})] + (Ci) \quad (1)$$

Em que:

- IF é o Fator de Impacto;

- $\alpha$  é um fator de ponderação variando de 1 a 10 atribuído pelo pesquisador e quando mais próximo do 10 maior importância da atualidade do tema;
- AnoPesquisa é o ano em que a pesquisa foi realizada;
- AnoPublicação é o ano em que o artigo foi publicado;
- Ci é a quantidade de citações do artigo.

Dentro dessa etapa, outras duas sub-etapas fizeram-se necessárias. Devido ao trabalho apresentar 2 eixos de pesquisa distintos, a ordenação também foi dividida em duas partes, sendo na primeira ordenado todos os artigos do eixo 1 (combinação 1 e 2) e depois, todos os artigos do eixo 2 (combinação 3 e 4).

Essa divisão pode ser melhor visualizada no Apêndice A - Portfólio de artigos ordenados nesta pesquisa, conforme Tabela 8 e Tabela 9.

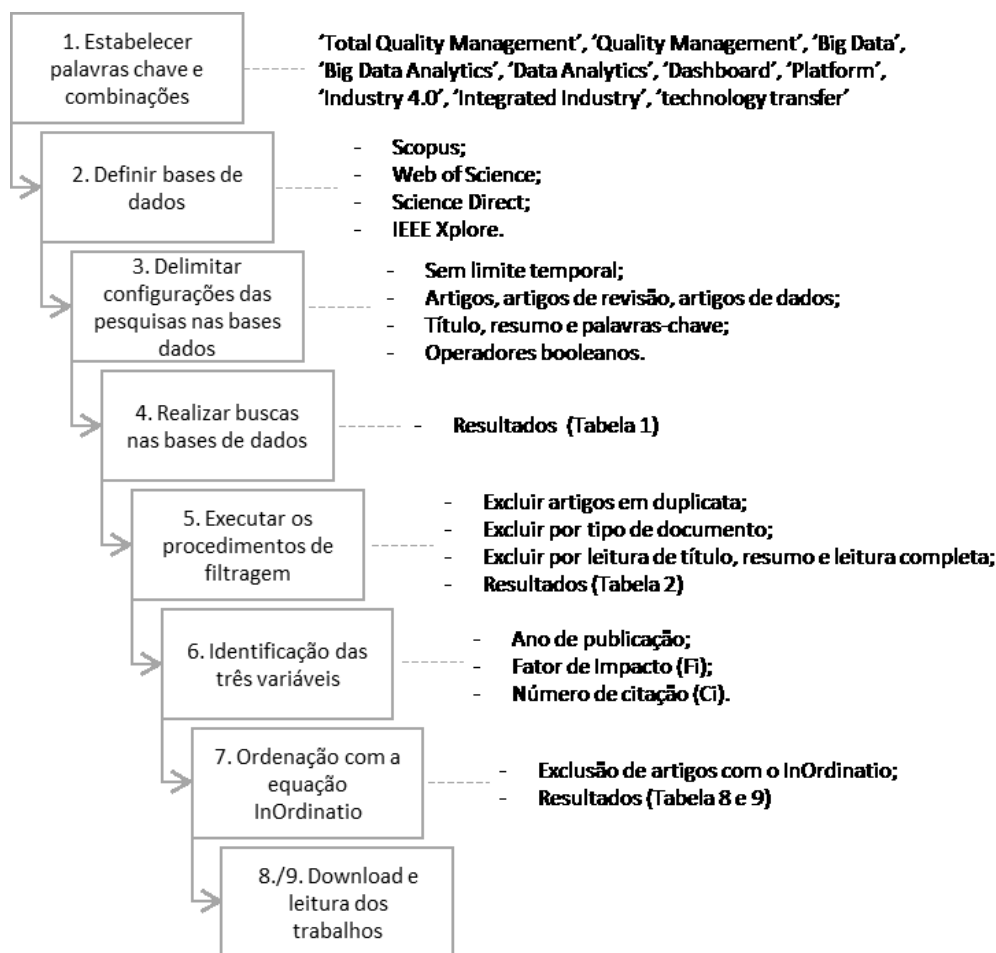
Após a ordenação dos artigos, definiu-se como critério de leitura, que todos os artigos dos anos de 2018, 2019 e 2020 seriam lidos, por possivelmente apresentarem ferramentas mais atuais em relação ao tema estudado, e estabelecendo assim que o menor valor InOrdinatio de 2018 seria usado como linha de corte para os demais artigos. Ou seja, todos os artigos com InOrdinatio igual o maior que 80 foram selecionados.

Essa filtragem justifica a utilização da metodologia de pesquisa Methodi Ordinatio, para compor o portfólio de artigos conforme relevância aceita pela comunidade científica.

*Etapa 8* – Encontrando os artigos completos: apenas um artigo, ranqueado na fase anterior, não foi encontrado em sua versão completa, todos os demais serão discutidos no decorrer deste estudo, totalizando 70 artigos.

*Etapa 9* - Leitura final e análise sistemática de artigos: Após classificados em ordem de relevância, os artigos foram lidos e analisados em sua totalidade. Por fim, a síntese da aplicação do Methodi Ordinatio (Pagani *et al.*, 2015), pode ser observado na Figura 15.

**Figura 15 – Etapas para a construção do portfólio de artigos científicos**



Fonte: Adaptado de Pagani, Kovaleski e Resende (2015; 2017)

### 3.3.1 Análise Bibliométrica

As análises bibliométricas cresceram rapidamente devido aos pesquisadores usarem esse método para rastrear a quantidade de publicação de artigos e patentes sobre determinados assuntos para embasar suas pesquisas, o que a tornou uma referência amplamente aceita (MOTOYAMA; EISLER, 2011).

Neste trabalho, todos os 60 artigos do eixo 1 e os 10 artigos do eixo 2, foram analisados separadamente, com o objetivo de se obter um panorama bibliométrico geral, a análise foi realizada a partir dos dados relacionados aos artigos, em que foram levantadas informações como o número de publicação em cada ano e os

países que mais publicam sobre os assuntos.

### 3.3.2 Análise de Conteúdo

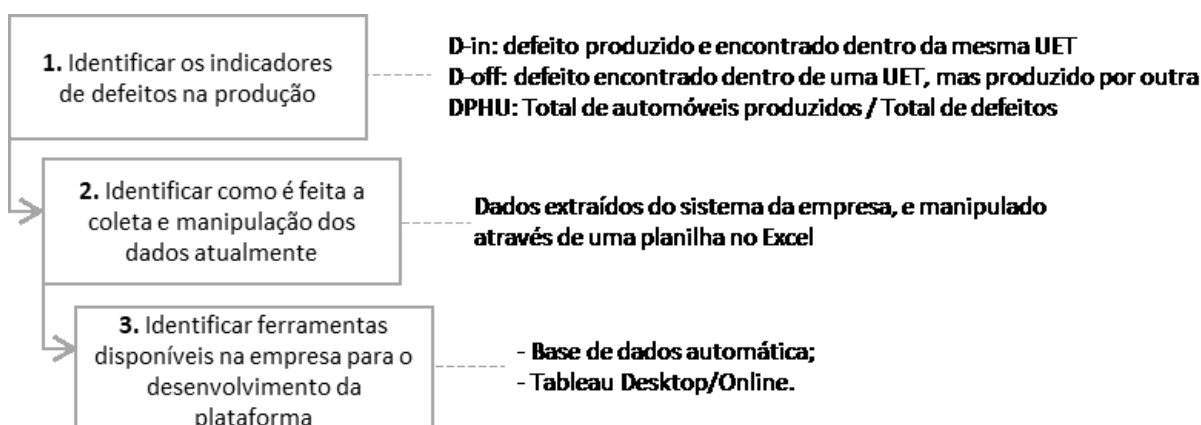
A análise de conteúdo consistiu na leitura dos documentos disponíveis no portfólio final de artigos utilizado nessa pesquisa, buscando informações sobre tecnologias e técnicas para BDA.

Essas informações foram posteriormente organizadas em formato de texto, tabela, quadros e figuras, e apresentados na Seção 2, de referencial teórico, além de permear todas as outras seções desse trabalho. Essa análise serviu para a construção do embasamento teórico e também para a construção da plataforma online, além de fornecer base teórica para a pesquisa de campo.

## 3.4 PESQUISA DE CAMPO

Após a revisão de literatura, foi realizada a pesquisa de campo, que foi estruturado em 3 etapas conforme apresenta Figura 16.

**Figura 16 – Etapas para realização da pesquisa de campo**



Fonte: Elaborado pela autora (2020)

Para que fosse possível obter as informações de cada etapa, empregou-se o

uso da observação assistemática participante, que compreende a observação um tipo de pesquisa que não possui um planejamento ou um projeto anterior à prática, sendo que o mesmo só será construído junto aos participantes, que são os objetos de pesquisa, essa observação se caracteriza pela interação entre o pesquisador e os demais membros das situações pesquisadas (LAKATOS; MARCONI, 2005, GIL, 2008).

A primeira etapa consistiu em identificar quais eram os indicadores de defeitos na produção utilizados pela empresa. Essa etapa se deu através do acompanhamento pessoal realizado durante 24 horas semanais, em um período de 12 meses dentro da empresa.

Com essa rotina foi possível coletar dados sobre os indicadores, que foram analisados de forma qualitativa, por meio de reuniões com equipes relacionadas a área da qualidade da empresa e observação assistemática, sendo as técnicas de análise de discurso utilizada nesse momento (CAREGNATO; MUTTI, 2006; CAPPELLE; MELO; GONÇALVES, 2003; CAMPOS, 2004).

Com isso foi definido com os supervisores de qualidade da empresa, que os indicadores DPU-in e DPU-off, deveriam ser priorizados devido ao alto custo envolvido com tarefas como retrabalho e descarte de peças danificadas.

Por meio do acompanhamento presencial de como os dados eram coletados, analisados e visualizados, foi possível ter uma visão geral de como o processo funcionava e quais seriam os requisitos do sistema.

A partir disso, foi possível verificar quais eram as ferramentas disponíveis na empresa para que a construção da plataforma on-line fosse possível, entrando em contato com os responsáveis pela área de Tecnologia da Informação (TI). Depois disso, teve início a próxima etapa que compreende a construção da plataforma.

#### *3.4.1 Análise das Informações Coletadas na Pesquisa de Campo*

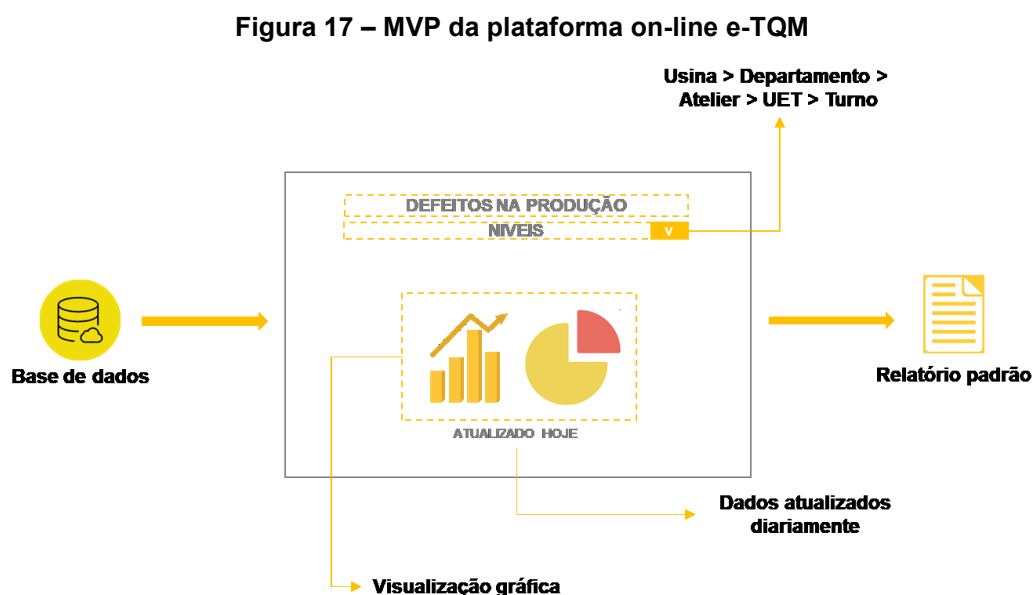
A análise de discurso dos supervisores de produção e da equipe de qualidade, foi realizada por meio de anotações em planilhas eletrônicas e em documentos de textos. Essas informações, aliadas a análise documental dos

relatórios de qualidade e da visualização dos sistemas utilizados, serviram para nortear o desenvolvimento da plataforma.

### 3.5 METODOLOGIA DO DESENVOLVIMENTO DA PLATAFORMA ON-LINE

O primeiro procedimento realizado buscou definir quais os requisitos de funcionalidades precisavam estar na plataforma. Isso foi feito através da construção de um modelo *Minimum Viable Product* (MVP) é um conceito utilizado dentro da esfera de *Startups*. Este conceito implica no desenvolvimento do produto certo para se estabelecer no mercado. Para isso, desenvolvem um protótipo funcional para testar se atendem ou não as necessidades do público que desejam atingir (TRIPATHI *et al.*, 2019).

Assim, ao iniciar o projeto de uma plataforma *on-line* com foco em visualização de dados por meio de um *dashboard*, é necessário que uma visão prévia seja desenvolvida. Assim, a Figura 17 apresenta o MVP da plataforma *on-line* e-TQM, com as funcionalidades básicas necessárias para a indústria objeto deste estudo.



Fonte: Elaborado pela autora (2020)




Os requisitos representados no MVP são:

- *Base de dados*: formada por dados provenientes de diferentes sistemas utilizados dentro da empresa, com diferentes formatos;
- *Níveis*: permitem visualizar os dados gerais das usinas, departamento, dos ateliers (que são oficinas de fabricação), Unidade de Trabalho Elementar (UET) e turno de trabalho.
- *Visualização gráfica*: o *dashboard* gráfico sinaliza a parte mais importante da plataforma *on-line*, pois servem para comunicar os dados de forma mais intuitiva.
- *Relatório padrão*: a empresa possui seus relatórios padronizados que serão gerados automaticamente pela plataforma e-TQM.

Com a visão geral construída exemplificando o objetivo a ser atingido com a construção da plataforma, os próximos passos do projeto foram dados, conforme Figura 18.

**Figura 18 - Etapas para o desenvolvimento da plataforma on-line**



Fonte: Elaborado pela autora (2020)

O primeiro passo consistiu em desenvolver a plataforma, a partir das informações coletadas na pesquisa de campo, que mostraram quais eram os indicadores que deveriam estar presentes na plataforma, quais eram as necessidades de análises para acompanhamento dos supervisores de produção e quais ferramentas de apoio estavam disponíveis na empresa para a construção da plataforma.

Então, os dados reais de defeitos de produção foram conectados a ferramenta de análise Tableau Desktop (TABLEAU, 2020), e os gráficos e tabelas de

acompanhamento foram desenvolvidos, sendo apresentados para os supervisores sempre que finalizados, visando saber se realmente atendiam a suas necessidades.

Depois disso, a plataforma foi publicada on-line, sendo possível ser acessada de qualquer lugar pelos supervisores de produção e outros responsáveis pelo acompanhamento dessas informações.

Seguindo esses passos foi possível desenvolver a plataforma on-line e-TQM, que será apresentada na Seção 4, desse trabalho.

### 3.5.1 *Análise dos Resultados Alcançados*

Uma avaliação dos ganhos do projeto foi realizada com a plataforma concluída. Essa avaliação consistiu em verificar quanto tempo era empregado nas atividades relacionados aos indicadores de defeitos na produção, antes da automatização do processo.

Com a visão dos ganhos, foi possível evidenciar o relacionamento entre os temas dessa pesquisa, em uma situação real, que abrangeu o embasamento teórico e prático.

## 3.6 CONSIDERAÇÕES SOBRE A SEÇÃO

Essa Seção descreveu de forma detalha como os procedimentos da pesquisa foram realizados. Inicialmente, a caracterização da pesquisa é feita para demonstrar quais são os tipos de estudo contemplados por esta pesquisa. Em seguida, apresenta-se a organização da pesquisa, ou seja, os passos necessários para sua realização, contemplando cada parte, etapa, procedimento, quais os principais autores relacionados e quais objetivos foram atingidos.

Após, foi descrito a revisão bibliográfica sistemática *Methodi Ordinatio* utilizada, com cada uma das duas etapas, que resultou no portfólio final composto por 70 artigos, utilizados na construção da análise bibliométrica e da análise de

conteúdo, que também são descritas. A revisão de literatura, juntamente com as análises permitiu que todas as demais etapas da pesquisa fossem possíveis, por meio das informações que forneceu, atingindo assim, o OE1.

A metodologia para a Pesquisa de Campo e para o desenvolvimento da plataforma também são apresentados, sendo os resultados dessas metodologias apresentadas a seguir, na Seção 4.

## 4 ANÁLISE E DISCUSSÃO DOS RESULTADOS

Nessa Seção os resultados serão apresentados e discutidos, sendo divididos conforme apresentado na Metodologia. Dessa forma, (4.1) Resultados da Revisão de Literatura, (4.2) Resultados da Pesquisa de Campo e o (4.3) Desenvolvimento da Plataforma, são descritos a seguir.


### 4.1 RESULTADOS DA REVISÃO DE LITERATURA

A revisão de literatura abrange os resultados da análise bibliométrica, que apresenta uma análise qualitativa do portfólio de artigos desse trabalho, e a reunião das técnicas e tecnologias para BDA mencionadas pelos autores.

#### 4.1.1 *Resultados da Análise Bibliométrica*

Assim como apresentado na Seção de metodologia, as análises bibliométricas também estão divididas por assunto, sendo o eixo 1 sobre *Big Data Analysis* e plataformas, e no eixo 2 abordando Qualidade e Indústria 4.0. O número de publicações por ano pode ser observado na Figura 19.

Uma média de 8,5 artigos foram publicados em cada ano, entre 2014 e 2020, que englobavam os temas dessa pesquisa. Em 2020, até o mês de abril em que este trabalho foi realizado, seis artigos haviam sido publicados. Os últimos três anos apresentam um total de 44 artigos, representando 73,34% do total de publicações selecionados para compor o eixo 1 de pesquisa. Assim, esta pesquisa possui um caráter atual.

**Figura 19 – Quantidade de artigos publicados por ano no eixo 1**

**Fonte:** Elaborado pela autora, com base em dados da Scopus, Web of Science, Science Direct e IEEE Xplore (2020)

Apesar da base de artigos representada neste gráfico possuir esta tendência, o assunto discutido no presente trabalho relativo aos temas: BDA, I4.0 e TQM, até a data de levantamento deste portfólio não possuiu nenhum artigo tratando desta temática de forma específica. Portanto, trata-se de um novo estudo na academia.

Em relação ao número de publicação por país, foi realizada a análise baseada nos países das afiliações dos autores do artigo, levando em consideração que um mesmo artigo pode ter mais de um autor, e, portanto, mais de uma filiação. Dessa forma, um país pode pontuar mais de uma vez no mesmo estudo. Assim, é possível observar na Tabela 3, os países dispostos em ordem decrescente em relação ao número de artigos publicados presentes nesse portfólio.

Observando a Tabela 3, é possível perceber que Estados Unidos e Índia lideram com maior número de publicações de artigos, seguido pela China, Coréia do Sul e Malásia. Uma grande e diversa quantidade de países aparece nessa análise, indicando que a pesquisa possui um foco de estudo de interesse mundial.

**Tabela 3 – Quantidade de artigos publicados por país no eixo 1**

País	Artigos	País	Artigos
Estados Unidos	40	Estônia	2
Índia	25	Geórgia	2
China	18	Grécia	2
Coreia do Sul	14	Iraque	2
Malásia	12	Noruega	2
Itália	11	Portugal	2
Alemanha	10	Singapura	2
Espanha	10	Turquia	2
Paquistão	10	Arábia Saudita	1
Brasil	9	Austrália	1
Canadá	9	Emirados árabes	1
Reino Unido	8	Hong Kong	1
Taiwan	7	Japão	1
Holanda	4	Qatar	1
Costa Rica	3	Suécia	1

Fonte: Elaborado pela autora, com base em dados da Scopus, Web of Science, Science Direct e IEEE Xplore (2020)

Na Tabela 4, são apresentados os *Journals* com maior representatividade dentro deste portfólio. É notado que apenas dois dos 48 periódicos publicaram mais de dois artigos: IEEE Access e o Journal of Big Data, evidenciando assim uma grande abrangência de publicações sobre o tema.

**Tabela 4 – Relação da representatividade dos periódicos do eixo 1**


Journal	Fator de Impacto	Artigos	Representatividade e (%)
IEEE Access	3,557	6	10%
Journal of Big Data	8,510	4	7%
Computers and Electrical Engineering	1,747	2	3%
Future Generation Computer Systems	4,760	2	3%
International Journal of Information Management	4,516	2	3%
International Journal of Recent Technology and Engineering	0,000	2	3%
Demais Journals	-	42	70%
<b>Total</b>	-	<b>60</b>	<b>100%</b>

Fonte: Elaborado pela autora, com base em dados da Scopus, Web of Science, Science Direct e IEEE Xplore (2020)

O portfólio de artigos do eixo 2 também foi analisado quanto a quantidade de

artigos publicados por ano, apresentado na Figura 20. O total de 10 artigos compõem esse eixo, sendo seis artigos de 2019 e quatro artigos de 2020. Dessa forma, o portfólio se caracteriza por conter artigos com temática atual.

**Figura 20 – Quantidade de artigos publicados por ano no eixo 2**



**Fonte: Elaborado pela autora, com base em dados da Scopus, Web of Science, Science Direct e IEEE Xplore (2020)**

Com um total de 15 países representados no portfólio, apresentando cada uma pelo menos um artigo publicado sobre a temática, o eixo de pesquisa 2, evidencia o interesse pelo tema em diversos países, conforme Tabela 6.

