

**UNIVERSIDADE FEDERAL DE SÃO CARLOS  
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO**

**JUNIOR APARECIDO ASSANDRE**

**DESENVOLVIMENTO DE UM PROTÓTIPO PARA USO DE  
DADOS NÃO ESTRUTURADOS EM SISTEMA DE MEDIÇÃO DE  
DESEMPENHO**

**SÃO CARLOS-SP  
2022**

JUNIOR APARECIDO ASSANDRE

DESENVOLVIMENTO DE UM PROTÓTIPO PARA USO DE DADOS NÃO  
ESTRUTURADOS EM SISTEMA DE MEDIÇÃO DE DESEMPENHO

Tese de doutorado apresentada ao Programa de Pós-Graduação em Engenharia de Produção do Centro de Ciências Exatas e de Tecnologia da Universidade Federal de São Carlos, como parte dos requisitos para obtenção do título de Doutor em Engenharia de Produção.

Área de Concentração: Gestão de Qualidade  
Orientador: Prof. Dr. Pedro Carlos Oprime  
Co-orientador: Prof. Dr. Roberto Antonio Martins

SÃO CARLOS-SP  
2022



**UNIVERSIDADE FEDERAL DE SÃO CARLOS**

Centro de Ciências Exatas e de Tecnologia  
Programa de Pós-Graduação em Engenharia de Produção

---

**Folha de Aprovação**

---

Defesa de Tese de Doutorado do candidato Júnior Aparecido Assandre, realizada em 29/06/2022.

**Comissão Julgadora:**

  
Prof. Dr. Pedro Carlos Oprime (UFSCar)

Prof. Dr. Roberto Antonio Martins (UFSCar)


Prof. Dr. Roberto Fernandes Tavares Neto (UFSCar)

Profa. Dra. Fabiane Letícia Lizarelli (UFSCar)


Prof. Dr. Fernando José Barbin Laurindo (USP) 

Prof. Dr. Luiz César Ribeiro Carpinetti (USP)

Documento assinado digitalmente

 ROBERTO ANTONIO MARTINS  
Data: 01/07/2022 18:02:13-0300  
Verifique em <https://verificador.itl.br>

Documento assinado digitalmente

 ROBERTO FERNANDES TAVARES NETO  
Data: 26/08/2022 08:43:18-0300  
Verifique em <https://verificador.itl.br>

O Relatório de Defesa assinado pelos membros da Comissão Julgadora encontra-se arquivado junto ao Programa de Pós-Graduação em Engenharia de Produção.

Dedico ao meu filho, minha esposa e meus pais.

## AGRADECIMENTO

À Deus.

Ao meu filho por abrir mão de minha dedicação sem queixar-se.

À minha esposa pela paciência e ajuda.

Ao professor Roberto Antonio Martins pela orientação e conselhos em momentos decisivos.

Ao professor Pedro Carlos Oprime pela compreensão e ajuda.

Aos meus pais pelo apoio e compreensão.

Aos membros da banca pela disponibilidade e contribuições ao trabalho.

Aos companheiros da Coordenadoria de Contratos da UFSCar pela ajuda durante estes anos.

Aos membros da secretaria do Programa de Pós-graduação em Engenharia de Produção pelo apoio e ajuda.

Ao Departamento de Engenharia de Produção da Universidade Federal de São Carlos pela oportunidade.

A todos aqueles que de forma direta ou indireta me ajudaram nesta longa jornada.

Nossa vida é um caminho, quando paramos, não vamos para frente.

Papa Francisco

## RESUMO

Tendo em vista as potencialidades que o *big data* pode trazer às organizações com o uso da grande quantidade de dados não estruturados gerados rapidamente em diferentes formatos e origens, e a escassez de pesquisas empíricas para validar seus impactos e oportunidades para os sistemas de medição de desempenho (SMD). Esta tese teve como principal objetivo, desenvolver um protótipo de SMD com uso de técnicas de *deep learning* e *big data analytics* (BDA) para coleta, armazenagem e análise de dados não estruturados. Entre os diferentes formatos de dados não estruturados, foram utilizadas as imagens de vídeos, frente a sua grande disponibilidade. Como forma de apresentar o processo cognitivo do projeto e construção do protótipo de SMD em estado funcional e assim criar conhecimento generalizável para esta classe de problema, foi usado o método de pesquisa *design science research* (DSR). Durante o processo de desenvolvimento do protótipo foi possível identificar convergências entre as fases de desenvolvimento dos SMD e as fases a serem seguidas para colocar em operação um projeto de *big data*. A análise destas convergências em conjunto com o aprendizado adquirido no processo de desenvolvimento do protótipo, evidenciaram os pontos mais relevantes neste tipo de projeto. Os resultados da pesquisa indicaram a importância de uma infraestrutura de suporte para o uso de dados não estruturados pelo SMD e a dependência ainda maior da área da tecnologia da informação e ciência da computação. Os resultados também evidenciaram que ao proporcionar a criação de medidas de desempenho e análises avançadas de dados não estruturados, anteriormente inviáveis, as técnicas de BDA, *deep learning* e visão computacional, influenciam positivamente a validade, confiabilidade e pontualidade deste recurso, bem como seu nível de agregação e custos. Assim, a principal contribuição da tese foi gerar conhecimento relevante, prático e prescritivo para uso de dados não estruturados de vídeos em SMDs, de forma a contribuir com seu aperfeiçoamento e adaptação.