**Tabela 5 – Quantidade de artigos publicados por país no eixo 2**

País	Artigos
Reino Unido	3
Malásia	2
Israel	2
Turquia	2
Chile	2
Hungria	2
Eslováquia	1
República Tcheca	1
Estados Unidos	1
România	1
Polônia	1
Suécia	1
Arábia Saudita	1
Tailândia	1
Áustria	1

**Fonte: Elaborado pela autora, com base em dados da Scopus, Web of Science, Science Direct e IEEE Xplore (2020)**

Na Tabela 7, são citados os *Journals* com maior fator de impacto presentes no eixo de pesquisa 2. O eixo abrangeu o total de 10 diferentes periódicos, demonstrando a interdisciplinaridade e pulverização dos temas.

**Tabela 6 – Periódicos com maior fator de impacto presente no eixo 2**

<b>Journal</b>	<b>Fator de Impacto</b>	<b>Artigos</b>
Journal of Cleaner Production	5,651	1
Journal of Manufacturing Technology Management	2,194	1
International Journal of Quality and Service Sciences	1,100	1
Journal of Systems and Control	0,680	1
Organizacija	0,430	1
Social Sciences	0,109	1
Demais Journals	-	4
<b>Total</b>	-	<b>10</b>

**Fonte:** Elaborado pela autora, com base em dados da Scopus, Web of Science, Science Direct e IEEE Xplore (2020)

#### 4.1.2 *BIG DATA ANALYTICS E SUAS TECNOLOGIAS*

Como resultado da análise de conteúdo foram identificadas as técnicas e tecnologias de BDA, compreendendo o processo para se obter uma informação da *Big Data*, que pode ser dividido em seis fases, sendo elas geração de dados, aquisição de dados, armazenamento e gerenciamento de dados, processamento de dados, recuperação de dados e análise e visualização de dados (MA, 2019).

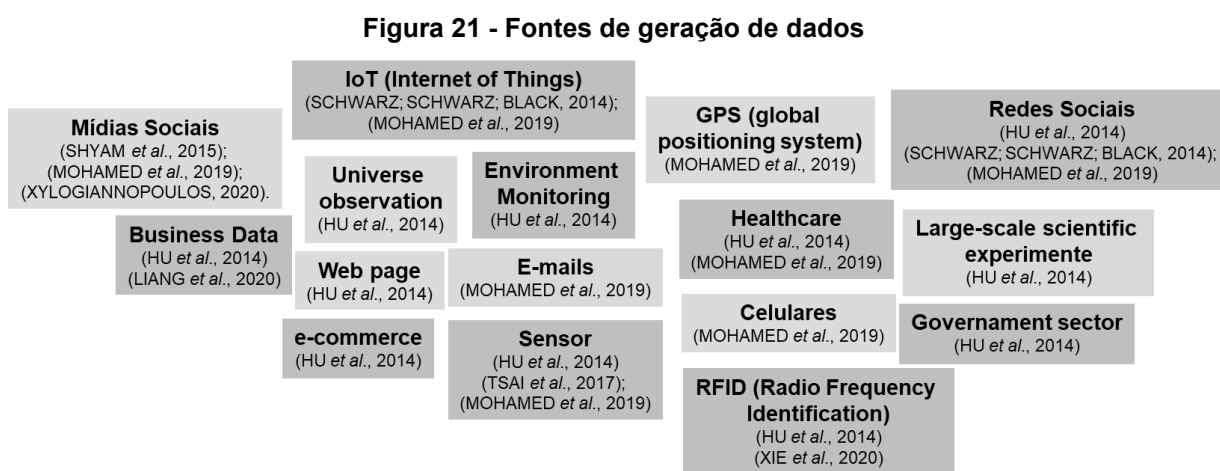
Sendo assim, foram reunidas técnicas e tecnologias utilizadas em cada uma dessas fases, de acordo com a literatura, evidenciando o autor mais antigo e o mais atual a citar o uso da tecnologia. Os resultados são apresentados nas subseções seguintes.

##### 4.1.2.1 Geração de dados

O processo de geração de dados pode acontecer de diferentes formas advindas de fontes distintas. No Figura 21, algumas dessas fontes são apresentadas



pelos autores.



As mídias sociais e as redes sociais representam as plataformas que estão disponíveis na internet que são alimentadas diariamente por seus usuários com conteúdo como: texto, fotos, áudios e vídeos.

O mesmo acontece com as páginas na web, que apresentam muitos conteúdos que podem ser acessados por milhões de pessoas a qualquer momento, e ainda servem como plataforma de venda de produtos e serviços, como no caso do e-commerce.

Nesse contexto, o uso do e-mail é essencial, pois representa um contato online requerido para acessar boa parte dessas plataformas, assim, muitas informações circulam de uma plataforma a outra, gerando dados em alta velocidade.

É comum que para ter acesso a todas essas informações o usuário utilize um celular, que além de acessar todas essas plataformas, ainda gera dados relacionados a localização por meio do Global Position System (GPS).

Os setores empresariais, da saúde e do governo, também são citados como potenciais geradores de dados, devido à grande quantidade de informações que circulam dentro desses ambientes.

Juntamente com diversas outras tecnologias da I4.0, a IoT e os sensores que monitoram o ambiente também são mencionados como gerados de dados, pois

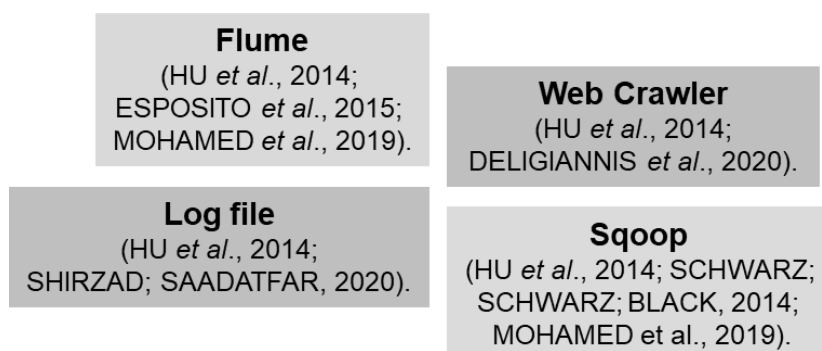
estão presentes no ambiente industrial, e também no dia a dia de muitas pessoas através de eletrodomésticos que possuem outras tecnologias atreladas a sua função principal, nesse contexto também está presente o RFID, que consiste em um tag que é lida por um leitor e que coleta automaticamente as informações contidas nela, que podem ser informações sobre produtos por exemplo (XIE *et al.*, 2020).

Por fim, as observações do universo e experimentos científicos em larga escala produzem muitos dados, que podem ser não estruturados, o que aumenta ainda mais a complexidade para aquisição desses dados da sua fonte de origem, para tratar essa questão, a subseção seguinte irá abordar as tecnologias e técnicas utilizadas nesse processo.

#### 4.1.2.2 Aquisição de dados

Após o processo de geração de dados, é necessário que esses dados sejam coletados, e em alguns casos, armazenados em seguida. Nessa perspectiva, alguns autores apontam ferramentas para esse processo, conforme Figura 22.

**Figura 22 - Técnicas e tecnologias para aquisição de dados**



**Fonte: Elaborado pela autora (2020)**

O *Web Crawler* é um programa capaz de baixar o conteúdo de páginas *web*, e é muito utilizado na extração de informações de redes sociais e mídias sociais (HU *et al.*, 2014; DELIGIANNIS *et al.*, 2020).

O *Log file* adquire informações sobre diversas ocorrências e eventos realizados dentro de um sistema, fornecendo dados para estudos direcionados a

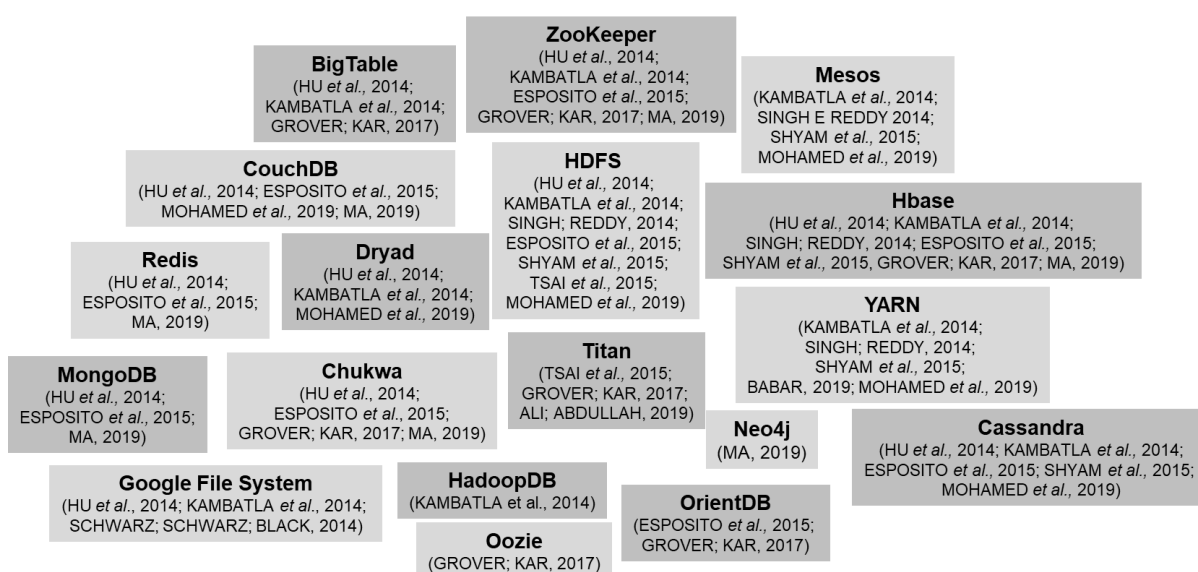
solução de problemas (HU *et al.*, 2014; SHIRZAD; SAADATFAR, 2020).

O Flume e o Sqoop são ferramentas que realizam a aquisição da BD. O Flume é um sistema distribuído que coleta, agrega e transfere com eficiência grandes quantidades de dados de fontes distintas para um armazenamento centralizado, enquanto que o Sqoop permite fácil importação e exportação de dados entre armazenamentos de dados estruturados e não estruturados (HU *et al.*, 2014; FLUME, 2020, SQOOP, 2020).

#### 4.1.2.3 Armazenamento e gerenciamento de dados

O gerenciamento dos dados coletados é essencial para que possam ser armazenados dentro do banco de dados escolhido. No Figura 23, é possível visualizar algumas tecnologias que ajudam nesse processo.

**Figura 23 - Técnicas e tecnologias para armazenamento e gerenciamento de dados**



Fonte: Elaborado pela autora (2020)

Grande parte das plataformas de gerenciamento e armazenamento de BD é baseada no Apache Hadoop, como Dryad e Mahout (MOHAMED *et al.*, 2019).

Em síntese, o Hadoop Distributed File System (HDFS), faz parte de um algo

maior, o ecossistema Hadoop, e consiste em dois componentes: (1) o HDFS, em que o armazenamento de dados entre os nós de um cluster é distribuído; e (2) o mecanismo Hadoop MapReduce, que atribui o processamento de dados ao nó onde ele reside, criando um mapeamento de dados.

O Hadoop foi desenvolvido baseado na modelo de programação MapReduce, capaz de processar grandes conjuntos de dados, estruturados ou não (MOHAMED *et al.*, 2019), e seu ecossistema conta com muitas outras aplicações que servem como complemento as funções principais.

No processo a integração e limpeza de dados, que são feitas para preparar o BD para o processamento, são usadas tecnologias como o Spark, Hadoop e Mesos (GHANI *et al.*, 2019).

Apache Mesos e o Apache YARD, que fazem parte do framework Apark. São responsáveis por gerenciar o cluster de servidores onde estão alocados os dados, e fornece isolamento eficiente de recursos e compartilhamento entre aplicativos e estruturas distribuídas (SINGH; REDDY, 2014).

Nesse contexto, o Zookeeper e o Chukwa são usados para gerenciar e monitorar aplicativos distribuídos que são executados no Hadoop. O Zookeeper é um serviço centralizado para manter a configuração, enquanto que o Chukwa é responsável por monitorar o status do sistema, além de exibir, monitorar e analisar os dados coletados (HU *et al.*, 2014; GROVER; KAR, 2017; MA, 2019).

Outro exemplo seria o Apache Oozie, um sistema de processamento de fluxo de trabalho, que define que uma determinada consulta só pode ser realizada depois que outra já tiver sido feita, por exemplo. É um sistema escalável, ou seja, seu desempenho aumenta com o crescimento de mais hardware, de agendador de fluxo de trabalho para gerenciar tarefas do Apache Hadoop (GROVER; KAR, 2017). O Hadoop YARN (Yet Another Resource Negotiator) (BABAR, 2019), possui funcionamento similar, pois atua na camada de gerenciamento de recursos e agenda as tarefas em todo o cluster de servidores (SINGH; REDDY, 2014).

No que se refere ao armazenamento dos dados, o termo NoSQL surge quando se trata de BD. Esse é um termo geral para um sistema de gerenciamento

de banco de dados diferente do banco de dados relacional, que manipulava dados estruturados. Os esquemas de armazenamento distribuído baseados em NoSQL incluem: MongoDB, CouchDB, HBase, Redis, Neo4j, entre outros (MA, 2019).

O HBase é um modelo usado para acesso rápido a dados, similar ao Big Table do Google, já o OrientDB é um banco de dados gráfico, de alto desempenho (GROVER; KAR, 2017), e o HadoopDB, é um banco de dados distribuído muito usando pelo Hadoop (KAMBATLA *et al.*, 2014).

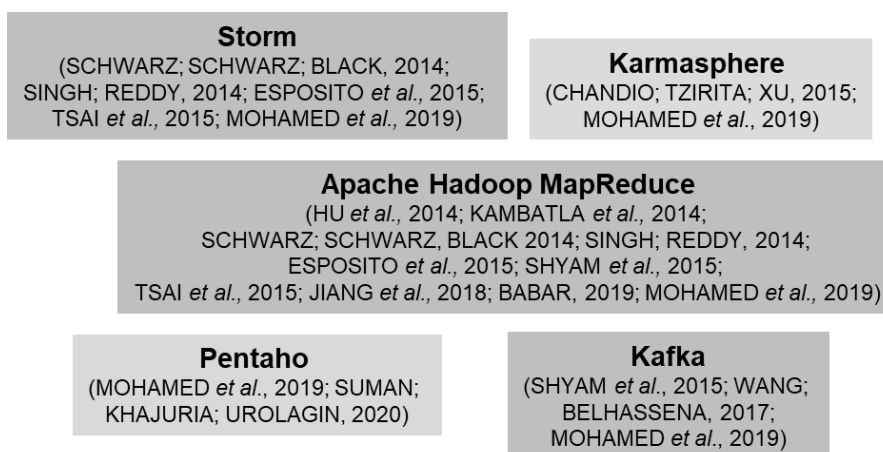
O Titan e o Cassandra, são bancos de dados distribuído projetado para escalabilidade que suporta a replicação em vários nós ou centros de dados (TSAI *et al.*, 2015; GROVER; KAR, 2017; ALI; ABDULLAH, 2019; MOHAMED *et al.*, 2019).

Por fim, o Google File System, não é um banco de dados, mas sim um sistema de arquivos distribuídos, desenvolvido pelo Google para fornecer acesso eficiente aos dados usando grandes grupos de hardwares. Levando os dados para a fase de processamento.

#### 4.1.2.4 Processamento de dados

O processamento de uma grande quantidade de dados necessita de técnicas e tecnologias específicas, conforme demonstra o Figura 24.

**Figura 24 - Técnicas e tecnologias para processamento de dados**



**Fonte: Elaborado pela autora (2020)**

Como já mencionado na subseção 5.2.3, o Apache Hadoop MapReduce é uma ferramenta para trabalhar com BD que possui um ecossistema de outras aplicações que podem ser usadas para diferentes finalidades, como o processamento de dados (BABAR, 2019).

O Storm, faz parte desse ecossistema, e é responsável por processar em tempo real o streaming de dados (TSAI *et al.*, 2015; MOHAMED *et al.*, 2019).

O Karmasphere, que é uma plataforma para análise da BD de negócios, também é baseado no Hadoop. É capaz analisar BD com eficiência, sendo capaz de gerar relatórios, visualizações e análise iterativa da BD para obter uma visão de negócios, além de processar BD estruturados e não estruturados no Hadoop incorporado ao Hive (CHANDIO; TZIRITA; XU, 2015; MOHAMED *et al.*, 2019).

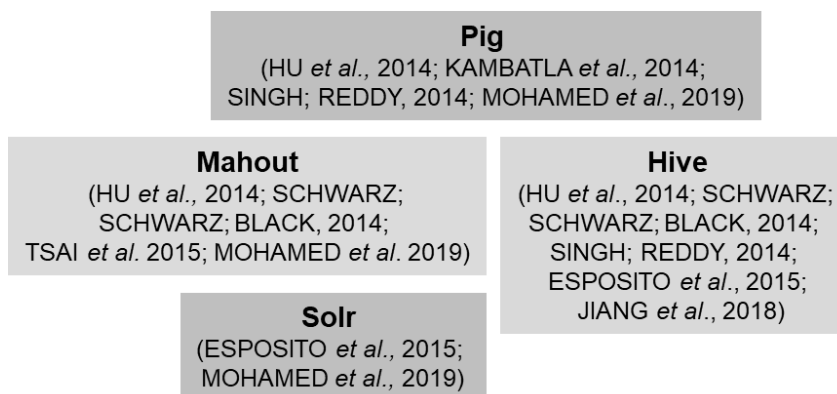
O Pentaho é uma das plataformas para integração de dados e análise de negócios, capaz de capturar dados usando um formato consistente e acessível aos usuários finais (MOHAMED *et al.*, 2019; SUMAN; KHAJURIA; UROLAGIN, 2020).

Outra plataforma de processamento é o Kafka que tem como objetivo fornecer uma plataforma unificada, de alta capacidade e baixa latência para tratamento de dados em tempo real (WANG; BELHASSENA, 2017; MOHAMED *et al.*, 2019; KAFKA, 2020).

Essas plataformas fornecem a base para a próxima fase de manipulação de dados, que consiste em buscar os dados que já foram processados e armazenados.

#### 4.1.2.5 Recuperação de dados

A recuperação de dados representa a possibilidade de executar consultas nos dados armazenados com a finalidade de realizar as análises necessárias, que resultarão nas visualizações dos dados. O Figura 25 apresenta algumas tecnologias e técnicas utilizadas nessa fase.

**Figura 25 - Técnicas e tecnologias para recuperação de dados**

**Fonte: Elaborado pela autora (2020)**

O Apache Hive é um software de Data Warehouse desenvolvido sobre o Apache Hadoop para consulta e análise de dados, ele oferece uma interface para consultas em diferentes bancos de dados e sistemas de arquivos integrados ao Hadoop (HIVE, 2020).

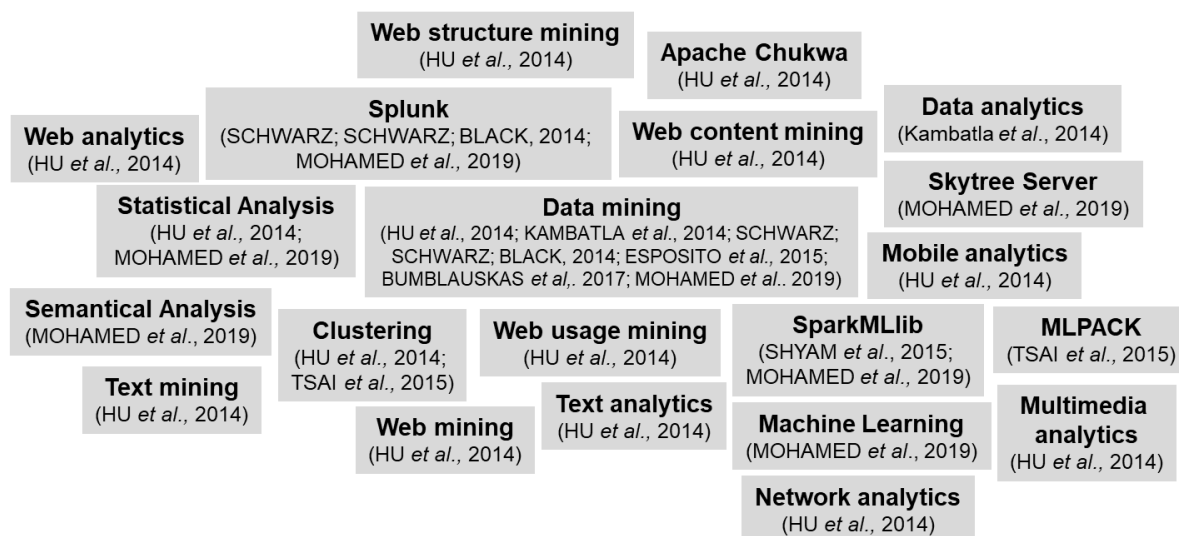
O Mahout atua na recuperação de dados, com foco em oferecer suporte a uma coleção de algoritmos de aprendizado de máquina escalonáveis para BD é o Mahout para Apache Hadoop. O Mahout fornece implementações distribuídas de algoritmos de classificação, agrupamento e mineração de conjunto de itens bem conhecidos com base em MapReduce (MOHAMED *et al.*, 2019).

Apache Pig e Apache Solr realizam consultas em um ambiente da Big Data criado dentro do Hadoop (SINGH; REDDY, 2014; MOHAMED *et al.*, 2019), e a partir disso, é possível passar para a parte de análise e visualização que resultam em várias informações.

#### 4.1.2.6 Análise e visualização de dados

Muitas das técnicas de análise e visualização de dados, como por exemplo as técnicas estatísticas, já existiam muito antes da BD, mas agora, com o advento dessa grande quantidade de dados, tornou-se possível utilizar essas técnicas em todo o seu potencial. No Figura 26, é possível visualizar algumas técnicas e ferramentas para análise de dados e informações.

**Figura 26 - Técnicas e tecnologias para analisar dados**



**Fonte: Elaborado pela autora (2020)**

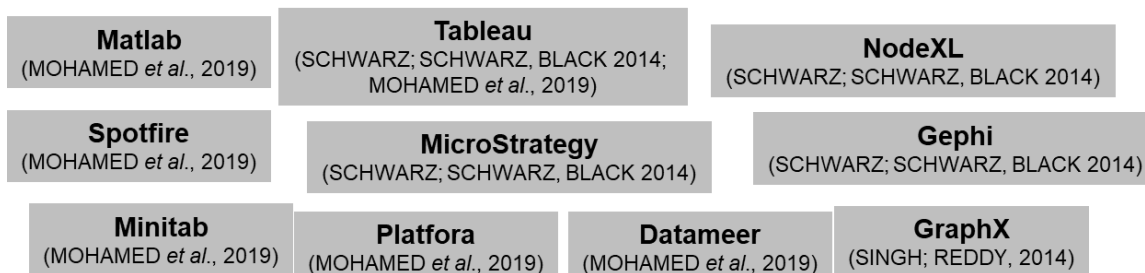
Essa transformação de dados em informações acionáveis é uma das partes mais importantes no processo de agregar valor aos dados coletados, portanto, se essa fase não for realizada com eficiência as demais perderam seu valor.

Sendo assim, visualizar os dados de forma intuitiva é essencialmente importante para a análise. Essas são algumas das ferramentas encontradas na literatura para analisar os dados.

Após isso, é possível visualizar os dados utilizando ferramentas que, em alguns casos, fazem tanto o procedimento de analisar quanto o de gerar visualização, que é o caso das ferramentas citadas na Figura 27, a seguir.



**Figura 27 - Técnicas e tecnologias para analisar e visualizar dados**



**Fonte: Elaborado pela autora (2020)**

A visualização de dados se dá por meio de tabelas e gráficos que proporcionam um melhor entendimento das informações, e nesse trabalho o foco foram as duas últimas fases da *Big Data* sendo elas: recuperação, análise e visualização de dados. Dessa forma, algumas das técnicas e tecnologias encontradas como resultado da revisão sistemática de literatura foram utilizadas na construção da plataforma on-line, apresentada na Seção 5 desse trabalho.

Além da reunião de ferramentas de BDA ser a base para identificar na pesquisa de campo, apresentada na Subseção 4.2 a seguir, as tecnologias disponíveis na indústria que podem ser utilizadas no desenvolvimento da plataforma, a revisão de literatura também resultou na construção da Seção 2 reunindo conceitos e informações de diversos autores sobre os temas dessa pesquisa. Além disso, o resultado da bibliometria dos documentos evidenciou a atualidade do tema, bem como o interesse mundial relacionado ao mesmo.

#### 4.2 PESQUISA DE CAMPO NA EMPRESA MULTINACIONAL DO RAMO AUTOMOBILÍSTICO

A empresa compõe a “*world’s leading automotive alliance*”, uma aliança firmada entre três fabricantes de veículos no ano de 1999, e foi anunciada como a montadora de automóveis líder mundial em 2019, sendo representada com a venda de 1 em cada 9 veículos em todo o mundo, totalizando cerca de 3,8 milhões de vendas no mesmo ano, conquistando 4,25% da parcela de mercado no ramo

automobilístico (LÔ; DIOCHON, 2019). Presente em 5 continentes: Europa, África, Ásia, Oceania e América, a empresa conta com um total de 179.565 mil colaboradores, atuando na produção, administração e comercialização dos automóveis.

Na América Latina, a empresa possui quatro unidades localizadas na Argentina, Brasil, Chile e Colômbia, sendo possível ter acesso aos dados dos indicadores de qualidade de todos esses países, para a implementação do projeto piloto da plataforma e-TQM que ocorreu na unidade brasileira, que contempla a produção do motor, produção da carroceria e montagem do veículo, localizada em São José dos Pinhais, no Estado do Paraná.

Por meio do acesso a todos esses dados e da pesquisa de campo presencial na empresa no Brasil, foi possível obter mais informações sobre os indicadores de defeitos na produção e a forma como eram coletados, analisados e disponibilizados.

#### *4.2.1 Indicadores de Qualidade da Empresa*

A empresa multinacional, objeto de estudo deste trabalho, possui vários indicadores de qualidade que fornecem base para que a TQM possa ser acompanhada em diferentes setores, classificados pela organização em seis grupos, sendo eles: segurança, recursos humanos, crescimento, lucratividade, financeiro e qualidade.

Para ter conhecimento de quais eram os indicadores relacionados aos defeitos de produção, primeiro foram mapeados os principais indicadores de cada um desses setores, obtendo como resultado a Figura 28, que apresenta a identificação dos indicadores, a sua descrição e a frequência necessária de atualização dos dados.

**Figura 28 - Grupos de indicadores de qualidade da empresa**

SEGURANÇA		
LUP	Lista única de pendências de itens referentes a segurança do trabalho	Diário
FR1	Taxa de acidente de trabalho que leve a uma lesão ou mais	Diário
FR2	Taxa de acidente com pelo menos um dia de paralisação dos trabalhos	Diário
FR0	Taxa de acidente que leve a uma lesão	Diário
N0	Acidentes que leve a uma lesão	Diário
N1	Acidentes com uma lesão ou mais	Diário
N2	Acidentes com pelo menos um dia de paralisação dos trabalhos	Diário
RECURSOS HUMANOS		
Efetivos	Horas trabalhadas por cada colaborador	Mensal
Hora Extra	Horas extras realizadas por cada colaborador	Semanal
Absenteísmo	Atrasos e ausências de cada colaborador	Mensal
CRESCIMENTO		
RGU	Quantidade de Carros produzidos em relação à quantidade pedida (Geral)	Diário
R.O	Quantidade de Carros produzidos em relação à quantidade pedida	Diário
D-STAR	Taxa Cumprimento da Sequência Programada (Geral)	Diário
SSAR	Taxa de Cumprimento da Sequência Programada	Diário
PAD	Quantidade em % de carros produzidos no dia sem defeitos	Diário
LUCRATIVIDADE		
DMD	Maturidade da aplicação dos conceitos APW* na rotina das UETs**	Mensal
MD	Maturidade da aplicação dos conceitos APW* na rotina das Ateliers***	Mensal
COGs/TDC	Custo do veículo desde a sua concepção até a entrega nas concessionárias	Mensal
VEH/FTE	Quantidades de veículos produzidos / efetivos totais	Mensal
KPI Manufacturing	Todos os custos de responsabilidade da fabricação	Mensal
FINANCEIRO		
VT	Despesas p/ fabricar um motor/peça/veículo dividido pelo volume produzido	Mensal
VTU	Despesas p/ fabricar um motor/peça/veículo dividido pelo volume produzido	Mensal
LCS	Quantidade de peças degradadas na linha	Diário
LCS	Quantidade de peças degradadas na linha	Mensal
DSTR	Horas usadas na produção	Mensal
FIP	Todos os custos não relacionados diretamente a produção do carro	Diário/Mensal
ESER	Proporção de consumo realizado pelo padrão estabelecido	Semanal
QUALIDADE		
<b>D-IN</b>	<b>Defeitos por unidade produzida</b>	<b>Diário</b>
<b>D-OFF</b>	<b>Defeitos por unidade produzida</b>	<b>Diário</b>
<b>DPHU</b>	<b>Total de automóveis produzidos / Total de defeitos (Índice)</b>	<b>Diário</b>
QFS	Como foi a avaliação do veículo	Semestre
GMF3	Defeito que chegou ao cliente	Mensal
GMF1	Defeitos e reclamações no período de garantia da fábrica	Mensal
SAVES V1	Auditoria de qualidade antes da entrega do veículo para o cliente	Diário
SAVES V1+V2	Auditoria de qualidade antes da entrega do veículo para o cliente	Diário
STR	Fazer bem da primeira vez	Diário
PHC	Auditória/Qualidade/Performance	Semestre
NR	Nível de retrabalho realizado pelo módulo	Diário
NNS	Nível de defeito detectados fora da UET**	Diário

\*APW - Alliance Production Way - Compartilhamento de melhores práticas em toda a organização

\*\*UET - Unités Élémentaires de Travail - Unidades de Trabalhos Elementares

\*\*\*Ateliers - Oficinas de fabricação

**Fonte: Elaborado pela autora (2020)**

Como observado na Figura 28, é desejável que alguns indicadores sejam atualizados diariamente, como é o caso dos indicadores de defeitos na produção D-in e D-off, que resultam no índice DPHU, conforme descreve o Quadro 7.

**Quadro 7 - Descrição dos indicadores D-in e D-off**

<b>D-in</b>	<b>D-off</b>	<b>DPHU</b>
Defeitos por unidade produzida identificados dentro da UET de origem	Defeitos por unidade produzida identificados fora da UET de origem	Total de automóveis produzidos / Total de defeitos

**Fonte: Elaborado pela autora (2020)**

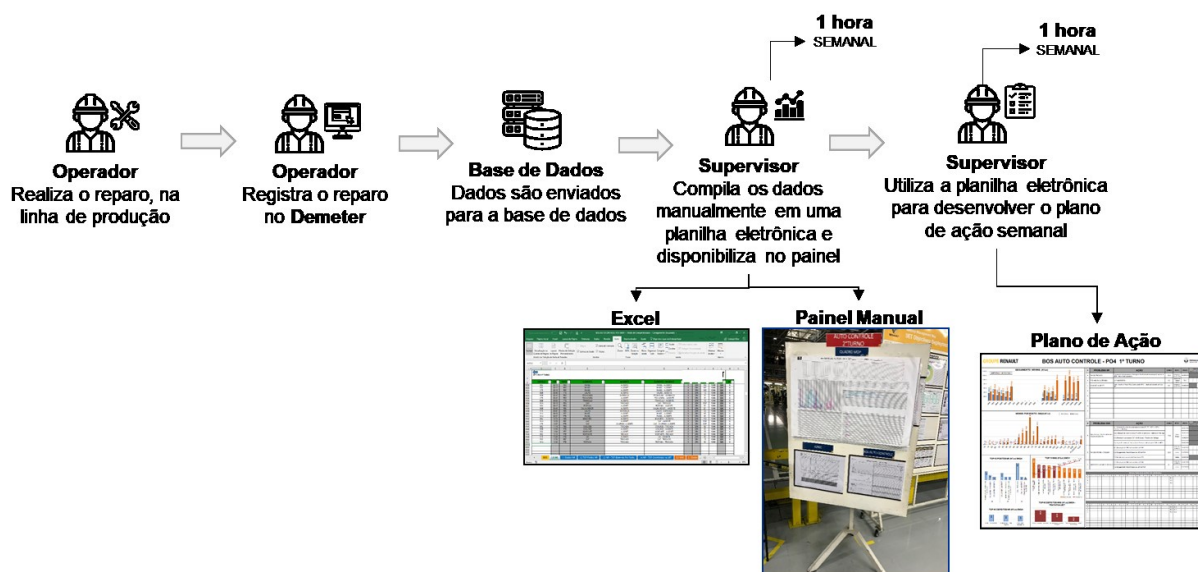
Uma Unidade de Trabalhos Elementares, do Francês, Unités Élémentaires de Travail - (UET) é nome dado pela empresa para dividir a linha de produção em funções específicas, como por exemplo: a UET A, é responsável pela montagem da porta do veículo, enquanto que a UET B, se encarrega da instalação da parte elétrica do veículo.

Dessa forma, se um defeito relacionado a montagem da porta for identificado pelos operadores que trabalham montando a porta, o defeito é considerado como D-in. Caso esse mesmo defeito seja encontrado pelos operadores que instalam a parte elétrica do veículo, o defeito é considerado como D-off, pois foi encontrado fora da sua UET de origem.

Como visto, apesar da necessidade de atualização diária desses indicadores para acompanhamento dos defeitos na produção, no decorrer da pesquisa de campo, foi possível observar que essa atualização diária não ocorria.

Diante disso, buscou-se entender como era realizado o acompanhamento desses indicadores, como ilustrado na Figura 29, com o objetivo de identificar como possíveis adaptações poderiam ser realizadas nesse processo.

**Figura 29 - Processo realizado para acompanhar os indicadores de defeitos**



Fonte: Elaborado pela autora (2020)

O processo de geração dos dados de indicadores de defeitos começa quando o operador, que está trabalhando na linha de produção, observa um defeito no veículo e realiza o reparo, em seguida, o mesmo operador tem acesso ao DEMETER, sistema interno da empresa utilizado para registrar os defeitos por meio de computadores que estão disponíveis ao longo de toda a linha de produção.

Nesse sistema o operador irá fornecer informações sobre o problema, identificando quais eram as peças danificadas, ou qual parte do veículo estava avariado, além de identificar se esse defeito foi identificado dentro da UET origem, sendo atribuído ao indicador D-in, ou em outra UET que não aquela onde o reparo foi realizado, somando-se ao indicador D-off.

Demais informações, como data e hora do reparo são registradas automaticamente pelo sistema.

Esses dados são então armazenados no banco de dados e ficam disponíveis para serem acessados e analisados. No início de cada semana, o supervisor de produção que é responsável por acompanhar esses indicadores, realiza a extração desses dados e os visualiza em uma planilha eletrônica.

Para que esses dados sejam melhor compreendidos e acompanhados faz-se necessário que gráficos e tabelas sejam criados, cabendo ao supervisor realizar

esse processo, geralmente totalizando cerca de 1 hora de trabalho do supervisor.

Depois dos dados serem transformados em visualizações gráficas, o supervisor precisa ainda desenvolver o plano de ação baseado nesses dados. Além disso, é preciso imprimir tanto o plano de ação como as visualizações para disponibilizar no painel manual, que fica disponível nos centros de reunião de cada UET na linha de produção, para que os operadores possam visualizar os principais defeitos e o plano de ação.

Esse processo de desenvolver o plano de ação e acompanhar durante a semana usa geralmente mais 1 hora do supervisor.

Uma das principais dificuldades é que esse processo precisa ser realizado por 98 supervisores de produção na usina de montagem e 38 supervisores de produção na usina de carroceria, e nem sempre esses supervisores dispõem de tempo e de habilidades para realizar um processo de manipulação de dados.

Toda essa situação gera altos índices de *No Value Added* (NVA), que são aqueles procedimentos que não agregam valor ao produto vendido, mas que por alguma razão ainda precisam ser feitos.

Neste caso, boa parte dos processos realizados para conseguir desenvolver o plano de ação semanal, não irá agregar imediatamente qualidade ao veículo produzido, mas torna-se necessário devido a necessidade de os supervisores terem conhecimento sobre quais passos tomar para continuar o processo de crescimento.

O Quadro 8, reúne os principais desafios da empresa em relação aos indicadores de qualidade de defeitos na produção.

Esses são apenas alguns dos desafios relacionados a disponibilização adequada dos indicadores de defeitos na produção, que podem causar imprecisão na priorização de ações do plano de ação semanal, devido à falta de atualização dos dados e brechas para possíveis alterações nos dados, causando a perda da visão da real situação da empresa.

**Quadro 8 - Principais desafios em relação aos indicadores de qualidade**

<b>DESAFIOS</b>	<b>DESCRIÇÃO</b>
<b>Inconsistência nas informações</b>	Os dados precisam ser extraídos do banco de dados pelo supervisor de produção que irá organizá-los em uma planilha eletrônica, o que possibilita que exclusões e erros de digitação modifiquem a realidade da situação.
<b>Atualização dos dados</b>	A planilha eletrônica não se conecta à base de dados, portanto, após a extração, novos dados que forem gerados não serão incorporados as análises até que seja feita uma nova extração, resultando em planos de ação baseados em dados antigos.
<b>Acesso aos indicadores</b>	Para acessar os dados é necessário solicitar que cada um dos supervisores de produção compartilhe suas planilhas eletrônicas, ou ir até a linha de produção e visualizar os gráficos impressos no painel manual.
<b>Padronização das visualizações</b>	Cada supervisor desenvolve seus modelos de gráficos e tabelas, com cores, tamanhos e informações que não são padronizadas, o que prejudica uma visualização geral da situação da empresa, quanto aos indicadores de defeitos na produção

**Fonte: Elaborado pela autora (2020)**

Portanto, os defeitos na produção representam um alto custo para empresa, por gerar retrabalho e perda total ou parcial de um veículo produzido, essa situação acarreta desperdícios, que vão contra os princípios da TQM fazer o melhor uso dos recursos e evitar ao máximo os desperdícios. Por isso, definiu-se junto ao setor de qualidade da empresa, a priorização da disponibilização desses indicadores na plataforma e-TQM.

A partir da definição dos indicadores de defeitos na produção mais urgentes a serem disponibilizados na plataforma, teve início o processo de escolha da ferramenta de apoio para isso. A ferramenta Tableau Desktop foi escolhida por ter sido mencionada pela literatura como uma ferramenta de análise e visualização de dados, e estar disponível na empresa. A seguir é descrito o desenvolvimento da plataforma com seu uso.

#### 4.3 DESENVOLVIMENTO DA PLATAFORMA E-TQM

Para o desenvolvimento da plataforma on-line, foi utilizada a ferramenta

Tableau desktop por proporcionar um ambiente para a criação de *dashboards* interativos ao explorar e analisar dados e ainda contar com a possibilidade de disponibilizar essas visualizações on-line.

Desenvolvido pela empresa Tableau Software, que conta produtos para manipulação e visualização de dados, como: Tableau Server, Tableau Prep e Tableau On-line (TABLEAU, 2020), o Tableau Desktop possibilita a conexão com diferentes fontes de dados para criar visualizações como: gráfico de barras, gráficos de linhas, *treemaps*, mapas de calor e outros (KO; CHANG, 2017). A Figura 30, organiza os três passos necessários para que um *dashboard* criado com essa ferramenta, seja publicado on-line.



Fonte: Elaborado pela autora (2020)

O Tableau Desktop é uma ferramenta paga, mas possui uma opção com funcionalidades reduzidas disponibilizado gratuitamente no site da empresa, o Tableau Public. Para a realização desta pesquisa, foi necessário utilizar a licença para estudante com validade de 12 meses para ter acesso a todas as ferramentas do Tableau Desktop, na versão 10.2.

Os dados, antes de serem inseridos no Tableau Desktop, podem passar por uma etapa adicional de preparação, que pode ser feita através do Tableau Prep. Esse *software*, auxilia no processo de limpeza dos dados e melhora a interpretação do tipo (inteiro, decimal, cadeia de caracteres, etc.), de cada um deles antes da fase de análise começar. Por fim, a publicação do *dashboard* é feita através do Tableau Server, um servidor que hospeda dados localmente (TABLEAU, 2020), que nesse caso está localizado dentro da rede de uma empresa.

Dessa forma, os dados que são inseridos no sistema DEMETER, que registra as informações sobre os defeitos ocorridos, e é salvo na base de dados, se comunicada diariamente com a plataforma e-TQM, que realiza a atualização das

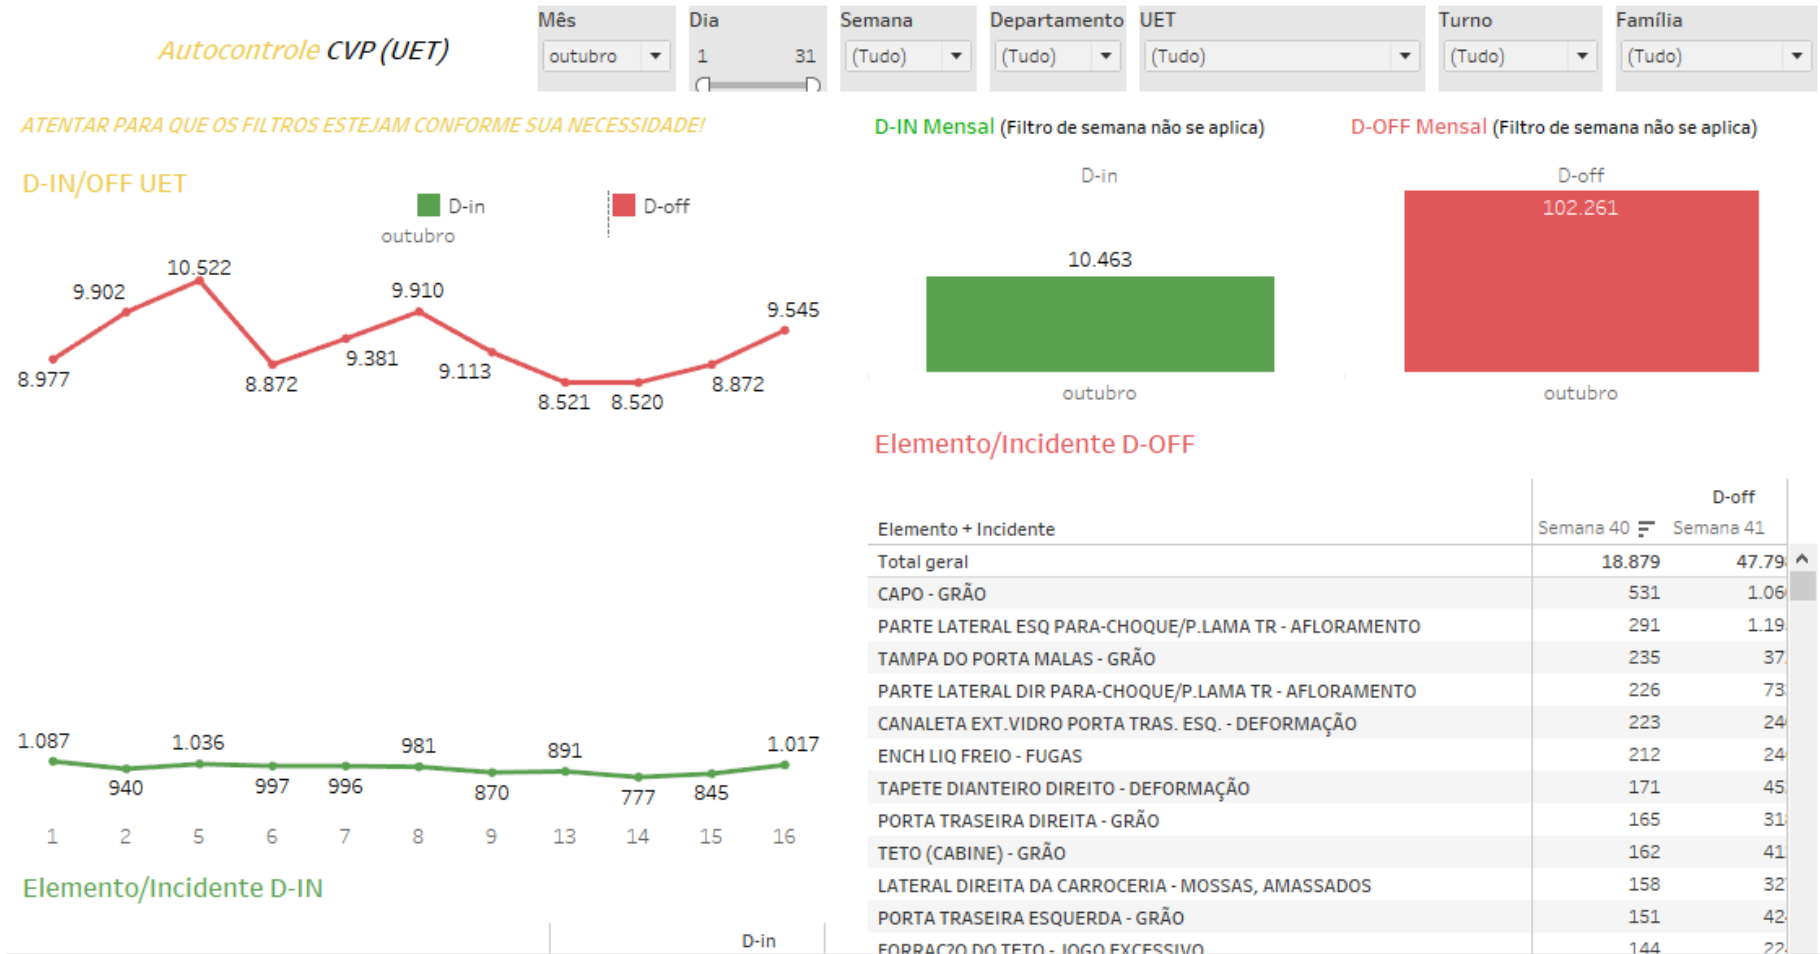


informações dos gráficos e tabelas sem a necessidade de intervenção humana, liberando tempo para que os supervisores e tomadores de decisão concentrem seus esforços no plano de ação e correção dos problemas indicados pelas informações.