**Palavras-chaves:** *Big Data; Big Data Analytics; Sistema de Medição de Desempenho; Deep Learning; Dados Não Estruturados*

## ABSTRACT

Given the potential that big data can bring to organizations with the use of the large amount of unstructured data generated quickly in different formats and sources, and the scarcity of empirical research to validate its impacts and opportunities for performance measurement systems (SMD). The main objective of this thesis was to develop an SMD prototype using deep learning and big data analytics (BDA) techniques for collecting, storing and analyzing unstructured data. Among the different formats of unstructured data, video images were used, due to their great availability. As a way to present the cognitive process of the design and construction of the SMD prototype in a functional state and thus create generalizable knowledge for this class of problem, the design science research (DSR) research method was used. During the prototype development process, it was possible to identify convergences between the MDS development phases and the phases to be followed to put a big data project into operation. The analysis of these convergences together with the learning acquired in the prototype development process, highlighted the most relevant points in this type of project. The research results indicated the importance of a support infrastructure for the use of unstructured data by the SMD and the even greater dependence on the area of information technology and computer science. The results also showed that, by providing the creation of performance measures and advanced analysis of unstructured data, previously unfeasible, BDA, deep learning and computer vision techniques positively influence the validity, reliability and timeliness of this resource, as well as its level. aggregation and costs. Thus, the main contribution of the thesis was to generate relevant, practical and prescriptive knowledge for the use of unstructured data from videos in SMDs, in order to contribute to their improvement and adaptation.

**Keywords:** Big Data; Big Data Analytics; Performance Measurement System; Deep Learning; Unstructured Data



## LISTA DE FIGURAS

<i>Figura 1 - Os três níveis dos sistemas de medição de desempenho</i>	26
<i>Figura 2 - Modelo de transformação geral</i>	31
<i>Figura 3 - Controle básico de medição do processo</i>	31
<i>Figura 4 – Integral Framework for Performance Measurement</i>	32
<i>Figura 5 – Processo iterativo de desenvolvimento de um SMD</i>	35
<i>Figura 6 – 5Vs do big data</i>	44
<i>Figura 7 – Classificação dos desafios do big data</i>	47
<i>Figura 8 – Projeto de big data</i>	48
<i>Figura 9 – Análise de grandes quantidades de dados</i>	50
<i>Figura 10 – Métodos de análise preditiva</i>	52
<i>Figura 11 – Processo de análise prescritiva</i>	55
<i>Figura 12 – Relacionamento entre Deep Learning na IA</i>	59
<i>Figura 13 – Design Science Research</i>	66
<i>Figura 14 – Etapas previstas e realizadas da DSR neste trabalho</i>	70
<i>Figura 15 – Seleção de artefatos para análise</i>	75
<i>Figura 16 – Classes de problemas</i>	76
<i>Figura 17 – Propósito do protótipo</i>	90
<i>Figura 18 - Levantamento de requisitos do SMD</i>	91
<i>Figura 19 - Caso de uso dashboard</i>	94
<i>Figura 20 - Caso de uso da análise preditiva</i>	95
<i>Figura 21 - Caso de uso do treinamento de modelos</i>	96
<i>Figura 22 - Caso de uso do treinamento de modelos</i>	97
<i>Figura 23 - Caso de uso análise BDA</i>	98
<i>Figura 24 - Diagrama de casos de uso do protótipo de SMD</i>	99
<i>Figura 25 - Diagrama de sequência</i>	105
<i>Figura 26 - Diagrama de comunicação</i>	107
<i>Figura 27 - Diagrama de máquina de estado</i>	108
<i>Figura 28 - Integração de componentes do projeto</i>	115
<i>Figura 29 – Acompanhamento em tempo real</i>	119
<i>Figura 30 – Acompanhamento em tempo real</i>	119
<i>Figura 31 – Dashboard com medidas de desempenho</i>	121
<i>Figura 32 – Componentes de saída</i>	122

<i>Figura 33 – Medidas de desempenho e BDA</i>	<i>123</i>
<i>Figura 34 - Componentes do protótipo e elementos do SMD</i>	<i>124</i>
<i>Figura 35 – Representação de registros armazenados no big data</i>	<i>130</i>
<i>Figura 36 – Representação gráfica da análise preditiva</i>	<i>132</i>
<i>Figura 37 – Acompanhamento das operações em tempo real</i>	<i>134</i>
<i>Figura 38 – Principais operações do processo</i>	<i>135</i>
<i>Figura 39 – Convergência entre desenvolvimento de SMD e projeto de big data</i>	<i>143</i>

## LISTA DE QUADROS

<i>Quadro 1 - Elementos dos SMDs</i>	27
<i>Quadro 2 - Classificação de artefatos</i>	67
<i>Quadro 3 - Protocolo de coleta de dados para análise bibliométrica</i>	72
<i>Quadro 4 - Artefatos analisados</i>	73
<i>Quadro 5 - Aspectos identificados nos artefatos analisados</i>	79
<i>Quadro 6 - Recursos, processos e propósitos, dos artefatos analisados</i>	79
<i>Quadro 7 - Requisitos do artefato para uma solução satisfatória</i>	84
<i>Quadro 8 - Especificações do caso de uso</i>	100
<i>Quadro 9 - Avaliações planejadas para o protótipo</i>	111
<i>Quadro 20 - Avaliação para cada medida de desempenho</i>	113

## LISTA DE TABELAS

<i>Tabela 1- Principais modelos e estruturas de SMD desenvolvidos até 2007</i>	29
<i>Tabela 2 - Abordagens de desenvolvido de SMD</i>	33
<i>Tabela 3 - Relação entre referências teóricas e fases da pesquisa</i>	69
<i>Tabela 4 - Componentes do dashboard</i>	102
<i>Tabela 5 - Recursos computacionais de software</i>	116
<i>Tabela 6 - Resultado final das 3 simulações analisadas</i>	126
<i>Tabela 7 - Capacidade na interpretação das ações</i>	128
<i>Tabela 8 - Resultado da análise preditiva para previsão de encerramento</i>	131
<i>Tabela 9 - Resultados acompanhamento das operações em tempo real</i>	133

## SIGLAS

BDA	<i>Big Data and Analytics</i>
BSC	<i>Balanced Scorecards</i>
BI	<i>Business Intelligence</i>
CAD	<i>Computer-Aided Design</i>
DS	<i>Design Science</i>
DL	<i>Deep Learning</i>
DW	<i>Data Warehouse</i>
DSR	<i>Design Science Research</i>
EFQM	<i>European Foundation for Quality Management</i>
ERP	<i>Enterprise Resource Planning</i>
GPU	<i>Graphics Processing Unit</i>
HDFS	<i>Hadoop Distributed File System</i>
HTML	<i>HyperText Markup Language</i>
IA	Inteligência Artificial
ID	Indicadores de Desempenho
IE	<i>Information Extraction</i>
IoT	<i>Internet of Things</i>
ISO	<i>International Organization for Standardization</i>
KPI	<i>Key Performance Indicator</i>
NI	<i>Não Identificado</i>
OEE	<i>Overall Equipment Effectiveness</i>
OLAP	<i>On-line Analytical Processing</i>
PB	Projeto básico
PIL	<i>Python Imaging Library</i>
RA	Realidade Aumentada
RFID	<i>Radio Frequency Identification</i>
SAAS	<i>Software as a service</i>
SMD	Sistema de Medição de Desempenho
SQL	<i>Structured Query Language</i>
TI	Tecnologia da Informação
TPU	<i>Tensor Processing Units</i>
TS	<i>Text summarization</i>

UML	<i>Unified Modeling Language</i>
VA	<i>Video Analytics</i>
VCA	<i>Video Content Analysis</i>

## SUMÁRIO

<b>1 INTRODUÇÃO</b>	<b>16</b>
1.1 Contexto e questão de pesquisa	16
1.2 Objetivo	19
1.3 Objetivos específicos	19
1.4 Justificativa e contribuições	19
1.5 Estrutura do Trabalho	21
<b>2 REVISÃO DA LITERATURA</b>	<b>23</b>
2.1 Sistemas de medição de desempenho	23
2.1.1 Definições	24
2.1.2 Elementos do SMD	25
2.1.3 Modelos de referência para sistemas de medição de desempenho	29
2.1.3.1 <i>Integral Framework for Performance Measurement</i>	30
2.1.4 Processos de desenvolvimento de um SMD	33
2.1.5 <i>Design</i> dos sistemas de medição de desempenho	35
2.1.6 Implantação do SMD	39
2.1.7 Uso e revisão do SMD	40
2.1.8 Infraestrutura de tecnologia da informação para SMDs	41
2.2 <i>Big data</i>	43
2.2.1 Desafios de uso do <i>big data</i>	46
2.2.2 <i>Big data analytics</i>	48
2.2.3 Formas de análise de grandes volumes de dados	49
2.2.3.1 Análise descritiva	50
2.2.3.2 Análise preditiva	52
2.2.3.3 Análise prescritiva	54
2.2.4 Técnicas de BDA	55
2.2.4.1 <i>Video analytics</i>	56
2.2.5 Uso <i>deep learning</i> em BDA	58
2.2.5.1 <i>Machine learning</i>	58
2.2.5.2 <i>Deep learning</i> e BDA	59
2.2.6 <i>Video analytics</i> para SMDs com uso de <i>deep learning</i>	61
<b>3 DELINEAMENTO DA PESQUISA</b>	<b>63</b>
3.1 Concepção metodológica	63
3.2 Método de pesquisa	64
3.3 Construção de artefatos por meio da <i>Design Science Research</i>	66
3.4 Fase da pesquisa	68
<b>4 DESENVOLVIMENTO DO PROTÓTIPO</b>	<b>71</b>
4.1 Identificação do problema	71
4.2 Conscientização	71
4.2.1 Revisão sistemática da literatura	72

4.3	Identificação dos artefatos e configuração de classes de problemas	75
4.3.1	Análise dos artefatos selecionados	76
4.3.2	Síntese dos artefatos estudados	82
4.4	Proposição do protótipo de SMD com uso de <i>deep learning</i> e visão computacional	83
4.5	Projeto do artefato	89
4.5.1	Levantamento de requisitos	91
4.5.2	Visão geral - Caso de uso	92
4.5.2.1	Diagrama de caso de uso do <i>dashboard</i>	93
4.5.2.2	Diagrama de caso da análise preditiva de encerramento	95
4.5.2.3	Diagrama de caso de uso do treinamento de modelos para classificação	95
4.5.2.4	Diagrama de caso de uso do treinamento de modelos para previsão	97
4.5.2.5	Diagrama de caso de uso para BDA	98
4.5.2.6	Diagrama de caso de uso geral do SMD	99
4.5.2.7	Especificações dos casos de uso	100
4.5.3	Ordem de execução e integração entre as partes do sistema	103
4.5.4	Diagrama de comunicação	106
4.5.5	Comportamento interno das aplicações	107
4.5.6	Procedimentos de avaliação	109
4.6	Desenvolvimento do Artefato	115
4.6.1	Recursos computacionais usados no desenvolvimento do artefato	116
4.6.2	Etapas do desenvolvimento do artefato	118
4.7	Avaliação do Artefato	124
4.7.1	Avaliação da disponibilidade dos resultados	126
4.7.2	Avaliação dos processos de coleta e manipulação de dados	127
4.7.3	Avaliação dos processos de manipulação e armazenagem de dados	128
4.7.4	Avaliação de análise preditiva do processo de fabricação	131
4.7.5	Avaliação do acompanhamento das operações em tempo real	132
4.8	Apresentação do aprendizado no desenvolvimento	135
4.8.1	Infraestrutura para coleta, análise e armazenagem de dados	136
4.8.2	Medidas de desempenho com dados não estruturados a partir de imagens	138
4.8.3	Análises descritivas e preditivas com uso de BDA e visão computacional	140
4.8.4	Painel de indicadores de desempenho	141
4.8.5	Fases de desenvolvimento do protótipo	142
<b>5</b>	<b>CONCLUSÕES</b>	<b>146</b>
	<b>REFERÊNCIAS</b>	<b>152</b>