Após ter toda a infraestrutura para coletar e armazenar esses dados, iniciou-se o processo de análise dos dados. Nessa fase, foram utilizados os gráficos e relatórios feitos manualmente pelos supervisores para que fossem replicados na ferramenta, fornecendo na ferramenta as informações que são necessárias para a análise e tornando padronizado para todos os supervisores.

Na Figura 31, é possível observar uma das várias visualizações disponibilizadas on-line para que os supervisores possam acessar. É importante salientar que os dados dos indicadores D-in, D-off e DPHU apresentados nesse trabalho são fictícios utilizados apenas para ilustrar o funcionamento da plataforma, sem expor dados sigilosos da empresa.

Figura 31 - Plataforma On-line e-TQM



Fonte: Disponibilizada pela empresa com os dados de teste (2020)

Além da e-TQM tornar possível o acompanhamento de D-in e D-off, de forma centralizada, também é possível visualizar os dados de forma personalizável por meio de filtros que permitem a visualização pelo período de tempo desejado, além de segmentar informações por departamentos, UETs, postos e turnos de trabalho, possibilitando uma visão geral ou específica.

Dessa forma, podem ser identificadas as origens dos principais incidentes, que posteriormente podem ser tratados, evitando que o problema perdure por longos períodos de tempo, reduzindo os custos provenientes de retoques e retrabalhos.

Os filtros, localizados na parte superior ou na lateral esquerda da plataforma, conforme apresentado na Figura 32, visam adaptar a visualização dos gráficos e tabelas, tornando a análise mais limpa e eficiente.

**Figura 31 - Filtros da plataforma e-TQM**

**Fonte: Disponibilizada pela empresa com os dados de teste (2020)**

Ao selecionar um filtro, todas as tabelas e gráficos que estiverem na visualização serão alteradas. É importante frisar que os filtros trabalham juntos, então a seleção de um filtro altera as opções apresentadas pelos demais. Por exemplo, ao selecionar apenas uma UET, no filtro de UETs, o filtro de postos irá mostrar apenas os postos pertencentes a UET selecionada. Os demais filtros possuem suas funções específicas para personalizar as visualizações, como:

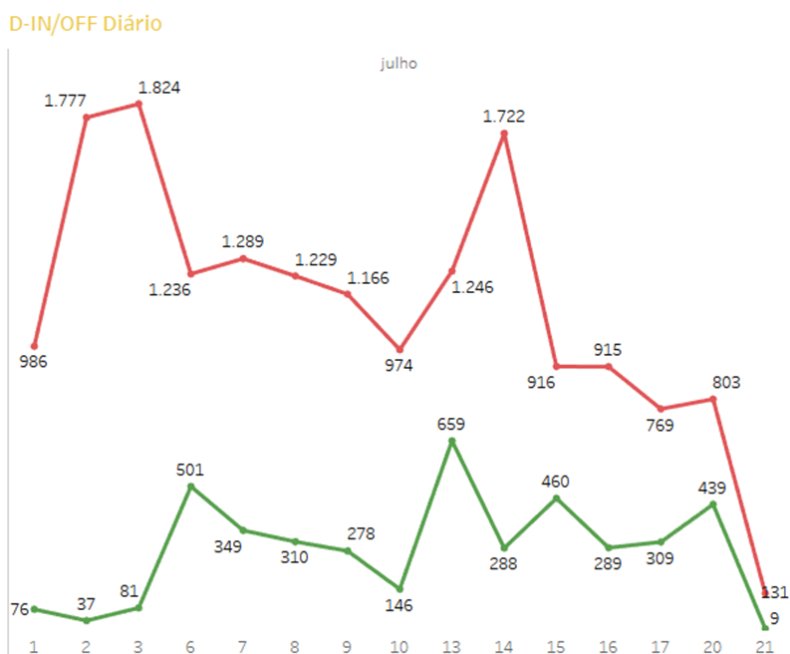
- *Mês*: selecionar quais meses serão visualizados nos gráficos e tabelas;
- *Dia*: nesse filtro são selecionados os intervalos de dias que serão visualizados nos gráficos/tabelas. Para isso, é necessário apenas aumentar ou diminuir o intervalo na barra. Dessa forma, é possível ver apenas os primeiros 15 dias de um mês, por exemplo;
- *Departamento*: com esse filtro é possível visualizar apenas os departamentos desejados (montagem, pintura, carroceria e logística);
- *UET*: esse filtro permite selecionar quais UETs serão apresentadas nos

gráficos e tabelas;

- *Semana*: utilizando esse filtro é possível selecionar as semanas do ano que serão apresentadas nos gráficos e tabelas;
- *Elemento + Incidente*: como existem diversos elementos e incidentes, em alguns casos pode ser interessante visualizar apenas alguns deles. Portanto, ao clicar na seta ao lado desse filtro, a caixa de seleção se abre, mostrando as opções disponíveis, após selecionar os Elementos + Incidentes desejados, clica-se em aplicar e as visualizações se adaptam;
- *Turno*: permite visualizar os turnos de trabalhos específicos;
- *Posto*: com esse filtro é possível visualizar os postos de trabalho separadamente, e
- *Família*: permite visualizar o modelo de um veículo de forma específica.

O uso dos filtros permite que os gráficos e tabelas se adequem a diferentes necessidades de análise. A Figura 33, apresenta um dos gráficos disponíveis na plataforma e-TQM, que tem como objetivo apresentar o total diário de D-in e D-off.

**Figura 32 - Gráfico D-in e D-off diário**




**Fonte: Disponibilizada pela empresa com os dados de teste (2020)**

Esse gráfico permite que o acompanhamento diário seja realizado, identificando aumentos de defeitos que precisam ser tratados com rapidez. A Figura 34, apresenta mais um desses gráficos, sendo esse utilizado para fornecer uma visão mensal.

**Figura 33 - Gráfico D-in e D-off mensal**

**D-IN Mensal** (Filtro de semana não se aplica)

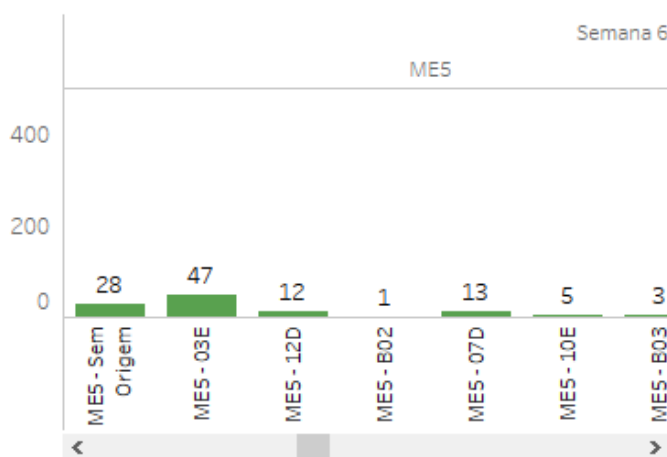


**Fonte: Disponibilizada pela empresa com os dados de teste (2020)**

Outro gráfico disponível é o de D-in e D-off por postos de trabalho, apresentado na Figura 35, que permitem uma visão mais específica de onde estão ocorrendo os defeitos, fazendo com que o plano de ação para solucionar a recorrência de problemas seja focalizada.

**Figura 34 - Gráfico D-in e D-off por posto de trabalho**

**D-in por Postos** (Valores "nulo" não tem origem definida)



**Fonte: Disponibilizada pela empresa com os dados de teste (2020)**

Com esse gráfico também é possível visualizar por meio dos valores 'nulos', se existem defeitos sendo lançados no sistema sem o seu posto de origem. Nesse

caso o supervisor da UET irá trabalhar para que todos os defeitos lançados tenham um posto de origem.

Na Figura 36, o gráfico apresenta a quantidade de cada elemento + incidente por semana. A primeira linha “Grand Total”, mostra a soma semanal dos defeitos, que logo abaixo são listados em ordem decrescente.

**Figura 35 - Gráfico elemento + Incidente**

### Elemento/Incidente D-OFF

Elemento + Incidente	Semana 30
Grand Total	934
PAINEL DE INSTRUMENTOS(CONJUNTO) - RUÍDO ANORMAL	40
CANALETA EXT.VIDRO PORTA DIANT.DIR. - JOGO EXCESSIVO	29
ZONA TRASEIRA DA CABINE - RUÍDO ANORMAL	17
FUNC ANTI PARTIDA - INSTAL PEV ASSINATUR	15
JOINT PROTECTEUR BAS DE PORTE ARD - JUNTA MAL ENCAIXADA	15
FUNÇÃO INJEÇÃO - INSTAL PEV ESTATICOS	14

**Fonte: Disponibilizada pela empresa com os dados de teste (2020)**

Esse gráfico permite que os supervisores verifiquem quais foram os elementos e os incidentes relacionados a eles que ocorrem com maior frequência durante aquela semana, sendo possível focar o plano de ação nesses pontos.

O gráfico de soma do D-in e do D-off mensal, separadamente, por departamento, é visualizada na Figura 37.

**Figura 36 - D-in e D-off por departamento**

### D-in/off (Soma UETs)


IN/OFF	CARROCERIA		LOGISTICA		MONTAGEM		PINTURA	
	junho	Total	junho	Total	junho	Total	junho	Total
D-in	33	33			4.000	4.000	13.826	13.826
D-off	7.914	7.914	2	2	27.675	27.675	5.786	5.786

**Fonte: Disponibilizada pela empresa com os dados de teste (2020)**

Nesse gráfico é possível identificar quais são os departamentos que estão com D-in e D-off mais altos e precisam de atenção especial durante a formulação do plano de ação. Na Figura 38 é apresentado o gráfico com a soma do D-in e do D-off

mensal, separadamente, por departamento e por UET.

**Figura 37 - D-in por UET**



**Fonte: Disponibilizada pela empresa com os dados de teste (2020)**

Esse gráfico permite uma análise quanto as UETs dentro dos departamentos que estão registrando maior número de D-in e D-off. A Figura 39, apresenta uma tabela que serve para identificar a origem dos defeitos. Apresenta também todos os elementos + incidentes que não possuem origem como “Null”, evidenciando a necessidade de buscar com os responsáveis essa informação.

**Figura 38- D-in por Posto**

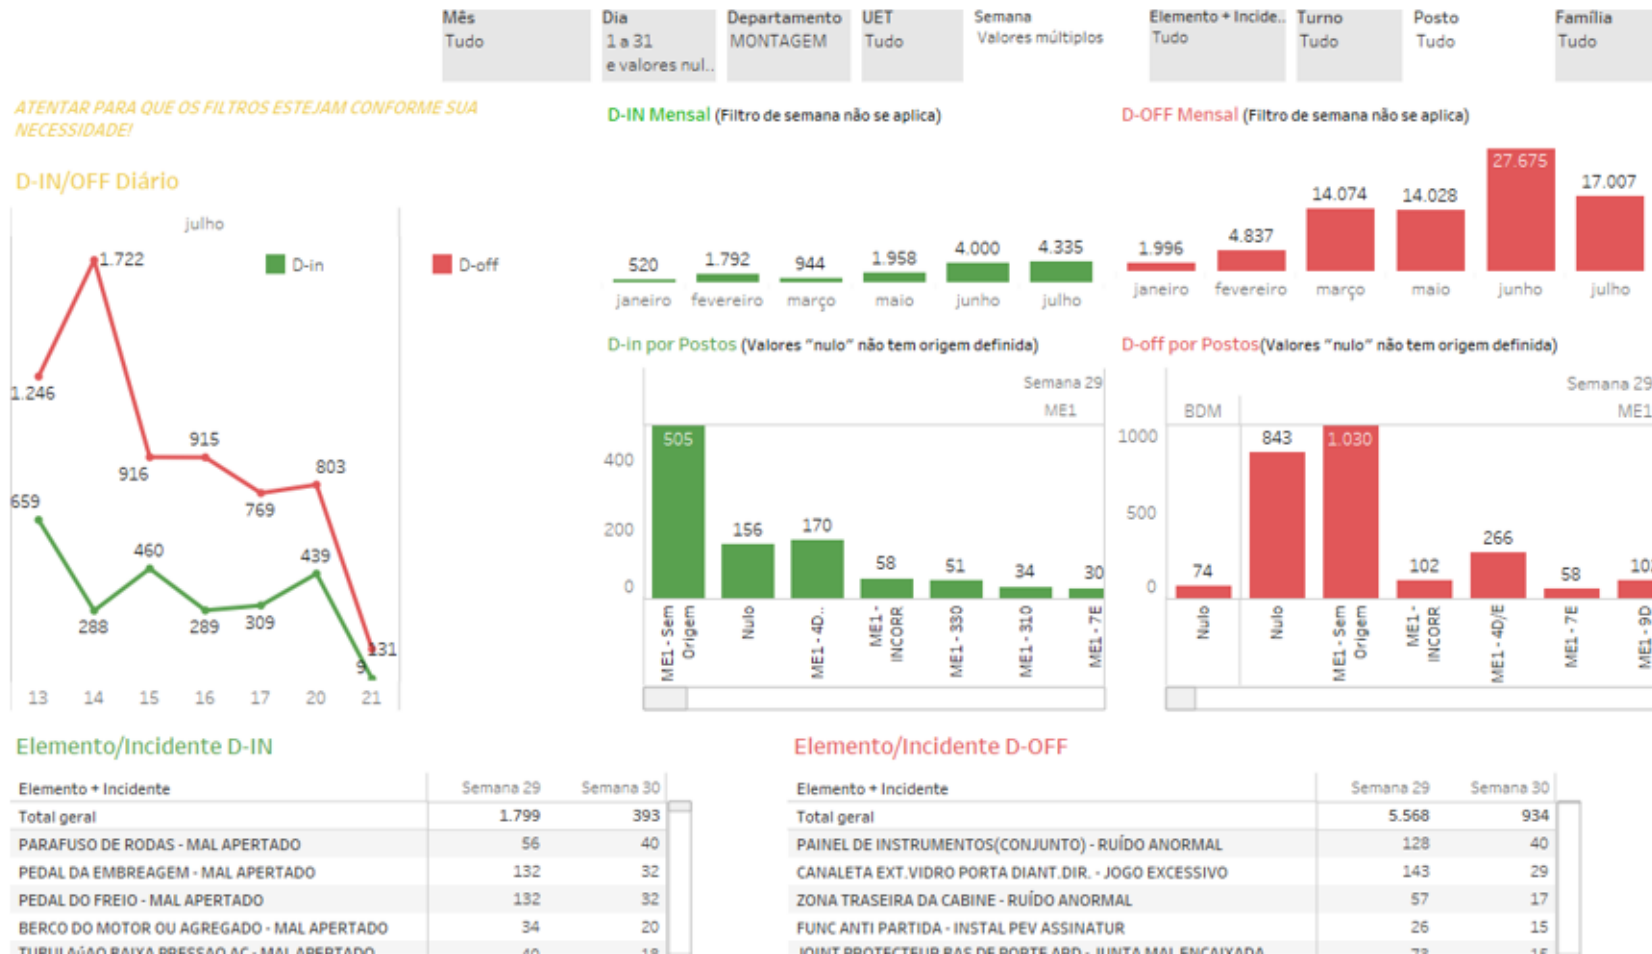
**D-IN por Posto - Usar para identificar origem de Defeitos**

UET..	Elemento + Incidente	Elemento	Incidente	Posto	julho
MES	JUNTA DA PORTA TRAS. DIREITA - JOGO EXCESSIVO	JUNTA DA PORTA TRAS. DIREITA	JOGO EXCESSIVO	Null	114
	JUNTA DA PORTA TRAS. ESQUERDA - JOGO EXCESSIVO	JUNTA DA PORTA TRAS. ESQUERDA	JOGO EXCESSIVO	Null	83
	JUNTA DA PORTA DIANT. ESQ. - JOGO EXCESSIVO	JUNTA DA PORTA DIANT. ESQ.	JOGO EXCESSIVO	Null	39
	JUNTA DA PORTA TRAS. DIREITA - DEFORMAÇÃO	JUNTA DA PORTA TRAS. DIREITA	DEFORMAÇÃO	Null	25

**Fonte: Disponibilizada pela empresa com os dados de teste (2020)**

Dessa forma, analisar os gráficos de forma individual fornece informações, que podem ser ainda mais abrangentes quando visualizado o *dashboard* completo, conforme Figura 40. Com essa visualização torna-se possível analisar e obter diversas informações, que poderão auxiliar na tomada de decisão.

Figura 40 - Dashboard e-TQM



Fonte: Disponibilizada pela empresa com os dados de teste (2020)



Como por exemplo, no primeiro gráfico (D-IN/OFF Diário), é possível visualizar um pico de defeitos que a UET deixou passar no dia 14/07 e diferenças na quantidade de detecção/perturbação dentro da UET nos dias 15/07 e 20/07.

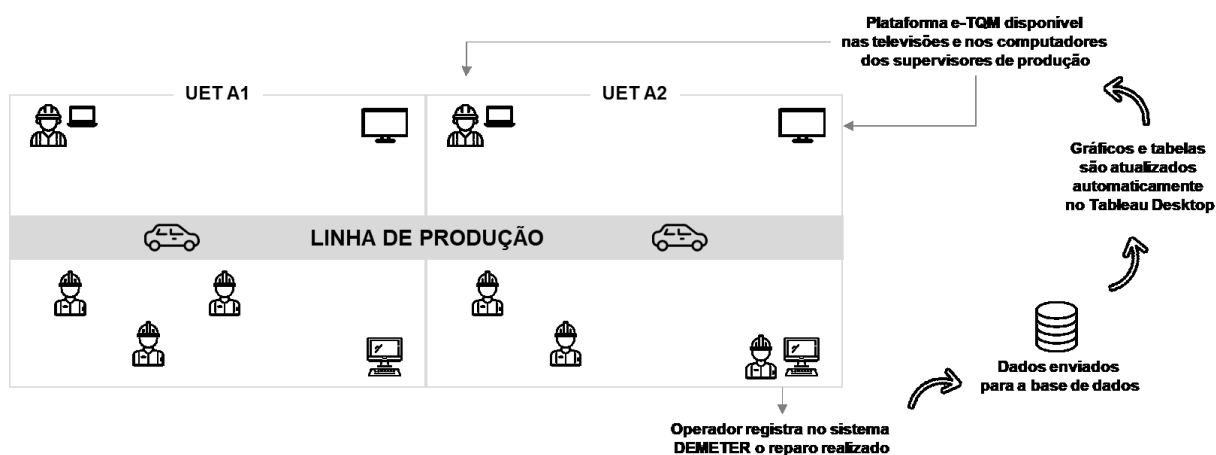
Através dos meses, é percebido o aumento substancial dos defeitos não detectados na linha e no gráfico de postos (D-IN por postos, D-OFF por postos), um número grande de elementos + incidentes sem informação da origem dos postos chegando a 266 defeitos no posto 4D na linha ME1.

Ao final do *dashboard*, são apresentados os defeitos mais recorrentes por semana (Elemento/Incidente D-IN e Elemento/Incidente D-OFF), sendo na semana 30, 'Parafuso de rodas mal apertado' o TOP Defeito D-IN e 'Painel de instrumento com ruído anormal', o TOP Defeito D-OFF, dessa forma, com uma visão geral um plano de ação mais completo pode ser desenhado.

Após finalizada a plataforma e-TQM, um manual e um vídeo de instruções foi disponibilizado para que os supervisores de produção pudessem entender quais análises poderiam ser extraídas de cada um dos gráficos e tabelas, e como personalizar essas exibições através dos filtros, tendo a disposição o material para consultar no caso de dúvidas.

Conforme ilustra a Figura 41, os dados gerados na linha de produção retornam em forma de informações por meio da plataforma, proporcionando ao supervisor e aos operadores a visualização dos indicadores em seu ambiente comum de trabalho.