## 1 INTRODUÇÃO

Este capítulo apresenta o contexto atual no qual se insere o tema desta tese, bem como a questão de pesquisa a ser respondida, os objetivos geral e específicos, as devidas justificativas, as possíveis contribuições e a estrutura do trabalho.

### 1.1 Contexto e questão de pesquisa

Cada vez mais gerir o desempenho possui um papel crítico no funcionamento de qualquer organização (OJIAKO et al., 2022; FRANCESCHINI; GALETTO; MAISANO, 2018; BOURNE et al., 2018; VAN FENEMA; KEERS, 2018) e não medir pode levar os gestores a ignorar problemas potenciais até que seja tarde demais para tomar as medidas adequadas (FRANCESCHINI; GALETTO; MAISANO, 2018). Neste contexto, as informações resultantes de um sistema de medição de desempenho (SMD) podem ser usadas para planejar e administrar um negócio, auxiliar na comunicação, gerir a implantação de estratégias, influenciar comportamentos, e promover o aprendizado e aperfeiçoamento na organização (OJIAKO et al., 2022; PAPULOVÁ et al., 2021; PARMENTER, 2015; BOURNE; BOURNE, 2011; FRANCO-SANTOS et al., 2007; BOURNE et al., 2003).

Os SMDs abrangem os processos de coletar, armazenar, analisar e interpretar dados para tomada de decisão (AGOSTINO; SIDOROVA, 2016; BITITCI, et al., 2015; MELNYK et al., 2014). Também podem ser definidos como um conjunto de medidas de desempenho para quantificar a eficiência e a eficácia das ações tomadas no planejamento e gestão de um negócio (NEELY; GREGORY; PLATTS, 1995). Estes sistemas fornecem, além de informação para tomada de decisão, uma comunicação aberta e transparente entre as várias partes interessadas (KAMBLE; GUNASEKARAN, 2020; FRANCO-SANTOS; LUCIANETTI; BOURNE, 2012; FORZA; SALVADOR, 2000), sendo elemento fundamental dos sistemas de gestão das organizações ao avaliar se objetivos estratégicos, táticos e operacionais estão sendo alcançados (BHADANI et al., 2020; FREDERICO et al., 2020; BOURNE, MELNYK, BITITCI, 2018; VAN FENEMA e KEERS, 2018) e interagir com o ambiente onde está inserido (NUDURUPATI; GARNIGO; BITITCI, 2021; GUTIERREZ et al., 2015; KENNERLEY; NEELY, 2003).

Contudo, nas últimas décadas, a quantidade de dados e informações geradas e compartilhadas por pessoas, empresas, setores da administração pública, organizações sem fins lucrativos, pesquisa científica, entre outras fontes, aumentou imensamente (ZHANG J. et

al., 2021; TANWAR et al., 2019; RASCHKA; MIRJALILI, 2019; SIVARAJAH et al., 2017). Este volume de dados complexos e heterogêneos gerados por uma multiplicidade de plataformas, como *sites* de mídia social, telefonia móvel, dispositivos de tráfego, comunicação de máquina para máquina, redes de sensores, sistemas ciber-físico e *Internet of Things* (IoT), em formatos estruturados, semiestruturados e não estruturados (vídeos, áudios, fala, streaming, imagens em tempo real, documentos, gráficos, dados geoespaciais, mundos virtuais 3D) é conhecida como a era do *big data* (TANWAR et al., 2019; GHAVAMI, 2019; RASCHKA; MIRJALILI, 2019; SIVARAJAH et al., 2017).

O *big data* é definido como 5 Vs, ou seja, volume, variedade, velocidade, veracidade, e valor dos dados gerados, armazenados, processados e analisados nas organizações (WANG et al., 2016; WAMBA et al., 2015; MOUSANNIF et al., 2016; ZIKOPOULOS et al., 2011). Contudo, apenas os 3 Vs, volume, variedade, velocidade, caracterizam o *big data*, pois apesar de intrínsecos ao *big data*, a veracidade e o valor não são distintivos, uma vez que são inerentes a qualquer sistema informatizado. A era do *big data* apresenta oportunidades sem precedentes para melhorar o desempenho dos negócios por meio da informação (ZHANG J. et al., 2021; TALWAR; KAUR; WAMBA, 2021; SARDI, et al., 2020; ALEXANDER; KUMAR; WALKER, 2018; ANWAR; KHAN; SHAH, 2018), sendo uma das tecnologias fundamentais para o conceito de indústria 4.0 (TAMBARE et al., 2022; WIECH et al., 2022; KAMBLE, et al., 2020; SARDI, et al., 2020; XU; DUAN, 2019; MOEUF et al., 2018).

*Big data* combinado com o uso de um conjunto de processos de análises avançadas de dados, define o conceito *big data analytics* (BDA) (KHANRA; DHIR; MÄNTYMÄKI, 2020; DEV et al., 2019; LAMBA; DUBEY, 2015; DAVENPORT, 2013). O BDA é um impulsionador de inovação econômica e gestão do desempenho organizacional (BAG, S. et al., 2021; TALWAR; KAUR; WAMBA, 2021; MAWED; AL-HAJJ, 2017), e tem como cerne a mineração e a extração de padrões significativos a partir de dados massivos e brutos de diferentes formatos, proporcionar previsões, minimizar riscos, expandir o entendimento do modelo de negócios, revelar informações ocultas (AKTER, 2016; NAJAFABADI et al., 2015).

Como os SMDs são dinâmicos e evoluem conforme a necessidade da estratégia organizacional e a influência de fatores internos e externos da organização em um ambiente instável (NUDURUPATI; GARNEGO; BITITCI, 2021; SAHLIN; ANGELIS, 2019; NUDURUPATI; TEBBOUNE; HARDMAN, 2016; TUNG; BAIRD; SCHOCH, 2011), obrigados a estarem adequadamente preparados para aproveitar as novas oportunidades é natural que o BDA tenha sobre estes sistemas, forte influência, como o uso de dados não

estruturado na medição de desempenho (ELKMASH; ABDEL-KADER; EL DIN, 2021; KAMBLE; GUNASEKARAN, 2020; ASSANDRE; MARTINS, 2020a; NUDURUPATI; TEBBOUNE; HARDMAN, 2016; MARR, 2015a). Conhecer essa influência é de grande importância para os negócios (KHANRA; DHIR; MÄNTYMÄKI, 2020; KAMBLE; GUNASEKARAN, 2020; ALEXANDER, KUMAR; WALKER, 2018; ANTONIOU et al., 2016; WAMBA et al., 2015), e para medição de desempenho que precisa sempre ser validada em diferentes cenários (TAMBARE et al., 2022; SAHLIN; ANGELIS, 2019; MAWED; AL-HAJJ, 2017; FRANCO-SANTOS et al., 2012; NEELY et al., 1995). Entretanto, apesar de avanços tecnológicos que possibilitam análises mais rápidas e avançadas de grandes volumes de dados complexos e heterogêneos, o aumento exponencial de dispositivos multimídia e consequentemente de dados não estruturados, representa um desafio na geração de valor para os negócios (ELKMASH; ABDEL-KADER; EL DIN, 2021; ZHANG J. et al., 2021; TANWAR et al., 2019; CAMM et al., 2020; MARR, 2015a; GANDOMI; HAIDER, 2015).

Entre várias alternativas de BDA, que podem ajudar a superar o desafio de usar dados não estruturados nos SMDs, uma forma de inteligência artificial e *machine learning*, definida como *deep learning* pode produzir excelentes resultados em diferentes aplicações, utilizando técnicas como visão computacional, reconhecimento de padrões, análise de redes sociais, análise de áudio e processamento de linguagem natural (ORHEI et al., 2021, PATEL; THAKKAR, 2020; LI; OTA; DONG, 2018; JUUSO, 2018; NAJAFABADI et al., 2015).

A análise da produção científica do tema apresenta esta tendência de uso de tecnologias de inteligência artificial (ASSANDRE; MARTINS, 2020a; SAHLIN; ANGELIS, 2019), com destaque para a subárea de *deep learning*, na exploração de dados não estruturados (ASSANDRE; MARTINS, 2020a).

Entre os diferentes formatos de dados não estruturados, as imagens de sistemas de vídeo, que já são utilizadas em várias indústrias (CHOI; SEO, 2020; MAHAMI et al., 2019), podem proporcionar novas oportunidades para medição de desempenho, quando analisadas (DESHPANDE; SHARMA; PEDDOJU, 2019) com técnicas de *deep learning* e BDA. Dentro do contexto apresentado e considerando que a pesquisa empírica pode promover a validação de novas oportunidades (KAMBLE; GUNASEKARAN, 2020; SAHLIN; ANGELIS, 2019; MAWED; AL-HAJJ, 2017; LIMA; CARPINETTI, 2010), a aplicação destas novas tecnologias têm um grande potencial de enriquecer um SMD com contribuições para as medidas de desempenho, infraestrutura e processo de tomada de decisão. Neste sentido, surge a seguinte questão de pesquisa:

**Como o uso de técnicas de BDA e *deep learning* para explorar dados não estruturados de imagens de vídeo pode contribuir para os sistemas de medição de desempenho?**

## 1.2 Objetivo

Dada a questão de pesquisa apresentada anteriormente, que sintetiza a problemática em que esta pesquisa se debruça, o objetivo principal desta tese é: **desenvolver um protótipo de sistemas de medição de desempenho, com uso de técnicas de *deep learning* e BDA para coleta, armazenagem e análise de dados não estruturados de imagens de vídeos.**

## 1.3 Objetivos específicos

- Definir uma infraestrutura de SMD para coleta, análise e armazenagem de dados a partir de imagens de vídeo com uso de *deep learning*;
- Aprimorar o uso de medidas de desempenho, tendo como fonte, dados não estruturados de imagens;
- Criar análises descritivas e preditivas a partir de dados não estruturados de imagem com uso de técnicas de BDA e visão computacional;
- Propor um painel de indicadores de desempenho considerando as características de dados coletados, armazenados, manipulados e analisados a partir de imagens e vídeos;