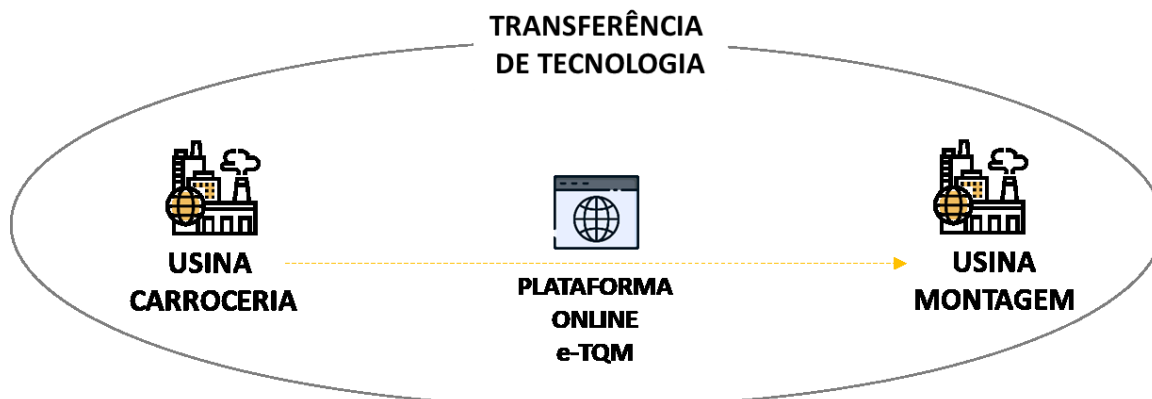
Figura 39 - Ilustração do processo de geração e exibição dos indicadores na linha de produção



Fonte: Elaborado pela autora (2020)

Por fim, a TT entre as usinas foi realizada, por meio da conexão com os dados da usina de produção da carroceria e da usina de montagem do veículo, que podem acessar a plataforma e visualizar seus indicadores, conforme ilustra Figura 42.

Figura 40 - Transferência de Tecnologia entre Usinas



Fonte: Elaborado pela autora (2020)

Com isso, a plataforma e-TQM promoveu uma maior integração da indústria, caminhando assim para atingir um dos principais objetivos da Indústria 4.0, de conectar toda a organização tornando os dados acessíveis o mais próximo do tempo real (SADER; HUSTI; DARÓCZI, 2019).

Aliado a isso, a Gestão da Qualidade Total (TQM) torna-se mais simples, visto

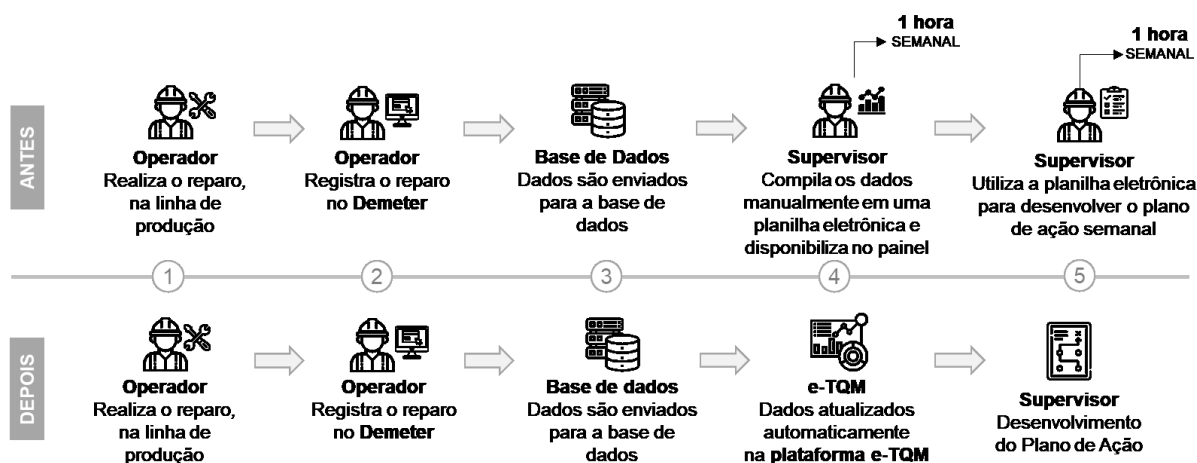
que os dados estarão centralizados em apenas um local.

#### 4.3.1 Ganhos do Projeto

A plataforma e-TQM, representa uma proposta para automatizar o processo de acompanhamento dos indicadores de defeitos, atualizando as informações diariamente e facilitando a forma de acesso para os supervisores de produção e demais tomadores de decisão da empresa.

Como é possível visualizar na Figura 43, o processo anterior demandava que os supervisores realizassem tarefas que não estão exatamente atreladas ao seu cargo, resultando em uma análise de dados realizada sem o conhecimento necessário sobre as tecnologias e técnicas disponíveis para a obtenção de informações a partir da grande quantidade de dados disponíveis.

Figura 41 - Antes e depois da proposta da plataforma e-TQM



Fonte: Elaborado pela autora (2020)

Antes da possibilidade de utilizar a plataforma e-TQM, o processo de extração de dados e criação de visualização, abria muitas brechas para que erros fossem cometidos por falta de atenção por parte do supervisor de produção, que estava realizando suas funções na linha de produção, mas ao mesmo tempo precisava realizar as análises.

Nesse ponto, uma simples alteração ou exclusão de dados poderia alterar

significativamente o resultado final da análise, devido a inconsistência das informações, que por consequência poderia priorizar ações incorretamente no plano de ação semanal.

Aliado a isso, questões como a falta de padronização dos gráficos e tabelas, visto que os 136 supervisores de produção precisavam realizar suas análises separadamente, de acordo com as UET que são responsáveis e a falta de atualização diária das informações, sinalizavam a necessidade de uma readequação quanto a forma de acompanhar esses indicadores importantes para a organização.

#### 4.3.1.1 Ganhos quantitativos

Com o uso da plataforma e-TQM conectando-se a base de dados para atualizar as informações todos os dias, a fase 4 para disponibilização dos dados se tornou automática, não sendo necessário que o supervisor de produção manipule os dados todas as semanas.

Somente nesse processo eram investidos em média 1 hora de trabalho do supervisor, que durante o decorrer da semana precisava atualizá-los manualmente e acompanhá-los, resultando em mais 1 hora semanal dedicada a essa tarefa. Na Figura 44, é possível visualizar em números os ganhos obtidos com a implementação da e-TQM.

**Figura 42 - Ganhos obtidos em dias de trabalho**

<b>Extração, limpeza e análise dos dados (Segundas-feiras)</b>	<b>Revisão dos dados (Terça-feira - Sexta-feira)</b>
<b>1 horas/semana</b>	<b>1 horas/semana</b>
<b>4 horas/mês</b>	<b>4 horas/mês</b>
<b>48 horas/ano</b>	<b>48 horas/ano</b>
<b>Liberados aproximadamente 12 dias de trabalho do supervisor</b>	

Fonte: Elaborado pela autora (2020)

Estima-se que aproximadamente doze dias de trabalho do supervisor foram poupados de realizar atividades que não agregam valor, dando espaço para que tarefas como planos de ação para a minimização desses defeitos possa ser realizada.

Esse ganho quantitativo aponta para uma série de outros ganhos que não são facilmente traduzidos em números, pois representam, de forma qualitativa, a melhoria de qualidade ocasionada pelo uso da plataforma, conforme discorre a próxima Subseção.

#### 4.3.1.2 Ganhos qualitativos

O processo realizado com o auxílio da plataforma e-TQM, tornou o resultado das análises mais confiáveis quanto a integridade dos dados, devido ao fato de não haver manipulação humana no processo de extração e conexão entre a base de dados e a plataforma.

Dessa forma, os dados podem ser atualizados automaticamente todos os dias, tornando o plano de ação mais acurado e alinhado com a realidade dos dados que são traduzidos em gráficos e tabelas que proporcionam uma visão geral dos indicadores de qualidade de defeitos na produção.

Outro benefício alcançado com a plataforma é a facilidade de acesso aos indicadores, que podem ser visualizados de vários lugares, a qualquer momento e quantas vezes forem necessárias através de um dispositivo conectado à *internet*, por se tratar de uma plataforma disponível on-line. Por meio dessa facilidade, foi possível substituir o painel manual que ficava na linha de produção e demandava que papéis com os gráficos fossem impressos todas as semanas, por televisões mostrando as informações dos indicadores por meio da plataforma.

Essas televisões já estavam disponíveis nas linhas de produção, mas alguns supervisores não as utilizavam esses aparelhos que possuem inclusive a opção *touch screen*, que possibilita a personalização dos gráficos por meio dos filtros diretamente na televisão, facilitando muito o acesso as informações no momento em que o supervisor de produção precisar. Essa ação caracterizou mais um passo para

o melhor uso dos recursos disponíveis na empresa, de acordo com os princípios da TQM.

Além dos ganhos quanto a qualidade do processo, ganhos indiretos também podem ser percebidos, como uma maior qualidade do plano de ação, que agora é realizado a partir de gráficos e tabelas padronizadas e com dados íntegros, que podem aumentar os pontos positivos em uma auditoria de qualidade, por exemplo.

Os supervisores de produção também foram impactados positivamente, quanto a simplificação do processo de acompanhamento dos indicadores, visto que com o uso da plataforma, mais foco e energia podem ser empregados no plano de ação e em vários outros projetos e iniciativas relacionadas ao processo.

Portanto, a e-TQM tornou possível a visualização, análise e acompanhamento desses dados de forma centralizada em uma única plataforma personalizável por meio de filtros. Dessa forma, os desafios mencionados no Quadro 8 na Subseção 4.2.1, foram explorados e receberam uma opção de solução, conforme demonstra Quadro 9.

**Quadro 9 – Solução proposta para os principais desafios dos indicadores**

<b>DESAFIOS</b>	<b>SOLUÇÃO PROPOSTA</b>
<b>Inconsistência nas informações</b>	Dados extraídos e conectados automaticamente com a plataforma e-TQM.
<b>Atualização dos dados</b>	Dados atualizados diariamente, conectados diretamente com a plataforma e-TQM.
<b>Acesso aos indicadores</b>	O acesso aos indicadores pode ser feito a partir de dispositivos com acesso à <i>internet</i> , visto que a plataforma está disponível em uma plataforma on-line.
<b>Padronização das visualizações</b>	Todos que acessarem a plataforma terão acesso aos mesmos estilos de gráficos e tabelas, facilitando uma visualização sobre a situação geral da empresa.

**Fonte: Elaborado pela autora (2020)**

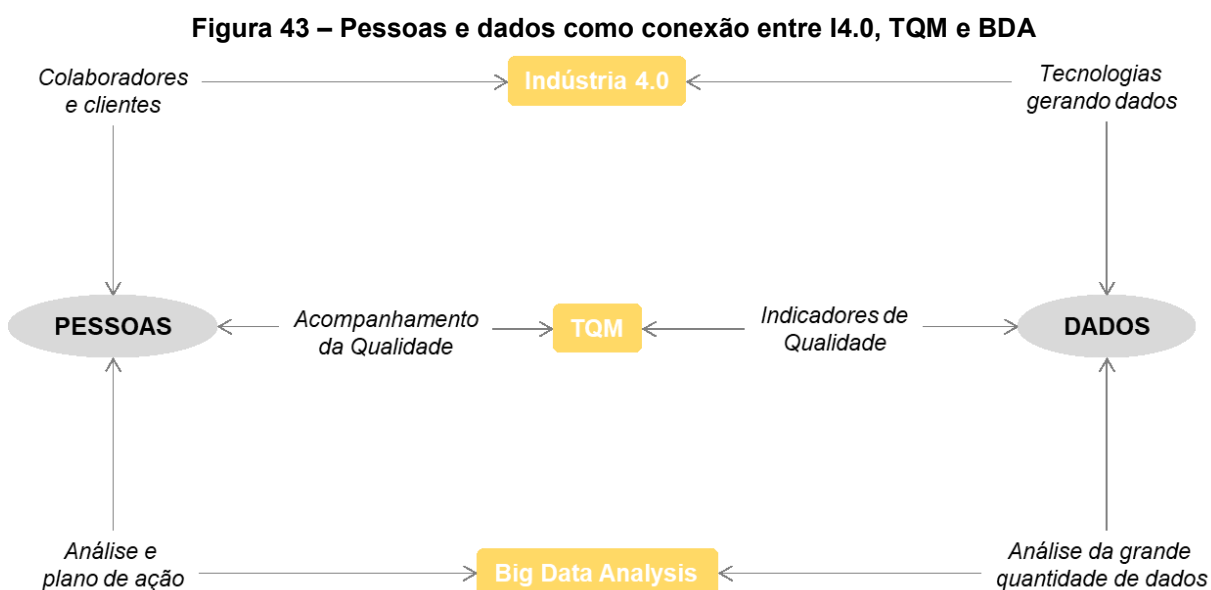
Além disso, tarefas secundárias relacionadas ao projeto foram concluídas, como: o mapeamento dos principais indicadores de cada setor, que podem servir

como base na priorização para inserir os demais indicadores na plataforma e a Transferência de Tecnologia realizada entre as usinas de carroceria e montagem, deixando um exemplo de como esse processo pode ser realizado nas demais unidades da empresa na América Latina.

Dentro desse cenário, o projeto e-TQM como um todo evidenciou como a união dos temas BDA, I4.0 e TQM podem ser integrados no contexto industrial para um maior alinhamento entre a qualidade e as tecnologias disponíveis.

#### 4.3.2 Big Data Analytics na Integração entre I4.0 e TQM

Buscando destacar como BDA, I4.0 e TQM podem ser uma combinação interessante para o desenvolvimento organizacional baseado em qualidade, tecnologia e pessoas, a Figura 45 ilustra a relação entre os temas, que parecem tão distintas a princípio, mas que possuem duas características que os relacionam intimamente: dados e pessoas.



Fonte: Elaborado pela autora (2020)

A Figura 45 demonstra o ecossistema de uma organização. Que tem como desafio fazer o melhor aproveitamento dessas relações para que exista maior colaboração e integração entre eles.

A I4.0 necessita de colaboradores e clientes para existir, além disso, tem como característica a geração de dados por meio de suas tecnologias. A TQM, precisa de indicadores de qualidade, que são dados, para que pessoas possam fazer o acompanhamento dos objetivos definidos. Por sua vez, a BDA contempla as técnicas para manipular todos esses dados e entregar uma análise consistente para que pessoas desenvolvam planos de ação.

Em relação as pessoas na I4.0, é notável que uma indústria não se baseia apenas na implantação de máquinas e tecnologias, mas também é formada por pessoas responsáveis por gerir isso tudo.

Além disso, sabe-se que as tecnologias emergentes mudarão boa parte dos processos de qualidade, atingindo um nível diferente do atual, baseando-se no monitoramento, detecção de falhas, e até mesmo análises e estratégias corretivas realizadas de forma autônoma (RAMEZANI; JASSBI, 2020).

Sendo assim, tarefas repetitivas, realizadas por pessoas, passarão a serem realizadas de forma automática com uso de robôs, aliados Inteligência Artificial (IA) (HAMID *et al.*, 2019). Contudo, esses processos semiautomatizados e repetitivos diminuem o engajamento e a atenção plena, resultando em um questionamento relevante para compreender os impactos da I4.0 no ambiente de trabalho (ASIF, 2020).

Outra questão discutida por Asif (2020), é que o desenvolvimento da I4.0 ocorre no aspecto técnico da organização, reduzindo o envolvimento cognitivo dos funcionários e a percepção da significância do trabalho, o que pode implicar na redução da qualidade deste trabalho.

Por outro lado, com a inserção de robôs e automação de processos repetitivos, a saúde física e mental dos colaboradores pode ser poupada, melhorando, em alguns casos, as taxas de ergonomia, qualidade no trabalho e motivação, estimulando uma melhor aceitação dessas novas tecnologias que complementam e melhoram as atividades desempenhadas pelos colaboradores.

Nesse contexto, a TQM pode ser empregado por apresentar a visão de capacitação dos funcionários e superação de barreiras organizacionais de



comunicação e interpessoais (AMIN *et al.*, 2017; BUGDOL, 2020), possuindo, portanto, não somente foco na qualidade, mas também nas pessoas.

A implementação da TQM requer a existência de uma cultura organizacional receptiva à mudança, baseada na motivação dos colaboradores e da indústria para almejar a melhoria. Também é adequado que as pessoas estejam dispostas a se envolver, compreender e posteriormente implementar um determinado grupo de princípios, técnicas e práticas de TQM (ARAÚJO *et al.*, 2019).

Nesse cenário, surge o conceito de Quality 4.0 que necessita que os funcionários possuam novas habilidades técnicas. Além disso, as habilidades transformacionais, como adaptabilidade, pensamento crítico, criatividade e habilidades sociais também serão necessárias (SONY *et al.*, 2020).

A Quality 4.0, assim como a I4.0 trazem consigo a BD, proveniente dos dados gerados pelas tecnologias dessa fase 4.0, levantando a necessidade de notar que a utilidade dos dados e análises relacionadas está estritamente relacionada e dependente da qualidade dos dados (CIMINI *et al.*, 2020).

Portanto, garantir a qualidade e consistência desses dados é um desafio nesse cenário, questões como o fracasso em alcançar os resultados planejados para a qualidade prejudica a cooperação e dificulta o trabalho em equipe, fazendo com que dados sejam falsificados sugando a motivação dos colaboradores (BUGDOL, 2020).

Conforme mencionado por Bagozi *et al.* (2019), as análises de dados podem ser melhor aproveitadas quando aliada aos *insights* humanos provenientes, por exemplo, de experiências com cenários anteriores, além disso, a tomada de decisão final ainda é melhor aceita quando advinda de um humano.

As tecnologias representam um apoio para que os colaboradores possam trabalhar com a grande quantidade de dados disponíveis. Que necessitam de soluções que forneçam aos especialistas uma visão compacta sobre a grande quantidade de dados coletados (BAGOZI *et al.*, 2019).

O setor 4.0 fornece diversas plataformas, que são capazes de gerar visualizações baseadas na *Big Data*, que podem ser analisados e fornecer, não

somente um acompanhamento da produção, como também gerar insights futuros prevenindo, por exemplo, que problemas de produção demorem a ser solucionados. Dessa forma, até mesmo análises o mais próximo possível do tempo real podem ser realidade, desburocratizando o controle da qualidade em grandes produções.

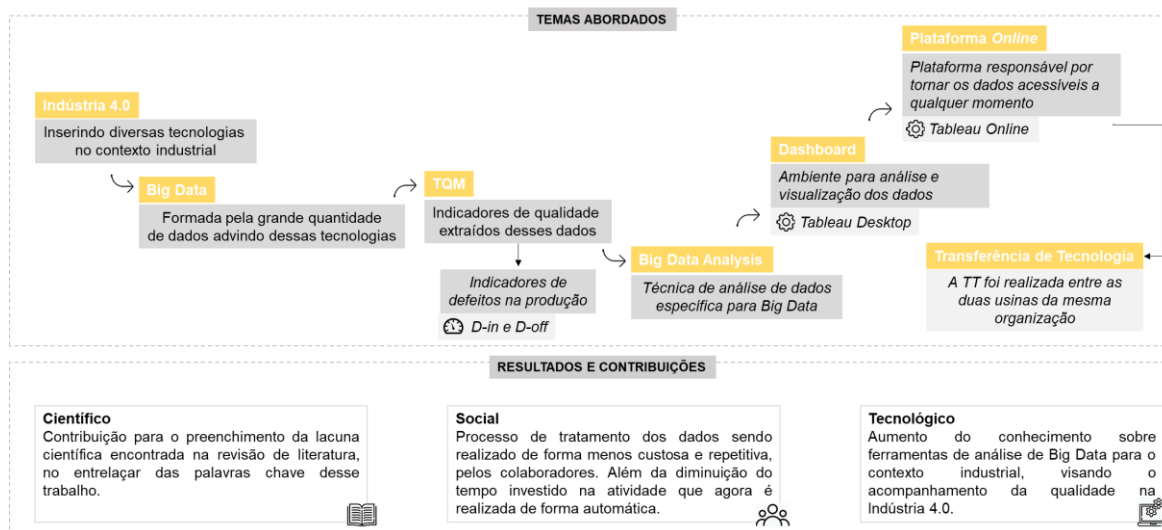
Esses são apenas alguns exemplos de interações que podem acontecer nesse cenário, com uma exploração ainda mais profunda, diversas outras podem surgir e integrar ainda mais o ecossistema. Essas interações, podem resultar em um envolvimento benéfico para todas as esferas e sub-esferas, em que uma complementa a outra.

Com a TQM a I4.0 pode manter padrões de qualidade, mesmo em produções descentralizadas, em que o produto final necessita de várias organizações envolvidas, mas que estão distribuídas em diferentes espaços físicos (produção, logística, etc.). Além disso, o acompanhamento em tempo real, torna-se possível por meios das tecnologias disponíveis.

Dessa forma, fica evidenciado como essas três esferas que são naturalmente relacionados umas às outras, tem como pontos em comum a necessidade de pessoas e dados, além, é claro, da necessidade de qualidade.

Isso demonstra uma a oportunidade de mantê-las conectadas para promover a integração da indústria, e, quando bem estudas e interconectadas, podem ser aplicadas dentro de diferentes organizações, com o objetivo de acompanhar as inovações tecnológicas da nova fase industrial sem deixar de lado a qualidade e a participação ativa das pessoas nesse contexto. Esse trabalho foi construído levando isso e conta, e na Figura 46 é possível visualizar o panorama geral da pesquisa, demonstrando a relação entre os temas abordados, e a suas aplicações no estudo de caso realizado.

Figura 44 - Panorama geral dessa pesquisa



Fonte: Elaborado pela autora (2020)

O panorama ainda relata os resultados dessa integração de temas, pontuando sobre as contribuições científicas, que apontam para o preenchimento de uma lacuna na literatura, contribuindo com pesquisas futuras, que abordam o tema, levando em consideração o âmbito social, em que se buscou o bem-estar dos colaboradores da empresa por meio de uma plataforma que está atrelada ao desenvolvimento tecnológico, conforme demonstrou essa pesquisa.

#### 4.4 CONSIDERAÇÕES SOBRE A SEÇÃO

Essa Seção reuniu os resultados alcançados com a Revisão de Literatura, a Pesquisa de Campo e o Desenvolvimento da Plataforma, bem como a discussão sobre os mesmos.

A Revisão de literatura apresentou a atualidade do tema e o interesse mundial demonstrado através das análises bibliométricas, enquanto que a análise de conteúdo forneceu aporte de técnicas e tecnologias para o desenvolvimento de plataformas on-line que lidam com BD e BDA.