## 1.4 Justificativa e contribuições

Apesar de cada vez mais ser citado o uso de BDA no contexto dos SMDs (KAMBLE; GUNASEKARAN, 2020; WANG et al., 2016; NUDURUPATI; TEBBOUNE; HARDMAN, 2016; MELLO; LEITE; MARTINS, 2014) e da exigência que esses sistemas sejam mais dinâmicos frente às alterações dos ambientes interno e externo das organizações, capazes de lidar com diferentes variedades e volumes de dados para proporcionar vantagem competitiva (NUDURUPATI; GARNIGO; BITITCI, 2021; SAHLIN; ANGELIS, 2019; NUDURUPATI; TEBBOUNE; HARDMAN, 2016), o estudo da produção científica sobre o tema, demonstrou a necessidade de desenvolver trabalhos empíricos (KAMBLE; GUNASEKARAN, 2020; SAHLIN; ANGELIS, 2019; ANWAR; KHAN; SHAH, 2018), de forma a criar e validar novas análises avançadas de dados e medidas de desempenho, bem como mudanças em

processos existentes de medição (KAMBLE; GUNASEKARAN, 2020). Um estudo da literatura sobre o tema da pesquisa, também demonstrou uma tendência de evolução do uso de tecnologias de inteligência artificial para medição de desempenho e BDA (TAMBARE et al., 2022; SAHLIN; ANGELIS, 2019; ASSANDRE; MARTINS, 2020a), principalmente voltadas à análise de dados não estruturados por meio de técnicas de *deep learning* (ASSANDRE; MARTINS, 2020a).

*Deep learning* é uma forma de *machine learning*, dentro da área de inteligência artificial, pela qual os computadores aprendem com experiências, sem a necessidade de operadores humanos especificarem formalmente todo o conhecimento necessário para compreender algo, levando a um progresso significativo na solução de uma ampla gama de problemas, mesmo frente a grandes volumes e variedade de dados (CHOLLET, 2021; LIU et al., 2020; PATEL; THAKKAR, 2020; JUUSO, 2018; GOODFELLOW, 2016).

Nos últimos anos a tecnologia de *deep learning* melhorou muito o desempenho das máquinas em interpretar visualmente informações, por meio de sistemas de visão computacional, sendo utilizada nas aplicações mais avançadas desta área (ORHEI et al., 2021; LONG; HE; YAO, 2021; CHOLLET, 2021; ZHANG A. et al., 2021; LIU et al., 2020; SHANAHAN; DAI, 2020; ZHAO et al., 2019), com maior precisão no reconhecimento de vídeo (LI; OTA; DONG, 2018; LIU; QI; BANERJEE, 2018; LECUN; BENGIO; HINTON; 2015). Esta maior precisão alcançada, pode possibilitar a criação de medidas de desempenho mais precisas a partir de medições que antes eram inviáveis, como quantificar o progresso de processos de montagens, avaliar o comportamento de clientes em lojas, medir filas, acompanhar a movimentação de pessoas e máquinas dentro de uma operação, cotejar ações humanas nos processos de fabricação, além de identificar o uso de ferramentas manuais em células de produção, o estado de equipamentos, desvios de procedimentos etc. O uso da combinação de *deep learning* e visão computacional também pode viabilizar coleta de dados mais frequentes de forma a fomentar o uso de BDA nos SMD.

As oportunidades geradas com o uso destas tecnologias podem aprimorar os SMDs e auxiliar a tomada de decisão, a fim de melhorar o desempenho das organizações (PATEL; THAKKAR, 2020; DAUGHERTY; WILSON, 2018). Contudo, não foram localizadas no estudo da literatura sobre o uso de BDA em SMD, pesquisas combinando *deep learning* com técnicas de visão computacional, com objetivo de explorar a grande quantidade de imagens geradas pelas mais variadas plataformas (dados não estruturados) e fornecer informações para estes sistemas, o que caracteriza uma lacuna na literatura.

Este trabalho traz contribuições para o campo de SMD à medida que disponibiliza o conhecimento científico para produção de novas soluções com a aplicação de técnicas de BDA, *deep learning* e visão computacional. O trabalho também contribui com o conhecimento prescritivo ao apresentar o processo cognitivo para projetar e construir artefatos como solução de problemas práticos e relevantes das organizações, além de fomentar o desenvolvimento de conhecimento em Engenharia (GOECKS et al., 2021; LACERDA et al., 2013; GOUVÊA DA COSTA; PINHEIRO DE LIMA, 2011).

## 1.5 Estrutura do Trabalho

A estrutura do trabalho é composta por cinco partes: (i) introdução, (ii) revisão da literatura, (iii) delineamento da pesquisa, (iv) desenvolvimento do protótipo e (v) conclusão. Este Capítulo 1 de introdução apresenta o contexto, a questão de pesquisa, o objetivo geral e objetivos específicos, bem como a justificativa, contribuições e a estrutura do trabalho.

No Capítulo 2, a revisão de literatura trata da fundamentação teórica dos temas, dividida em duas partes. A primeira se refere ao SMD e apresenta as principais definições sobre o tema, os elementos do SMD, modelos de referência, o processo de um SMD, *design*, implantação, uso e revisão do SMD, e a infraestrutura de tecnologia da informação para estes sistemas. A segunda parte se refere ao conceito de *big data*, desafios no uso do *big data*, BDA, formas de análise de grandes volumes de dados e suas aplicações, técnicas de BDA e *video analytics*, além do uso *deep learning* em BDA e *video analytics* para SMDs com uso de *deep learning*.