Por sua vez, os resultados da Pesquisa de Campo apresentaram mais

informações sobre a empresa, destacando algumas dificuldades no processo de disponibilizar os dados para o acompanhamento dos supervisores e tomadores de decisão, como a não existência de uma visualização centralizada em um único ambiente e a necessidade de manipulação dessa BD todas as vezes que alguma pessoa desejava ter acesso aos indicadores de defeitos na produção.

Essas questões apontavam para a necessidade de uma plataforma que fornecesse apoio na análise desses dados, através da BDA. Portanto, os resultados da metodologia para desenvolvimento da plataforma e-TQM vem de encontro com essa constatação e apresenta o funcionamento da plataforma, com seus principais filtros, gráficos e tabelas, que promoveram a automatização do processo repetitivo, além de apresentar os ganhos do projeto, que evidenciam o ganho em questões de tempo e também de qualidade no processo que se tornou automatizado.

A relação entre I4.0, TQM, BD e BDA é mencionada, demonstrando que pessoas e dados formam a conexão dessas esferas que a princípio podem parecer tão diferentes.

## 5 CONSIDERAÇÕES FINAIS

Essa Seção busca sintetizar as conclusões sobre o esse trabalho, e está dividida em três subseções que abordam a análise dos objetivos, considerações gerais e sugestões para trabalhos futuros.

### 5.1 ANÁLISE DOS OBJETIVOS

O presente trabalho atingiu seu Objetivo Geral (OG), que visava *propor uma forma de adaptar a gestão e o acompanhamento dos indicadores de qualidade de uma empresa multinacional automobilística, às mudanças tecnológicas advindas da Indústria 4.0 (I4.0)*. E para que o OG fosse atingido, foram delimitados os Objetivos Específicos (OE), que por sua vez, também foram atingidos, sendo as considerações sobre um descrito a seguir:

- **OE1:** *Realizar um levantamento dos procedimentos, técnicas e ferramentas de manipulação da Big Data:* o OE1 constitui a primeira parte desse trabalho, e visava buscar base teórica para que os demais objetivos pudessem ser alcançados. Dessa forma, após as Subseções 3.1 e 3.2 apresentarem as características da pesquisa, bem como sua organização, a Subseção 3.3, de metodologia, descreveu o passo a passo da metodologia de revisão sistemática de literatura, *Methodi Ordinatio* (Autor, 0000), que resultou no portfólio de 70 artigos. Esses artigos forneceram uma visão sobre a atualidade dos temas abordados, bem como o interesse mundial por eles, o que caracterizou essa pesquisa como atual e de interesse, sendo esses resultados apresentados na Subseção 4.1.1, por meio da análise bibliométrica. Na sequência, após a leitura dos artigos selecionados, a análise de conteúdo reuniu diversos autores que contribuíram com técnicas e tecnologias para trabalhar com a *Big Data*, divididas em seis partes, conforme apresentado na Subseção 4.1.2. Assim, na Pesquisa de Campo, foi possível identificar se a empresa automobilística dispunha de algumas dessas tecnologias para o desenvolvimento da plataforma on-line, além

disso, essa reunião de autores, técnicas e tecnologias podem servir de auxílio para outros autores em pesquisas futuras sobre o tema.

- **OE2:** *Compreender como são analisados e disponibilizados os indicadores TQM utilizados pela indústria automobilística, objeto deste estudo, para o acompanhamento dos defeitos na produção:* após a conclusão do OE1, que forneceu a base teórica para a construção da plataforma, foi possível avançar a Pesquisa de Campo que foi desenvolvida presencial na empresa automobilística, durante 12 meses, totalizando 1.152 horas para compreender como os indicadores de defeitos na produção (D-in, D-off e DPHU), eram analisados e disponibilizados para que os supervisores de produção pudessem desenvolver seu plano de ação semanal, sendo a metodologia para essa exploração inicial descrita na Subseção 3.4 e 3.4.1. Para que o OE2 pudesse ser alcançado, a observação assistemática foi empregada, possibilitando compreender quais eram os requisitos para que a plataforma on-line fosse desenvolvida e fornecesse suporte para a tomada de decisão. Os resultados alcançados demonstraram quais eram os indicadores de qualidade utilizados pela empresa, bem como quais eram os que focavam no acompanhamento de defeitos na produção. Possibilitando entender quais eram os desafios relacionados a disponibilização desses indicadores, conforme apresentaram os resultados na Subseção 4.2.

- **OE3:** *Desenvolver uma plataforma on-line para gerir e acompanhar os indicadores de defeitos na produção da empresa automobilística:* com a base teórica e as informações da pesquisa de campo reunidas, foi possível dar início ao desenvolvimento da plataforma on-line, seguindo a metodologia apresentada na Subseção 3.5 para a construção de um rascunho dos requisitos da plataforma. Depois disso, a Subseção 4.3 evidencia como a ferramenta Tableau se conecta a base de dados dos indicadores de defeitos na produção, para serem analisados e disponibilizados na plataforma e-TQM, que é apresentada em seguida, demonstrando a visão dos indicadores, por meio de gráficos e tabelas, fornecida como suporte para a tomada de decisão dos supervisores de produção. Os ganhos quantitativos e qualitativos observados com o uso da plataforma são descritos na

Subseção 4.3.1, demonstrando resultados positivos em relação a redução do tempo empregado na análise e disponibilização das informações sobre os indicadores, além do aumento da qualidade no processo, na informação e na comodidade dos colaboradores da indústria. Por fim, correlacionando os temas abordados nesse trabalho, a Subseção 4.3.2 apresenta a relação naturalmente existente entre os temas, demonstrando oportunidades para que essas relações possam ser exploradas em diferentes setores.

## 5.2 CONSIDERAÇÕES GERAIS

Com a Gestão da Qualidade Total (TQM), que é uma estratégia de gerenciamento que visa o desenvolvimento da consciência de qualidade em todos os processos organizacionais, é possível fazer o acompanhamento dos indicadores de qualidade que são definidos para que exista alinhamento de objetivos entre todos os setores de uma organização.

Os indicadores são constituídos por um grande número de dados, que atualmente são provenientes da Indústria 4.0 (I4.0), caracterizada pela ampla variedade de tecnologias que podem ser aproveitadas para que o acompanhamento da qualidade seja realizado de forma mais fácil e eficaz.

Entretanto, esse aumento exponencial de dados disponíveis caracterizou um problema de Big Data (BD), que necessita de uma análise específica, conhecida como Big Data Analysis (BDA).

Essa problemática evidenciou a necessidade de uma adequação quanto as formas de gerir a qualidade dentro do contexto industrial, portanto, essa pesquisa buscou propor uma forma de adaptar a gestão e o acompanhamento dos indicadores de qualidade de defeitos de produção de uma empresa multinacional do ramo automobilístico, às mudanças tecnológicas resultantes da I4.0, buscando integrar qualidade e tecnologia.

Para isso, foi realizada uma Revisão Sistemática de Literatura, por meio da metodologia Methodi Ordinatio, resultando em um portfólio de artigos com relevância

científica, o qual foi fonte das coletas de dados para análise de conteúdo, aliado a isso, uma pesquisa de campo foi realizada na empresa automobilística, que serviu de base para a definição da metodologia utilizada para desenvolver uma plataforma on-line para gestão de indicadores de qualidade.

A combinação dessas metodologias resultou na plataforma on-line e-TQM, desenvolvida para gerir o acompanhamento da Gestão da Qualidade Total (TQM), automatizando o processo de obtenção, análise e disponibilização dos indicadores de defeitos na produção, resultando em ganho de tempo e melhoria de processo para a empresa multinacional do ramo automobilístico, objeto de pesquisa do estudo de caso.

Além disso, com a revisão de literatura, que abrangeu a análise bibliométrica e a análise de conteúdo, foi possível reunir diversos autores, técnicas e tecnologias para análise de grandes quantidades de dados que podem ser úteis para embasar trabalhos futuros que abordem uma problemática similar, juntamente a isso, a bibliometria demonstrou o interesse atual e mundial pelos temas aqui abordados, evidenciando a necessidade de mais pesquisas para aumentar o conhecimento sobre esses temas.

Dessa forma, esse trabalho propôs um meio de conciliar a Big Data gerada pelas tecnologias dessa nova fase, a uma gestão TQM simplificada e acessível o mais próximo do tempo real possível, contribuindo para o aumento de informações sobre como tratar da BD industrial, através de técnicas de BDA, além de tornar o processo de acompanhamento dos dados mais acessível e prático para a empresa, o que ajudou a evidenciar o relacionamento naturalmente existente entre a Indústria 4.0, a Gestão da Qualidade Total e a Big Data Analytics, que possuem em comum os dados e a necessidade do envolvimento de pessoas em seus processos.

E reunir e exemplificar formas de trabalhar com a Big Data no contexto da I4.0, pode promover o embasamento de pesquisas futuras sobre o tema, e disponibiliza o conhecimento industrial sobre os ganhos de se utilizar técnicas e tecnologias de Big Data Analysis, melhorando a obtenção de resultados positivos, quanto a análise de dados, por meio da implantação desses conceitos na indústria. Com isso, tem-se as contribuições deste trabalho, que estão divididos nos âmbitos



científicos, sociais e tecnológicos.

Entretanto, é interessante ressaltar que essa pesquisa apresenta uma solução específica para o estudo de caso apresentado, sendo necessário que estudos que visem outros cenários sejam realizados, abrangendo pequenas empresas e organizações públicas, por exemplo, sendo esse um ponto de limitação dessa pesquisa.

Algumas limitações como o tempo estipulado para o início e fim do projeto e a falta de reuniões com as demais unidades da empresa em outros países, fez com que a ferramenta ainda não fosse compartilhada entre elas.

Outra questão que tornou o andamento do projeto mais lento, foi devido ao momento de pandemia mundial de COVID-19. Nesse momento, boa parte das reuniões sobre o uso da plataforma foram realizadas remotamente, devido a muitas pessoas estarem trabalhando diretamente de suas casas.

A plataforma obteve adesão de uso por boa parte dos supervisores de produção, porém, ao se inserir uma nova tecnologia em um ambiente que anteriormente não estava habituado, certa resistência ao uso pode surgir, e isso foi observado em alguns momentos durante a implementação do uso da plataforma.

Para diminuir essa resistência e estranhamento da nova forma de uso, uma atualização nas cores e nos formatos dos gráficos da plataforma foi realizada, trazendo mais familiaridade com o que os supervisores já estavam acostumados a observar na planilha eletrônica e no painel manual.

Diante da originalidade do presente trabalho, visualizada através do resultado obtido com a revisão sistemática de literatura, observa-se a importância de estudos como este no contexto mundial atual, portanto, a Subseção seguinte aborda oportunidades a serem exploradas em pesquisas futuras.

### 5.3 SUGESTÕES PARA TRABALHOS FUTUROS

O projeto piloto da plataforma e-TQM utilizou apenas os dados dos indicadores de defeitos da produção do Brasil, mas a conexão com a base de dados

das demais unidades da América Latina localizadas no Chile, Colômbia e Argentina, em que a empresa está presente, também podem ser acessados pela plataforma, sendo um passo seguinte que esses países também comecem a utilizá-la.

Além disso, outros indicadores podem ser adicionados a plataforma, como indicadores de segurança que demonstram a quantidade de acidentes que ocorrem na indústria, por exemplo, tornando o acompanhamento da qualidade ainda mais centralizado e mais próximo do tempo real.

Da mesma forma, as metodologias e ferramentas descritas nesse trabalho, podem servir de base para que outras plataformas sejam desenvolvidas, não se limitando apenas ao setor industrial, mas abrangendo setores públicos e educacionais, e até mesmo propostas de *dashboards* para *Smart Cities*.

Quanto as pesquisas futuras, é interessante investigar a incompatibilidades entre os sistemas de qualidade e a I4.0 e como os gerentes podem superar esse desafio (ASIF, 2020), abrangendo as diferentes áreas da TQM, que são de gestão de processos, gestão de pessoas e a gestão estratégica (DAHLGAARD-PARK et al., 2013), é sempre possível que desafios surjam entre as partes interessadas como gerência e colaboradores.

Sader, Husti e Daróczy (2019), sugerem que pesquisas discutam o impacto e o papel da I4.0 nas práticas e resultados de TQM, acrescentando ainda que uma parceria industrial, para o desenvolvimento conjunto de sistemas de gerenciamento de qualidade, é altamente recomendada para nesses estudos.

Portanto, é muito importante que diversas iniciativas, que visem a facilitação do acompanhamento da qualidade dentro das organizações, sejam estudadas e desenvolvidas, como foi buscado nesse trabalho.

## REFERÊNCIAS

ABAWAJY, J. Comprehensive analysis of big data variety landscape. **International Journal Of Parallel, Emergent And Distributed Systems**, [s.l.], v. 30, n. 1, p. 5-14, jul. 2014.

ABDULLAH, M. *et al.*. Value-based total performance excellence model: A conceptual framework for organisations. **Total Quality Management & Business Excellence**, [s.l.], v. 23, n. 5-6, p. 557-572, jun. 2012.

ABELL, J. A. *et al.*. Big Data-Driven Manufacturing Process Monitoring for Quality Philosophy. **Journal Of Manufacturing Science And Engineering**, [s.l.], v. 139, n. 10, p.1-12, ago. 2017.

ABEPRO - Associação Brasileira de Engenharia de Produção. A Profissão. Rio de Janeiro: ABEPRO, 2020. Disponível em: <http://portalabepro.educacao.ws/a-profissao/#1521896790619c29714ce-c6b0>. Acesso em: 02 mar. 2020.

ACETO, G.; PERSICO, V.; PESCAPE, A. A Survey on Information and Communication Technologies for Industry 4.0: State-of-the-Art, Taxonomies, Perspectives, and Challenges. **Ieee Communications Surveys & Tutorials**, [s.l.], v. 21, n. 4, p. 3467-3501, ago. 2019.

ACHARJYA, D. P.; AHMED, K. A Survey on Big Data Analytics: Challenges, Open Research Issues and Tools. **International Journal of Advanced Computer Science and Applications**, [s.l.], v. 7, n. 2, p. 511-518, fev. 2016.

AJAYI, A. *et al.*. Optimised Big Data analytics for health and safety hazards prediction in power infrastructure operations. **Safety Science**, [s.l.], v. 125, n. 1, p. 1-12, mai. 2020.

ALI, A. H.; ABDULLAH, M. Z. A Survey on Vertical and Horizontal Scaling Platforms for Big Data Analytics. **International Journal Of Integrated Engineering**, [s.l.], v. 11, n. 6, p. 138-150, set. 2019.

ALOFAN, F.; CHEN, S.; TAN, H. National cultural distance, organizational culture,

and adaptation of management innovations in foreign subsidiaries: A fuzzy set analysis of TQM implementation in Saudi Arabia. **Journal Of Business Research**, [s.l.], v. 109, n. 4, p. 184-199, mar. 2020.

AMERICAN SOCIETY FOR QUALITY (ASQ)a. Edwards Deming's 14 points for total quality management. Wisconsin: 2020. Disponível em: <https://asq.org/quality-resources/total-quality-management/deming-points>. Acesso em: 04 mai. 2020.

AMERICAN SOCIETY FOR QUALITY (ASQ)b. The 7 basic quality tools for process improvement. Wisconsin: 2020. Disponível em: <https://asq.org/quality-resources/seven-basic-quality-tools>. Acesso em: 04 mai. 2020.

AMIN, M. *et al.*. The structural relationship between TQM, employee satisfaction and hotel performance. **International Journal of Contemporary Hospitality Management** v. 29, n. 4, p. 1256-1278, abr. 2017.

ANIL, A. P.; SATISH, K. P. Investigating the Relationship Between TQM Practices and Firm's Performance: A Conceptual Framework for Indian Organizations. **Procedia Technology**, [s.l.], v. 24, n. 3, p. 554-561, mai. 2016.

ANSHARI, M. *et al.*. Customer relationship management and big data enabled: Personalization & customization of services. **Applied Computing And Informatics**, [s.l.], v. 15, n. 2, p. 94-101, jul. 2019.

ANTAL, M. A "parasite market": A competitive market of energy price comparison websites reduces consumer welfare. **Energy Policy**, [s.l.], v. 138, n. 1, p.111228-111241, jan. 2020.

ARAUJO, R. *et al.*. The Quality Management System as a Driver of Organizational Culture: An Empirical Study in the Portuguese Textile Industry. **Quality Innovation Prosperity**, v. 23, n. 1, p. 1-24, jan. 2019.

ASIF, M. Are QM models aligned with Industry 4.0? A perspective on current practices. **Journal Of Cleaner Production**, [s.l.], v. 258, n. 1, p. 1-11, jun. 2020.

BABAR, M. *et al.*. Urban data management system: Towards Big Data analytics for

Internet of Things based smart urban environment using customized Hadoop. **Future Generation Computer Systems**, v. 96, p. 398-409, jul. 2019.

BAG, S. *et al.*. Big data analytics as an operational excellence approach to enhance sustainable supply chain performance. **Resources, Conservation And Recycling**, [s.l.], v. 153, n. 2, p.104559-104569, fev. 2020.

BAGOZI, A. *et al.*. A Relevance-based approach for Big Data Exploration. **Future Generation Computer Systems**, v. 101, p. 51-69, dez. 2019.

BAJABER, F. *et al.*. Big Data 2.0 Processing Systems: Taxonomy and Open Challenges. **Journal Of Grid Computing**, [s.l.], v. 14, n. 3, p.379-405, jun. 2016.

BARATA, J.; CUNHA, P. R. Synergies between quality management and information systems: a literature review and map for further research. : a literature review and map for further research. **Total Quality Management & Business Excellence**, [s.l.], v. 28, n. 3-4, p. 282-295, set. 2015.

BEHESHTI, H.; LOLLAR, J. An empirical study of US SMEs using TQM. **Total Quality Management & Business Excellence**, [s.l.], v. 14, n. 8, p. 839-847, out. 2003.

BELHADI, A. *et al.*. Understanding Big Data Analytics for Manufacturing Processes: Insights from Literature Review and Multiple Case Studies. **Computers & Industrial Engineering**, [s.l.], v. 137, n. 11, p. 106099-106116, nov. 2019.

BIONDI, S. *et al.*. A New Approach for Assessing Dealership Performance: An Application for the Automotive Industry. **International Journal Of Engineering Business Management**, [s.l.], v. 5, n. 1, p. 18-26, jan. 2013.

BOLATAN, G. I. S. *et al.*. The Impact of Technology Transfer Performance on Total Quality Management and Quality Performance. **Procedia - Social And Behavioral Sciences**, [s.l.], v. 235, n. 20, p. 746-755, nov. 2016.

BOULTER, L.; BENDELL, T.; DAHLGAARD, J. Total quality beyond North America. **International Journal Of Operations & Production Management**, [s.l.], v.

33, n. 2, p. 197-215, fev. 2013.

BRETTEL, M. *et al.*. How Virtualization, Decentralization and Network Building Change the Manufacturing Landscape: An Industry 4.0 Perspective", **International Journal of Information and Communication Engineering**, v. 8, n. 1, p. 37-44, jan. 2014.

BUGDOL, M.. "The problem of fear in TQM – causes, consequences and reduction methods – a literature review", **The TQM Journal**, v. 32, n. 6, p. 1217-1239, abr. 2020.

BUHL, H. U. *et al.*. Big Data. **Business & Information Systems Engineering**, [s.l.], v. 5, n. 2, p. 65-69, fev. 2013.

BUMBLAUSKAS D. *et al.*. Big data analytics: transforming data to action. **Business Process Management Journal**, [s.l.], v. 23, n. 3, p. 703-720, jun. 2017.

CAMPOS, C. J. G.. Método de análise de conteúdo: ferramenta para a análise de dados qualitativos no campo da saúde. **Revista Brasileira de Enfermagem**, [s.l.], v. 57, n. 5, p. 611–614, jan 2004.

CÂNDIDO, C. J. F.; SANTOS, S. P. Is TQM more difficult to implement than other transformational strategies?. **Total Quality Management & Business Excellence**, [s.l.], v. 22, n. 11, p. 1139-1164, nov. 2011.

CAPPELLE, M. C. A.; MELO, M. C. O. L.; GONCALVES, C. A.. Analysis of contents and analysis of speech in social sciences. **Organizações Rurais & Agroindustriais**, [s.l.], v. 5, n. 1, p. 0-0, 2003.

CAREGNATO, R. C. A.; MUTTI, R.. Pesquisa qualitativa: análise de discurso versus análise de conteúdo. **Texto & Contexto - Enfermagem**, SciELO Brasil, v. 15, n. 4, p. 679–84, 2006.

CHAE, B. Developing key performance indicators for supply chain: an industry perspective. **Supply Chain Management: An International Journal**, [s.l.], v. 14, n.

6, p. 422-428, set. 2009.

CHANDIO, A. A.; TZIRITAS, N.; XU, C.. Big-data processing techniques and their challenges in transport domain. **ZTE Communications**, [s.l.], v. 13, n. 1, p. 50-59, abr. 2015.

CHANG, J.; LI, H.; SUN, B. Matching Knowledge Suppliers and Demanders on a Digital Platform: A Novel Method. **Ieee Access**, Xian, v. 7, n. 2, p. 21331-21342, 2019.

CHEN, H.; CHIANG, L. H. R.; STOREY, V. C. Business Intelligence and Analytics: from big data to big impact: From Big Data to Big Impact. **Mis Quarterly**, [s.l.], v. 36, n. 4, p. 1165-1188, jan. 2012.

CHOISNE, F.; GROSBOIS, D.; KUMAR, U. Impact of TQM on company's performance. **International Journal Of Quality & Reliability Management**, [s.l.], v. 26, n. 1, p. 23-37, jan. 2009.

CIMINI, C. *et al.*. A human-in-the-loop manufacturing control architecture for the next generation of production systems. **Journal Of Manufacturing Systems**, [s.l.], v. 54, n. 1, p. 258-271, jan. 2020.

CORSI, A. *et al.*. Technology transfer for sustainable development: Social impacts depicted and some other answers to a few questions. **Journal of Cleaner Production**, v. 245, n.1, p. 118522- 118527, fev. 2020.

CROSBY, P. B. Quality without tears: the art of hassle-free management. 1. ed. New York: McGraw-Hill, 1984.

DAHLGAARD, J. J.; DAHLGAARD-PARK, S. M. Lean production, six sigma quality, TQM and company culture. **The Tqm Magazine**, [s.l.], v. 18, n. 3, p.263-281, mai. 2006.

DAHLGAARD-PARK, S. M. *et al.*. Diagnosing and prognosticating the quality movement – a review on the 25 years quality literature (1987–2011). **Total Quality**

**Management & Business Excellence**, [s.l.], v. 24, n. 1-2, p. 1-18, fev. 2013.

DAHLGAARD-PARK, S.M. *et al.*. Core values – the entrance to human satisfaction and commitment. **Total Quality Management & Business Excellence**, [s.l.], v. 23, n. 2, p. 125-140, jan. 2012.

DALE, B. (2015) "Total Quality Management", In: Cooper, C. L., Roden, S., Lewis, M., Slack, N. (eds.) *Wiley Encyclopedia of Management*, Wiley, Chichester, UK, pp. 1–4.

DALENOGARE, L. S. *et al.*. The expected contribution of Industry 4.0 technologies for industrial performance. **International Journal Of Production Economics**, [s.l.], v. 204, p. 383-394, out. 2018.

DELIGIANNIS, K. *et al.*. Hydria: an on-line data lake for multi-faceted analytics in the cultural heritage domain. **Big Data And Cognitive Computing**, [s.l.], v. 4, n. 2, p. 1-28, abr. 2020.

DEMING, W. E. *Out of the Crisis*. 2. ed. Cambridge: MIT press, 2018.

DRAGICEVIC, N. *et al.*. A conceptual model of knowledge dynamics in the industry 4.0 smart grid scenario. **Knowledge Management Research & Practice**, Londres, v. 17, n. 3, p.1-15, jun. 2019.

DRUCKER, J. *Graphesis: Visual forms of knowledge production*. 1. ed. Harvard University: Press, 2014.

DUBEY, R. *et al.*. Can big data and predictive analytics improve social and environmental sustainability?. **Technological Forecasting And Social Change**, [s.l.], v. 144, n. 7, p. 534-545, jul. 2019.

DURANA; P. Quality Culture of Manufacturing Enterprises: a possible way to adaptation to industry 4.0: A Possible Way to Adaptation to Industry 4.0. **Social Sciences**, [s.l.], v. 8, n. 4, p. 1-24, abr. 2019.



ECKES, G. **Six Sigma Execution**: How the World's Greatest Companies Live and Breathe Six Sigma. New York: United States of America: McGraw-Hill, 2005.

EREVELLES, S. *et al.*. Big Data consumer analytics and the transformation of marketing. **Journal Of Business Research**, [s.l.], v. 69, n. 2, p. 897-904, fev. 2016.

ESPOSITO, C. *et al.*. A knowledge-based platform for Big Data analytics based on publish/subscribe services and stream processing. **Knowledge-based Systems**, [s.l.], v. 79, p. 3-17, mai. 2015

FATORACHIAN, H.; KAZEMI, H. A critical investigation of Industry 4.0 in manufacturing: theoretical operationalisation framework. : theoretical operationalisation framework. **Production Planning & Control**, [s.l.], v. 29, n. 8, p. 633-644, jan. 2018.

FEIGENBAUM, A.V. **Total quality control**: engineering and management: the technical and management field for improving product quality, including its reliability, and for reducing operating costs and losses. 1. ed. New York: McGraw-Hill, 1961.

FISHER, D. *et al.*. Interactions with big data analytics. **Interactions**, [s.l.], v. 19, n. 3, p.50-60, mai. 2012.

FLUME. **Apache Flume**. Disponível em: <https://flume.apache.org/>. Acesso em: 19 nov. 2020.

FOSTER, S. T. **Managing Quality an Integrative Approach**. 1. ed. New Jersey: Prentice Hall, 2001.

FRANK, A. G. *et al.*. Servitization and Industry 4.0 convergence in the digital transformation of product firms: a business model innovation perspective: A business model innovation perspective. **Technological Forecasting And Social Change**, [s.l.], v. 141, p. 341-351, abr. 2019.

FUENTES, J. M. *et al.*. Impact of use of information technology on lean production adoption: evidence from the automotive industry. **International Journal Of**

**Technology Management**, [s.l.], v. 57, n. 1/2/3, p.132-148, dez. 2012.

GAO, L. X.; MELERO, I.; SESE, F. J. Multichannel integration along the customer journey: a systematic review and research agenda. **The Service Industries Journal**, [s.l.], v. 40, n. 15/16, p.1-32, ago. 2019.

GARTNER. **Pattern based strategy getting value from big data**. 2011. Disponível em: <https://www.gartner.com/en/documents/1727419/pattern-based-strategy-getting-value-from-big-data>. Acesso em: 06 abr. 2020.

GARVIN, D. A. **Managing Quality the Strategic and Competitive Edge**. 1. ed. New York: The Free Press, 1988.

GHANI, N. A. *et al.*. Social media big data analytics: a survey. **Computers In Human Behavior**, [s.l.], v. 101, n. 1, p. 417-428, dez. 2019.

GHOBAKHLOO, M. The future of manufacturing industry: a strategic roadmap toward industry 4.0. : a strategic roadmap toward Industry 4.0. **Journal Of Manufacturing Technology Management**, [s.l.], v. 29, n. 6, p. 910-936, out. 2018.

GHOBAKHLOO, M.; FATHI, M. Corporate survival in Industry 4.0 era: the enabling role of lean-digitized manufacturing: the enabling role of lean-digitized manufacturing. **Journal Of Manufacturing Technology Management**, [s.l.], v. 31, n. 1, p. 1-30, jul. 2019.

GIL, A. C. Como elaborar projetos de pesquisa. 2.ed. São Paulo: Atlas, 1991.

GIL, A.C. Métodos e técnicas de pesquisa social. 6. ed. São Paulo: Atlas, 2008.

GIL, A.C. Métodos e técnicas em pesquisa social. 5.ed. São Paulo: Atlas, 1999.

GODOY, A. S. Pesquisa qualitativa: tipos fundamentais. **Revista de Administração**

**de Empresas**, São Paulo, v. 35, n. 3, p. 20-29, jun. 1995.

GOECKS, L. S.; SANTOS, A. A.; KORZENOWSKI, A. L.. Decision-making trends in quality management: a literature review about industry 4.0. **Production**, [s.l.], v. 30, p. 1-11, 2020.

GÓMEZ-LÓPEZ, R.; LÓPEZ-FERNÁNDEZ, M. C.; SERRANO-BEDIA, A. M.. Implementation barriers of the EFQM excellence model within the Spanish private firms. **Total Quality Management & Business Excellence**, [s.l.], v. 28, n. 7-8, p. 695-711, nov. 2015.

GOWER, D. L. (Ed.) (1990). *Gower Handbook of Quality Management*. England: Gower Publishing Company Limited."

GRAY, S.; O'BRIEN, O.; HÜGEL, S. Collecting and Visualizing Real-Time Urban Data through City Dashboards. **Built Environment**, [s.l.], v. 42, n. 3, p. 498-509, out. 2016.

GROVER, P.; KAR, A. K.. Big data analytics: A review on theoretical contributions and tools used in literature. **Global Journal of Flexible Systems Management**, v. 18, n. 3, p. 203-229, 2017.

GUNASEKARAN, A; SUBRAMANIAN, N; NGAI, W. T. E. Quality management in the 21st century enterprises: research pathway towards industry 4.0: Research pathway towards Industry 4.0. **International Journal Of Production Economics**, [s.l.], v. 207, p. 125-129, jan. 2019.

HACKMAN, J. R.; WAGEMAN, R. Total Quality Management: Empirical, Conceptual, and Practical Issues. **Administrative Science Quarterly**, [s.l.], v. 40, n. 2, p. 309-342, jun. 1995.

HAGIU, A.; ALTMAN, E. J. "Finding the platform in your product four strategies that can reveal hidden value", **Harvard Business Review**, Boston, v. 95, n. 4, p. 94-100, 2017.

HALEVI, G.; MOED, H. (2012), "The evolution of big data as a research and scientific

topic: overview of the literature”, *Research Trends*, Vol. 30, pp. 3-6.”

HAMID, N. A. *et al.*. DETERMINANTS OF REINVESTMENT ALLOWANCE (RA) TAX INCENTIVE UTILIZATION IN EMBRACING INDUSTRY 4.0. **Polish Journal Of Management Studies**, [s.l.], v. 18, n. 2, p. 94-104, dez. 2019.

HARIHARASUDAN, A.; KOT, S. A Scoping Review on Digital English and Education 4.0 for Industry 4.0. **Social Sciences**, Basiléia, v. 7, n. 11, p. 227-247, nov. 2018.

HERMANN, M.; PENTEK, T.; OTTO, B. Design Principles for Industrie 4.0 Scenarios. 2016 49th Hawaii International Conference On System Sciences (hicc), [s.l.], v. 1, n. 1, p. 3927-3937, jan. 2016.

HITPASS, B. BPM: **Business Process Management, Fundamentos y Conceptos de Implementación**. 4. ed. Santiago: BHH LTDA, 2017.

HITPASS, B.; ASTUDILLO, H. Industry 4.0 Challenges for Business Process Management and Electronic-Commerce. **Journal Of Theoretical And Applied Electronic Commerce Research**, [s.l.], v. 14, n. 1, p. 1-3, jan. 2019.

HIVE. **Apache Hive**. Disponível em: <https://hive.apache.org/>. Acesso em: 19 nov. 2020.

HU, H. *et al.*. Toward Scalable Systems for Big Data Analytics: A Technology Tutorial. **Ieee Access**, [s.l.], v. 2, p. 652-687, jun. 2014.

HUNG, S.; TANG, R. Factors affecting the choice of technology acquisition mode: an empirical analysis of the electronic firms of Japan, Korea and Taiwan: An empirical analysis of the electronic firms of Japan, Korea and Taiwan. **Technovation**, [s.l.], v. 28, n. 9, p. 551-563, set. 2008.

IMAI, M. (1986). **Kaizen (Ky'zen), the key to Japan's competitive success** (1 ed.). New York: McGraw-Hill.

IQBAL, R. *et al.*. Big data analytics: Computational intelligence techniques and

application areas. **Technological Forecasting And Social Change**, [s.l.], v. 153, n.1, p.1-13, abr. 2020.

ISHIKAWA, K. **What is total quality control?: The Japanese way**. 1 ed. Universidade de Michigan: Prentice-Hall, 1985.

JACOB, D. (2017). **Quality 4.0 Impact and Strategy Handbook**. Getting Digitally Connected to Transform Quality Management. United State of America: LNS Research.

JAGADISH, H.V. *et al.*. Big Data and its technical challenges. **Communications of the ACM**, [s.l.], v. 57, n. 7, pp. 86-94, jan. 2014.

JIANG, S. *et al.*. Ensemble Prediction Algorithm of Anomaly Monitoring Based on Big Data Analysis Platform of Open-Pit Mine Slope. **Complexity**, [s.l.], v. , p. 1-13, ago. 2018.

JURAN, J. M. **Juran's quality control handbook**. 4. ed. New York: McGraw-Hill, 1988.

KAFKA. **Apache Kafka**. Disponível em: <https://kafka.apache.org/>. Acesso em: 19 nov. 2020.

KAKHANI ,M. K.; KAKHANI, S.; BIRADAR, S. R. Research issues in big data analytics, **International Journal of Application or Innovation in Engineering & Management**, [s.l.], v. 2, n. 8, p. 228-232, jan. 2015.

KAMBATLA, K., *et al.*. Trends in big data analytics. **Journal Of Parallel And Distributed Computing**, [s.l.], v. 74, n. 7, p. 2561-2573, jul. 2014.

KAMBLE, S. S.; GUNASEKARAN, A.; GAWANKAR, S. A. Sustainable Industry 4.0 framework: a systematic literature review identifying the current trends and future perspectives. **Process Safety And Environmental Protection**, [s.l.], v. 117, p. 408-425, jul. 2018.

KAMBLE, S.; GUNASEKARAN, A.; DHONE, N. C. Industry 4.0 and lean manufacturing practices for sustainable organisational performance in Indian manufacturing companies. **International Journal Of Production Research**, [s.l.], v. 1, n. 1, p. 1-19, jun. 2019.

KAUFFMANN, E. *et al.*. A framework for big data analytics in commercial social networks: A case study on sentiment analysis and fake review detection for marketing decision-making. **Industrial Marketing Management**, [s.l.], v. 90, p. 523-537, ago. 2019.

KITCHIN, R. **The Data Revolution: Big Data, Open Data, Data Infrastructures and Their Consequences**. 1. ed. Los Angeles: Sage, 2014.

KLEFSJÖ, B., *et al.*. Quality management and business excellence, customers and stakeholders. **The Tqm Journal**, [s.l.], v. 20, n. 2, p. 120-129, fev. 2008.

KO, I.; CHANG, H. Interactive Visualization of Healthcare Data Using Tableau. **Healthcare Informatics Research**, [s.l.], v. 23, n. 4, p. 349-354, jan. 2017.

KOURTIT, K.; NIJKAMP, P. Big data dashboards as smart decision support tools for i-cities – An experiment on stockholm. **Land Use Policy**, [s.l.], v. 71, n. 3, p. 24-35, fev. 2018.

KUMAR, A. S. S.; SHANMUGANATHAN, J.. A Structural Relationship Between TQM Practices and Organizational Performance with Reference to Selected Auto Component Manufacturing Companies. **International Journal of Management**, v. 10, n. 5, pp. 99–108, dec. 2019

LAKATOS, E. M.; MARCONI, M. Eva.. **Fundamentos de Metodologia Científica**. [s.n.], 2005.

LEE, J. Y.; YOON, J. S.; KIM, B. A big data analytics platform for smart factories in small and medium-sized manufacturing enterprises: An empirical case study of a die casting factory. **International Journal Of Precision Engineering And Manufacturing**, [s.l.], v. 18, n. 10, p. 1353-1361, out. 2017.

LEE, J; KAO, H.; YANG, S.. Service Innovation and Smart Analytics for Industry 4.0 and Big Data Environment. **Procedia Cirp**, [s.l.], v. 16, n. 6, p. 3-8, 2014.

LIANG, Yi *et al.* Financial Big Data Analysis and Early Warning Platform: A Case Study. **IEEE Access**, v. 8, p. 36515-36526, jan. 2020.

LÔ, A.; DIOCHON, P. F. Unsilencing power dynamics within third spaces. The case of Renault's Fab Lab. **Scandinavian Journal Of Management**, [s.l.], v. 35, n. 2, p.1-9, jun. 2019.

LONGO, R. M. J. **Gestão da Qualidade**: Evolução Histórica, Conceitos Básicos e Aplicação na Educação. In: CONGRESSO GESTÃO DA QUALIDADE NA EDUCAÇÃO, 397., 1996, Brasília. Anais eletrônicos [...]. Brasília: SENAC, 1996. Disponível em: [https://www.ipea.gov.br/portal/index.php?option=com\\_content&view=article&id=3552&Itemid=1](https://www.ipea.gov.br/portal/index.php?option=com_content&view=article&id=3552&Itemid=1). Acesso em: 27. Abr. 2020.

MA, L. Traditional Music Protection System from the Ecological Perspective based on Big Data Analysis. **Ekoloji**. [s.l.], v.2, n. 107, p. 3667-3676, fev. 2019.

MAKKIE, M. *et al.* A Distributed Computing Platform for fMRI Big Data Analytics. **Ieee Transactions On Big Data**, [s.l.], v. 5, n. 2, p. 109-119, jun. 2019.

MANDAL, S. K. **Total Quality Management**: Principles And Practice. 1. Ed. Vikas Publishing House Pvt Limited, 2009.

MANOGARAN, G.; LOPEZ, D. Spatial cumulative sum algorithm with big data analytics for climate change detection. **Computers & Electrical Engineering**, [s.l.], v. 65, p. 207-221, jan. 2018.

MAURO, A.; GRECO, M.; GRIMALDI, M. Understanding Big Data Through a Systematic Literature Review: The ITMI Model. **International Journal Of Information Technology & Decision Making**, [s.l.], v. 18, n. 4, p. 1433-1461, jul. 2019.

MOHAMED, A. *et al.* The state of the art and taxonomy of big data analytics: view

from new big data framework. **Artificial Intelligence Review**, [s.l.], v. 53, n. 2, p. 989-1037, fev. 2019.

MOHELSKA, H.; SOKOLOVA, M. Management approaches for industry 4.0 – the organizational culture perspective. **Technological And Economic Development Of Economy**, [s.l.], v. 24, n. 6, p. 2225-2240, nov. 2018.

MOTOYAMA, Y.; EISLER, M. N. Bibliometry and nanotechnology: A meta-analysis. **Technological Forecasting And Social Change**, [s.l.], v. 78, n. 7, p. 1174-1182, set. 2011.

MRUGALSKA, B.; WYRWICKA, M. K. Towards Lean Production in Industry 4.0. **Procedia Engineering**, [s.l.], v. 182, p. 466-473, jan. 2017.

MÜLLER, J. M. *et al.*. Fortune favors the prepared: how smes approach business model innovations in industry 4.0. : How SMEs approach business model innovations in Industry 4.0. **Technological Forecasting And Social Change**, [s.l.], v. 132, p. 2-17, jul. 2018.

MURNAWAN, A.; SAMIHARDJO, R.; NUGRAHA, U. Design of the Business Intelligence Dashboard for Sales Decision Making. **International Journal Of Psychosocial Rehabilitation**, [s.l.], v. 24, n. 2, p. 3498-3513, fev. 2020.

ONDRA, P.; TUČEK, D.; RAJNOHA, R. The Empirical Quality Management Practices Study Of Industrial Companies In The Czech Republic. **Polish Journal Of Management Studies**, [s.l.], v. 17, n. 2, p. 180-196, jun. 2018.

ORGANIZATION FOR ECONOMIC COOPERATION AND DEVELOPMENT (OECD). **An Introduction to On-line Platforms and Their Role in the Digital Transformation**. Paris: Ed. OECD, 2019. Disponível em: [https://www.oecd-ilibrary.org/science-and-technology/an-introduction-to-on-line-platforms-and-their-role-in-the-digital-transformation\\_19e6a0f0-en](https://www.oecd-ilibrary.org/science-and-technology/an-introduction-to-on-line-platforms-and-their-role-in-the-digital-transformation_19e6a0f0-en). Acesso em: 27 abr. 2020.

OTERO, C. E.; PETER, A. Research Directions for Engineering Big Data Analytics Software. **Ieee Intelligent Systems**, [s.l.], v. 30, n. 1, p. 13-19, jan. 2015.



PACHECO, D. A J; MARTINS, M. Análise da sistemática de gestão dos indicadores de desempenho na indústria automotiva. **Revista Ingeniería Industrial**, [s.l.], v. 14, n. 3, p. 7-30, jul. 2015.

PAGANI, R. N.; KOVALESKI, J. L.; RESENDE, L. M. Methodi Ordinatio: a proposed methodology to select and rank relevant scientific papers encompassing the impact factor, number of citation, and year of publication. **Scientometrics**, [s.l.], v. 105, n. 3, p. 2109-2135, set. 2015.

PAGANI, R.N.; KOVALESKI, J.L.; RESENDE, L.M. Tics na composição da methodi ordinatio: construção de portfólio bibliográfico sobre modelos de Transferência de Tecnologia. **Ciência da Informação**, v. 46, n. 2, 2017.

PERPELKIN, D. *et al.*. Development of Digital Platform Architecture of Distributed Data Processing. **IEEE**, Budva, v.8, n.1, p.1-5, 2019.

POWELL, T. C. Total quality management as competitive advantage: A review and empirical study. **Strategic Management Journal**, [s.l.], v. 16, n. 1, p. 15-37, jan. 1995.

POWER, D. J. **Handbook on Decision Support Systems**. Berlin: 2008. Cap. 1: Decision Support Systems: A Historical Overview. 1. ed. p.121-140.

QADER, W.; AMEEN, M.; AHMED, B.. Big Data Characteristics, Architecture, Technologies and Applications. **Journal Of Computer Science**, [s.l.], v. 16, n. 6, p. 817-824, jan. 2020.

QASRAWI, B.; ALMAHAMID, S. M.; QASRAWI, S. T. The impact of TQM practices and KM processes on organisational performance. **International Journal Of Quality & Reliability Management**, [s.l.], v. 34, n. 7, p.1034-1055, ago. 2017.

RAMEZANI, J.; JASSBI, J. Quality 4.0 in Action: Smart Hybrid Fault Diagnosis System in Plaster Production. **Processes**, v. 8, n. 6, p. 634. mai. 2020.

REED, R; LEMAK, D. J.; MONTGOMERY, J. C. Beyond Process: TQM Content and Firm Performance. **The Academy Of Management Review**, [s.l.], v. 21, n. 1, p.173-

202, jan. 1996.

RHADIKA, D.; KUMARI, A. The Smart Triad: Big Data Analytics , Cloud Computing and Internet of Things to shape the Smart Home, Smart City, Smart Business & Smart Country. **International Journal Of Recent Technology And Engineering**, [s.l.], v. 8, n. 211, p. 3594-3600, nov. 2019.

RICHARDSON, T. L. (1997). **Total Quality Management**. New York: United States of America: Delmar Publishers.

RIJMENAM, M. V. **Why The 3V's Are Not Sufficient To Describe Big Data**. Disponível em: <https://datafloq.com/read/3vs-sufficient-describe-big-data/166>. Acesso em: 06 abr. 2020.

ROSEWELL, A. *et al.*. Health information system strengthening and malaria elimination in Papua New Guinea. **Malaria Journal**, [s.l.], v. 16, n. 1, p. 1-16, jul. 2017.

SABBAGH, O. *et al.*. The impact of TQM practices on key performance indicators: empirical evidence from automotive dealerships. **E+m Ekonomie A Management**, [s.l.], v. 22, n. 1, p.115-129, jan. 2018.