No Capítulo 3 é apresentado o delineamento da pesquisa, descrevendo a escolha da concepção metodológica, o método de pesquisa definido, a construção de artefatos por meio da *design science research* e as fases da pesquisa. O Capítulo 4. abrange o desenvolvimento do protótipo de SMD com uso de técnicas de BDA e *deep learning*, descrevendo as fases realizadas de identificação do problema, conscientização, identificação dos artefatos e configuração de classes de problemas, síntese dos artefatos estudados, proposição, projeto, desenvolvimento e avaliação do protótipo e apresentação do aprendizado obtido com o processo de construção.

Por fim, o Capítulo 5 apresenta a generalização dos resultados da pesquisa, por meio da conclusão, limitações da pesquisa, além da proposta de futuros trabalhos a serem desenvolvidos sobre o tema.

## 2 REVISÃO DA LITERATURA

Para proporcionar suporte à discussão dos resultados, este capítulo apresenta o referencial teórico dos principais temas envolvidos na pesquisa. Em sua primeira parte, trata do SMD e apresenta aspectos como os conceitos de SMD e medidas de desempenho, elementos que formam o SMD, seus processos de construção, implantação, manutenção e uso/revisão, principais modelos de referência e evolução destes sistemas e a influência da tecnologia da informação. Na segunda parte do capítulo, são trabalhados os conceitos de *big data*, desafios no uso de *big data*, BDA, técnicas de BDA, formas de análise de grandes volumes de dados, uso *deep learning* em BDA, e *video analytics* para SMDs por meio de *deep learning*.

### 2.1 Sistemas de medição de desempenho

No final da década de 1980, a medição de desempenho começou a passar por uma revolução, frente a insatisfação dos sistemas tradicionais baseados em indicadores financeiros e de produtividade (NUDURUPATI; TEBBOUNE; HARDMAN, 2016; NUDURUPATI et al., 2011; TATICCHI; TONELLI; CAGNAZZO, 2010; BOURNE et al., 2000), uma vez que essas medidas não refletiam totalmente as mudanças nas circunstâncias competitivas e nas estratégias das organizações, tendo apenas foco em custos. Estas medidas de desempenho forneciam uma visão histórica, dando pouca indicação de realizações futuras e encorajando o planejamento de curto prazo (KENNERLEY; NEELY, 2002a; ECCLES, 1991).

A competição gerada pela globalização, os programas de qualidade, e o avanço da tecnologia da informação (TAMBARE et al., 2022; NEELY, 1999), somados ao questionamento desse paradigma de indicadores financeiros e de produtividade, contribuíram para o surgimento de novos modelos de SMDs, como para medir o desempenho de elementos específicos (por ex., custo ou clientes) e outros utilizados para medidas relacionadas com toda a organização. Entre 1991 e 2000, houve o desenvolvimento de vários modelos de gestão de desempenho. As dimensões das medidas de desempenho abrangidas por estes modelos centraram-se em grande parte nas medidas não financeiras, qualidade, questões relacionadas com pessoas, satisfação dos clientes e competitividade (YADAV; SAGAR, 2013).

A partir dos anos 2000, os SMDs apresentaram uma melhoria adicional na compreensão do processo, uma vez que foram incluídas medidas de desempenho sociais e ambientais junto com suas perspectivas tradicionais (YADAV; SAGAR, 2013; TATICCHI;

TONELLI; CAGNAZZO, 2010). A ligação entre SMD e estratégia também passou a ser motivo de preocupação neste período (BOURNE et al., 2000).

### 2.1.1 Definições

A medição de desempenho é o processo pelo qual é quantificada a eficiência e a eficácia das ações tomadas pelas organizações, por meio de medidas e indicadores estabelecidos. Neste contexto, a eficácia pode ser entendida como as medidas que abrangem às exigências dos clientes, enquanto a eficiência refere-se às medidas relacionadas economicamente de recursos da empresa utilizados na prestação de um nível de satisfação do cliente (LOHMAN; FORTUIN; WOUTERS, 2004; NEELY; GREGORY; PLATTS, 1995).

Desta forma, a medição de desempenho não permite que os tomadores de decisão simplesmente verifiquem o progresso em direção a metas preestabelecidas, mas também indica a situação do processo (FRANCESCHINI; GALETTO; MAISANO, 2018). Um conjunto de medições de desempenho reflete o quão bem a empresa consegue alcançar seus objetivos estratégicos e pode levar à tomada de ações a fim de aumentar a probabilidade de atingir as metas estabelecidas (FRANCESCHINI; GALETTO; MAISANO, 2018; LOHMAN; FORTUIN; WOUTERS, 2004). A medição de desempenho é o resultado da leitura de uma medida de desempenho preestabelecida, que geralmente é expressado, por meio de um número e uma unidade de medida (FRANCESCHINI; GALETTO; MAISANO, 2018; LOHMAN; FORTUIN; WOUTERS, 2004).

Uma medida/métrica de desempenho pode ser entendida como uma variável que expressa quantitativamente a eficácia ou eficiência ou ambos, de uma parte ou de todo um processo, ou sistema, comparada a uma determinada norma ou meta, de forma a apoiar a implantação e monitoramento de iniciativas estratégicas (PARMENTER, et al., 2015; LOHMAN; FORTUIN; WOUTERS, 2004), por exemplo o número de visitas ao *site* da empresa, notas fiscais emitidas, quantidade de peças produzidas, clientes atendidos no estabelecimento, total de equipamentos revisados, número de pedidos de venda finalizados etc.