SADER, S.; HUSTI, I.; DARÓCZI, M. Industry 4.0 as a Key Enabler toward Successful Implementation of Total Quality Management Practices. **Periodica Polytechnica Social And Management Sciences**, [s.l.], v. 27, n. 2, p. 131-140, ago. 2019.

SADIKOGLU, E.; ZEHIR, C. Investigating the effects of innovation and employee performance on the relationship between total quality management practices and firm performance: An empirical study of Turkish firms. **International Journal Of Production Economics**, [s.l.], v. 127, n. 1, p.13-26, set. 2010.

SAGGI, M. K.; JAIN, S. A survey towards an integration of big data analytics to big insights for value-creation. **Information Processing & Management**, [s.l.], v. 54, n. 5, p. 758-790, set. 2018.

SALAHALDEEN; A.. Developing countries and technology transfer, **International Journal of Technology Management**. v. 10, n. 7-8, p. 704-713, 1995.

SANTOS, C. *et al.*. Towards Industry 4.0: an overview of european strategic roadmaps. **Procedia Manufacturing**, [s.l.], v. 13, p. 972-979, 2017.

SARI, R. P. Integration of Key Performance Indicator into the Corporate Strategic Planning: Case Study at PT. **Agriculture and Agricultural Science Procedia, Indonesia**, v. 3, n. 1, p. 121-126, jan. 2015.

SARIKAYA, A. *et al.*. What Do We Talk About When We Talk About Dashboards?. **Ieee Transactions On Visualization And Computer Graphics**, [s.l.], v. 25, n. 1, p. 682-692, jan. 2019.

SCARCELLA, L. E-commerce and effective VAT/GST enforcement: can on-line platforms play a valuable role?: Can on-line platforms play a valuable role?. **Computer Law & Security Review**, [s.l.], v. 36, p. 1-15, abr. 2020.

SCHILD, H. Big data and organizational design – the brave new world of algorithmic management and computer augmented transparency. **Innovation**, [s.l.], v. 19, n. 1, p. 23-30, nov. 2016.

SCHWAB, K. **The fourth industrial revolution**. 2. ed. New York: Crown Business, 2017.

SCHWARZ, C.; SCHWARZ, A.; BLACK, W. C. Examining the Impact of Multicollinearity in Discovering Higher-Order Factor Models. **Communications Of The Association For Information Systems**, [s.l.], v. 34, p. 1-24, jan. 2014.

SEDDON, J. J. M.; CURRIE, W. L. A model for unpacking big data analytics in high-frequency trading. **Journal Of Business Research**, [s.l.], v. 70, p. 300-307, jan. 2017.

SHIMBUN, N. K. **Poka-Yoke**: Improving Product Quality by Preventing Defects. 1

Ed. Cambridge: Productivity Press, 1988.

SHIRZAD, E.; SAADATFAR, H.. Job failure prediction in Hadoop based on log file analysis. **International Journal Of Computers And Applications**, [s.l.], p. 1-10, mar. 2020.

SHROFF, N. TQM Indicators Implemented by Teachers of the Primary School. **Asset Analytics**, [s.l.], v. 1, n. 1, p. 243-254, ago. 2018.

SHYAM, R. *et al.*. Apache Spark a Big Data Analytics Platform for Smart Grid. **Procedia Technology**, [s.l.], v. 21, p. 171-178, jan. 2015.

SILVA, E. L.; MENEZES, E. M. **Methodology of the research and elaboration of dissertation**. Florianópolis: UFSC, 2005.

SILVA, V. L.; KOVALESKI, J. L.; PAGANI, R. N. Technology Transfer and Human Capital in the Industrial 4.0 Scenario: A Theoretical Study. **Future Studies Research Journal: Trends and Strategies**, [s.l.], v. 11, n. 1, p. 102-122, jan. 2019.

SILVA, V. L.; KOVALESKI, J. L.; PAGANI, R. N. Technology transfer in the supply chain oriented to industry 4.0: a literature review: a literature review. **Technology Analysis & Strategic Management**, [s.l.], v. 31, n. 5, p. 546-562, set. 2018.

SINGH, D.; REDDY, C. K. A survey on platforms for big data analytics. **Journal Of Big Data**, [s.l.], v. 2, n. 1, p. 1-20, out. 2014.

SIVARAJAH, U.; KAMAL, M. M.; IRANI, Z.; WEERAKKODY, V. Critical analysis of big data challenges and analytical methods. **Journal of Business Research**, [s.l.], v. 70, n. 1, p. 263–286, jan. 2017.

SLUSARCZYK, B. 2018. Industry 4.0 Are we ready?. **Journal of Management Studies**, [s.l.], v. 17, p. 232–248.

SMITH, J. **The KPI Book**: The Ultimate Guide to Understanding the Key Performance Indicators of Your Business. 1. ed. Inglaterra: Insight Training &

Development Limited, 2014.

SONY, M. *et al.*. Essential ingredients for the implementation of Quality 4.0. **The TQM Journal**, v. 32, n. 4, p. 779-793. jan. 2020.

SOUSA, R.; A VOSS, C. Quality management re-visited: a reflective review and agenda for future research. **Journal Of Operations Management**, [s.l.], v. 20, n. 1, p. 91-109, jan. 2002.

SOUZA, J. T. *et al.*. Data Mining and Machine Learning to Promote Smart Cities: A Systematic Review from 2000 to 2018. **Sustainability**, v. 11, n. 4, p. 1077, 2019.

SQOOP. **Apache Sqoop**. Disponível em: <https://sqoop.apache.org/>. Acesso em: 19 nov. 2020.

STADLER, J. G. *et al.*. Improving the Efficiency and Ease of Healthcare Analysis Through Use of Data Visualization Dashboards. **Big Data**, [s.l.], v. 4, n. 2, p. 129-135, jun. 2016.

SUH, T.; KWON, I. G. Matter over mind: When specific asset investment affects calculative trust in supply chain partnership. **Industrial Marketing Management**, [s.l.], v. 35, n. 2, p. 191-201, fev. 2006.

SUMAN, S.; KHAJURIA, P.; UROLAGIN, S.. Star Schema-Based Data Warehouse Model for Education System Using Mondrian and Pentaho. **Electrical Engineering**, [s.l.], p. 30-39, 2020.

TABLEAU. **Products**. Disponível em: <https://www.tableau.com/pt-br/products/desktop>. Acesso em: 18 mar. 2020.

TEJANINGRUM, A. Implementation the Trilogy Juran in SMEs Business Case Study in Indonesia. **Materials Science and Engineering**, [s.l.], v. 506, p. 1-9, abr. 2019.

TOMAC, N. RADONJA, R.; BONATO, J.. Analysis of Henry Ford's contribution to

production and management. **Pomorstvo**, [s.l.], v. 33, n. 1, p. 33-45, jun. 2019.

TORTORELLA, G. L.; FETTERMANN, D. Implementation of Industry 4.0 and lean production in Brazilian manufacturing companies. **International Journal Of Production Research**, [s.l.], v. 56, n. 8, p. 2975-2987, out. 2017.

TRIPATHI, N. *et al.*. Startup ecosystem effect on minimum viable product development in software startups. **Information And Software Technology**, [s.l.], v. 114, n. 1, p. 77-91, out. 2019.

TSAI, C. *et al.*. Big data analytics: a survey. **Journal Of Big Data**, [s.l.], v. 2, n. 1, p.1-15, out. 2015.

VAHN, G. Business Analytics In The Age Of Big Data. **Business Strategy Review**, [s.l.], v. 25, n. 3, p. 8-9, set. 2014.

VAIDYA, S.; AMBAD, P.; BHOSLE, S. Industry 4.0 – A Glimpse. **Procedia Manufacturing**, [s.l.], v. 20, n. 1, p. 233-238, 2018.

VAN HORNE, S. *et al.*. Facilitating Student Success in Introductory Chemistry with Feedback in an On-line Platform. **Technology, Knowledge And Learning**, [s.l.], v. 23, n. 1, p. 21-40, nov. 2017.

VELIMIROVIĆ, D.; VELIMIROVIĆ, M.; STANKOVIĆ, R. Role and importance of key performance indicators measurement. **Serbian Journal Of Management**, [s.l.], v. 6, n. 1, p.63-72, mai. 2011.

VERMA, A.; SETHI, N.; JAI, N.. Beyond Hadoop for e-commerce Big Data Analysis through Amazon. **2018 International Conference On Advanced Computation And Telecommunication (Icacat)**, [s.l.], p. 1-12, dez. 2018. IEEE.  
<http://dx.doi.org/10.1109/icacat.2018.8933660>.

VERMA, N.; SINGH, J. A comprehensive review from sequential association computing to Hadoop-MapReduce parallel computing in a retail scenario. **Journal Of**

**Management Analytics**, [s.l.], v. 4, n. 4, p. 359-392, out. 2017.

VIJAYKUMAR, S. *et al.*. Unique sense: Smart computing prototype for industry 4.0 revolution with IOT and big data implementation model. **Indian Journal of Science and Technology**, v. 8, n. 35, p. 1-4. jan, 2015.

VOGEL-HEUSER, B.; HESS, D. Guest Editorial Industry 4.0 – Prerequisites and Visions. **Ieee Transactions On Automation Science And Engineering**, [s.l.], v. 13, n. 2, p. 411-413, abr. 2016.

VUKŠIĆ V. B.; BACH M. P.; POPOVIĆ A. Supporting performance management with business process management and business intelligence: A case analysis of integration and orchestration, **International Journal of Information Management**, v. 4, n. 33, p. 613-619, abr. 2013.

WAMBA, *et al.*. The performance effects of big data analytics and supply chain ambidexterity: The moderating effect of environmental dynamism. **International Journal Of Production Economics**, [s.l.], v. 222, n. 1, p. 1-14, abr. 2020.

WANG, H.; BELHASSENA, A.. Parallel trajectory search based on distributed index. **Information Sciences**, [s.l.], v. 388-389, p. 62-83, maio 2017.

WASIM, A. *et al.*. Big Data Analytics - Current Status, Challenges and Connection of unbounded data Processing platforms. **International Journal Of Innovative Technology And Exploring Engineering**, [s.l.], v. 8, n. 92, p. 698-700, ago. 2019.

WATSON, H. J. Tutorial: business intelligence past, present, and future: Business Intelligence – Past, Present, and Future. **Communications Of The Association For Information Systems**, [s.l.], v. 25, p. 1-12, jan. 2009.

WEXLER, S.; SHAFFER, J.; COTGREAVE, A. **The Big Book of Dashboards: Visualizing Your Data Using Real-World Business Scenarios**. 1. ed. Nova Jersey: John Wiley & Sons, 2017.

WOMACK, J. P.; JONES, D. T. **Lean Thinking: Banish Waste and Create Wealth in**

your Corporation. 1. ed. Londres: Simon & Schuster, 1996.

WORLD BANK. **Indicator**. Washington: The World Bank, 2020. Disponível em: <https://data.worldbank.org/indicator/IP.JRN.ARTC.SC>. Acesso em: 18 mar. 2020.

WORLD ECONOMIC FORUM. **The 10 Skills You Need to Thrive in the Fourth Industrial Revolution**. Ed. Geneva: World Economic Forum, 2018. Disponível em: <https://www.weforum.org/agenda/2016/01/the-10-skills-you-need-to-thrive-in-the-fourth-industrial-revolution/>. Acesso em: 09 abr. 2020.

XIE, M.; MUKHERJEE, A. Advances in the theory and application of Statistical Process Control: Celebrate the Quasiquicentennial (125th) Birth Anniversary of the Father of Statistical Quality Control Dr. Walter Andrew Shewhart. *Quality Technology & Quantitative Management*, [s.l.], v. 14, n. 4, p. 341-342, set. 2017.

XIE, X. *et al.*. Geographical Correlation-Based Data Collection for Sensor-Augmented RFID Systems. **Ieee Transactions On Mobile Computing**, [s.l.], v. 19, n. 10, p. 2344-2357, out. 2020.

XU, L.; DUAN, L. Big data for cyber physical systems in industry 4.0: a survey. **Enterprise Information Systems**, [s.l.], v. 13, n. 2, p.148-169, mar. 2018.

XYLOGIANNOPOULOS, K. F. *et al.*. A password creation and validation system for social media platforms based on big data analytics. **Journal Ambient Intelligence Human Computer**, v. 11, p. 53–73, jan. 2020.

YADAV, N.; SHANKAR, R.; SINGH, S. Impact of Industry4.0/ICTs, Lean Six Sigma and quality management systems on organisational performance. **The TQM Journal**, v. 32, n. 4, p. 815-835, jan. 2020.

YIN, Robert K. **Estudo de caso – planejamento e métodos**. (2Ed.). Porto Alegre: Bookman.2001.

YU, S. *et al.*. Networking for Big Data: A Survey. **Ieee Communications Surveys &**



**Tutorials**, [s.l.], v. 19, n. 1, p. 531-549, 2017.

YÜLEK, M. A. The Industrialization Process: A Streamlined Version. How Nations Succeed: Manufacturing, Trade, Industrial Policy, and Economic Development, [s.l.], v.1, n.1, p.171-182, ago. 2018.

ZABADI, A. M. A. Implementing Total Quality Management (TQM) on the Higher Education Institutions – A Conceptual Model. **Journal Of Finance & Economics**, [s.l.], v. 1, n. 1, p. 42-60, mar. 2013.

ZASLAVSKY, A.; PERERA, C.; GEORGAKOPOULOS, D. Sensing as a service and big data. In: International Conference on Advances in Cloud Computing; 2012, Bangalore. Anais [...]. Bangalore: Computer and Society, 2012. p. 21-29.

ZHANG, X., *et al.*. An evolutionary trend reversion model for stock trading rule discovery. **Knowledge-based Systems**, [s.l.], v. 79, p. 27-35, mai. 2015.

ZHAO, Z; TIAN, Y.; ZILLANTE, G. Modeling and evaluation of the wind power industry chain: a china study: A China study. **Renewable And Sustainable Energy Reviews**, [s.l.], v. 31, p. 397-406, mar. 2014.

ZHOU, K.; LIU, T.; ZHOU, L. Industry 4.0: Towards future industrial opportunities and challenges. 2015 12th International Conference On Fuzzy Systems And Knowledge Discovery (fskd), [s.l.], v. 1, n. 1, p. 2147-2152, ago. 2015.

ZONNENSHAIN, A.; KENETT, R. S. Quality 4.0 — the challenging future of quality engineering. **Quality Engineering**, [s.l.], p. 1-13, fev. 2020.

ZWAIN, A. A. A.; LIM, K. T.; OTHMAN, S. N. TQM and academic performance in Iraqi HEIs: associations and mediating effect of KM. **The Tqm Journal**, [s.l.], v. 29, n. 2, p. 357-368, mar. 2017.

## APÊNDICE A - PORTFÓLIO DE ARTIGOS ORDENADOS

**Tabela 7 – Portfólio de artigos ordenados resultantes do eixo 1**

<b>EIXO 1 – ORDENADO</b>				
<b>Artigo</b>	<b>FI</b>	<b>Ano</b>	<b>CI</b>	<b>InOrdinatio</b>
Toward scalable systems for big data analytics: A technology tutorial	3,557	2014	889	929
Trends in big data analytics	1,815	2014	683	723
The Stratosphere platform for big data analytics	2,689	2014	454	494
Big data analytics: a survey	8,510	2015	379	429
A survey on platforms for big data analytics	8,510	2015	336	386
Tutorial: Big data analytics: Concepts, technologies, and applications	1,670	2014	259	299
A Survey on Big Data Analytics: Challenges, Open Research Issues and Tools	0,000	2016	100	160
Social media and the social sciences: How researchers employ Big Data analytics	0,000	2016	93	153
Ensemble prediction algorithm of anomaly monitoring based on big data analysis platform of open-pit mine slope	1,829	2018	64	144
Spatial cumulative sum algorithm with big data analytics for climate change detection	1,747	2018	59	139
A knowledge-based platform for big data analytics based on publish/subscribe services and stream processing	4,396	2015	88	138
Big Data Analytics: A Review on Theoretical Contributions and Tools Used in Literature	2,580	2017	65	135
Apache Spark a Big Data Analytics Platform for Smart Grid	0,000	2015	78	128
Social media big data analytics: A survey	3,536	2019	29	119
Big data analytics: transforming data to action	1,308	2017	49	119
Power systems big data analytics: An assessment of paradigm shift barriers and prospects	4,130	2018	35	115
The state of the art and taxonomy of big data analytics: view from new big data framework	3,814	2020	10	110
Traffic-aware geo-distributed Big data analytics with predictable job completion time	3,971	2017	37	107
A proposed social network analysis platform for big data analytics	3,129	2018	27	107
Big data analytics in health sector: Theoretical framework, techniques and prospects	4,516	2020	6	106
A Big Data Analytics Architecture for the Internet of Small Things	9,270	2018	25	105
A model-driven approach to automate data visualization in big data analytics	0,923	2020	3	103
A big data analytics model for customer churn prediction in the retiree segment	4,516	2019	12	102
Uncertainty in big data analytics: survey, opportunities, and challenges	8,510	2019	11	101
A Big Data platform for smart meter data analytics	2,850	2019	11	101
Financial big data analysis and early warning platform: A case study	3,557	2020	0	100
Triangulum city dashboard: An interactive data analytic platform for visualizing smart city performance	2,973	2020	0	100

<b>EIXO 1 – ORDENADO (CONTINUAÇÃO)</b>				
<b>Artigo</b>	<b>FI</b>	<b>Ano</b>	<b>CI</b>	<b>InOrdinatio</b>
A password creation and validation system for social media platforms based on big data analytics	1,423	2020	0	100
Urban data management system: Towards Big Data analytics for Internet of Things based smart urban environment using customized Hadoop	4,760	2019	8	98
Smart city big data analytics: An advanced review	3,880	2019	8	98
Developing a big data analytics platform for manufacturing systems: architecture, method, and implementation	2,601	2018	17	97
Towards Disaster Resilient Smart Cities: Can Internet of Things and Big Data Analytics Be the Game Changers?	3,557	2019	6	96
UNRAVEL: big data analytics research data platform to improve care of patients with cardiomyopathies using routine electronic health records and standardised biobanking	1,476	2019	4	94
A cloud-based energy data mining information agent system based on big data analysis technology	1,236	2019	3	93
Traditional music protection system from the ecological perspective based on big data analysis	0,101	2019	3	93
A survey on vertical and horizontal scaling platforms for big data analytics	0,000	2019	3	93
A Distributed Computing Platform for fMRI Big Data Analytics	0,000	2019	3	93
A framework for big data analytics in commercial social networks: A case study on sentiment analysis and fake review detection for marketing decision-making	0,000	2019	3	93
Random forest implementation and optimization for Big Data analytics on LexisNexis's high performance computing cluster platform	8,510	2019	2	92
BIGSEA: A Big Data analytics platform for public transportation information	4,760	2019	2	92
Cloud-based big data analytics platform using algorithm templates for the manufacturing industry	1,995	2019	1	91
Big data analytics platforms for electric vehicle integration in transport oriented smart cities: Computing platforms for platforms for electric vehicle integration in smart cities	0,530	2019	1	91
Smart dashboards for smart city - A platform to engage with citizen	0,450	2019	1	91
Understanding big data analytics (BDA) and business intelligence (BI) towards establishing organizational performance diagnostics framework	0,000	2019	1	91
Toward High-Performance Computing and Big Data Analytics Convergence: The Case of Spark-DIY	3,557	2019	0	90
An Integrated Big and Fast Data Analytics Platform for Smart Urban Transportation Management	3,557	2019	0	90
A Big Data-based Prediction Model for Purchase Decisions of Consumers on Cross-border E-commerce Platforms	0,050	2019	0	90
Streaming big data analytics-current status, challenges and connection of unbounded data processing platforms	0,000	2019	0	90

A critique on heart diseases predictive analytics using big data algorithms	0,000	2019	0	90
Developing a Big Data Analytic Model and a Platform for Particulate Matter Prediction: A Case Study	0,000	2019	0	90
The smart triad: Big data analytics, cloud computing and internet of things to shape the smart home, smart city, smart business & smart country	0,000	2019	0	90
DataCare: Big Data Analytics Solution for Intelligent Healthcare Management	0,000	2018	9	89
A big data analytics platform for smart factories in small and medium-sized manufacturing enterprises: An empirical case study of a die casting factory	1,661	2017	15	85
A comprehensive review from sequential association computing to Hadoop-MapReduce parallel computing in a retail scenario	0,000	2017	14	84
What determines user-generated content creation of college football? A big-data analysis of structural influences	0,000	2018	4	84
Big data, modeling, simulation, computational platform and holistic approaches for the fourth industrial revolution	0,080	2018	3	83
Applying intelligent data traffic adaptation to high-performance multiple big data analytics platforms	1,747	2018	2	82
VPL-based big data analysis system: UDAS	3,557	2018	0	80
Using big data to improve the performance management: a case study from the UAE FM industry	1,500	2017	10	80
Development and Application of Personal Hadoop-Based Big Data Platform	0,100	2018	0	80

**Fonte: Elaborado pela autora (2020)**

**Tabela 8 – Portfólio de artigos ordenados resultantes do eixo 2**

<b>EIXO 2 - ORDENADO</b>				
<b>Artigo</b>	<b>FI</b>	<b>Ano</b>	<b>CI</b>	<b>InOrdinatio</b>
Quality culture of manufacturing enterprises: A possible way to adaptation to industry 4.0	0,109	2019	22	112
Corporate survival in Industry 4.0 era: the enabling role of lean-digitized manufacturing	2,194	2020	9	109
Are QM models aligned with Industry 4.0? A perspective on current practices	5,651	2020	0	100
An analysis of total quality management (TQM) within the thai auto parts sector	0,000	2020	0	100
Quality 4.0—the challenging future of quality engineering	0,000	2020	0	100
TQM, games design and the implications of integration in Industry 4.0 systems	1,100	2019	6	96
Contributions of Industry 4.0 to quality management - A SCOR perspective	0,680	2019	0	90
Quality management evolution from the past to present: challenges for tomorrow	0,430	2019	0	90
Industry 4.0 and business process management	0,000	2019	0	90
Industry 4.0 as a key enabler toward successful implementation of total quality management practices	0,000	2019	0	90

**Fonte: Elaborado pela autora (2020)**