Também expressando a eficácia e eficiência, e conceituados como uma relação matemática, os indicadores de desempenho (ID) proporcionam uma visão mais ampla de um evento observado e a identificação de lacunas de desempenho entre o atual e o desejado (HWANG, et al., 2017). O faturamento da empresa dividido pelo número de funcionários em um período de tempo, ou defeitos por produtos produzidos, horas paradas por horas



disponíveis, são exemplos de IDs, que proporcionam a base para o conceito de *Key Performance Indicators* (KPI) empregados para o monitoramento de negócios e geralmente reconhecidos como IDs críticos para o sucesso atual e futuro de qualquer organização (PARMENTER, et al., 2015; RASMUSSEN; BANSAL; CHEN, 2009; KAPLAN; NORTON, 2001).

Um SMD é definido pelo conjunto de medidas de desempenho/métricas que interage com o ambiente em que é utilizado e faz parte de um sistema maior de gestão (GUTIERREZ et al., 2015; BITITCI et al., 1997). Entretanto, foram encontradas outras definições de SMD na literatura pesquisada. Para Lohman, Fortuin e Wouters (2004), um SMD é um sistema que abrange, *software*, bancos de dados e procedimentos para executar a medição de desempenho de forma consistente, padronizada e completa. Desdobrado da missão e do planejamento estratégico de uma organização, com uma abordagem estruturada, um SMD abrange a coleta e análise de dados, relata os resultados e auxilia a tomar de decisões de negócios (FRANCESCHINI; GALETTO; MAISANO, 2019; AGOSTINO; SIDOROVA, 2016).

O SMD é um conjunto de processos de uma organização usado para gerir a implantação de sua estratégia, comunicar sua posição e progresso internamente e externamente, influenciar o comportamento e ações dos funcionários, além de promover o aprendizado e aperfeiçoamento (FRANCO-SANTOS et al., 2007).

Entretanto, a definição mais citada na literatura para SMD é de Neely, Gregory e Platts (1995) em que um SMD é um conjunto de medidas para quantificar a eficiência e a eficácia de ações (NEELY; GREGORY; PLATTS, 1995). Neely (1998) complementa esta definição adicionando que “o SMD permite a tomada de decisões fundamentadas e a realização de ações, porque quantifica a eficiência e a eficácia das ações passadas por meio da coleta, compilação, ordenação, análise, interpretação e disseminação dos dados apropriados” (NEELY, 1998, p.5).

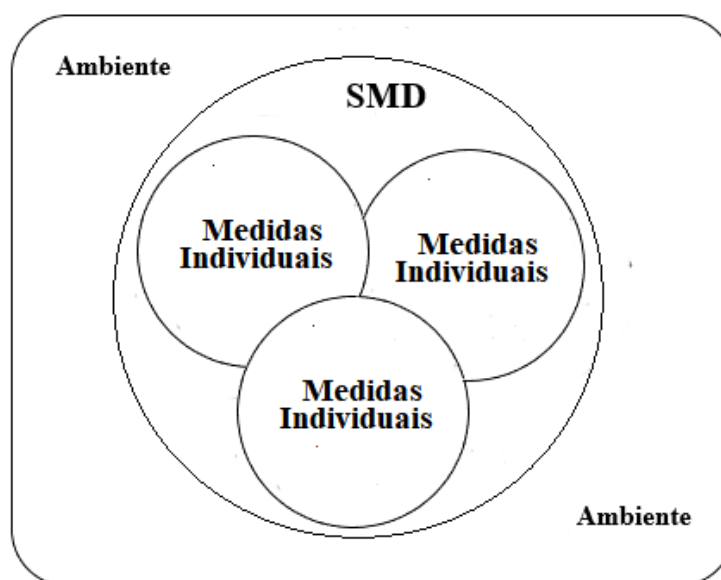
### **2.1.2 Elementos do SMD**

Os SMDs são parte fundamental dos sistemas de gestão das organizações (BHADANI et al., 2020; BOURNE; MELNYK; BITITCI, 2018; VAN FENEMA; KEERS, 2018) e proporcionam comunicação aberta e transparente entre as várias partes interessadas (KAMBLE; GUNASEKARAN, 2020; FORZA; SALVADOR, 2000). Neste contexto, um SMD pode ser analisado em três níveis, como apresentado na Figura 1: as medidas

individuais, o conjunto de medidas/indicadores (o SMD como entidade) e o ambiente em que ele opera (MARTINS et al., 2014; NEELY; GREGORY; PLATTS, 1995).

O nível das medidas de desempenho individuais está geralmente relacionado aos objetivos e estratégias da organização, e caso exista uma lógica no agrupamento das medidas de desempenho e na escolha das medidas individuais, este grupo forma um SMD. Quanto aos ambientes que o SMD opera, no ambiente interno é necessário ser consistente à cultura organizacional, por sua vez, no ambiente externo é preciso considerar os clientes e os concorrentes (NEELY; GREGORY; PLATTS, 1995).

Figura 1 - Os três níveis dos sistemas de medição de desempenho



Fonte: Adaptado de Neely, Gregory e Platts (1995)

Estes sistemas precisam ser dinâmicos, a fim de fornecer informações significativas sobre o desempenho, auxiliar na tomada de decisões corretas (NUDURUPATI; GARNEGO; BITITCI, 2021; SARDI et al., 2020; KENNERLEY; NEELY, 2003; BITITCI; TURNER, 2000), bem como ajudar a prever o desempenho futuro, frente às mudanças no ambiente interno e externo das organizações (KAMBLE; GUNASEKARAN, 2020; FRANCESCHINI; GALETTO; MAISANO, 2018; BOURNE et al., 2003; KENNERLEY; NEELY, 2002a).

Um SMDs tem um ciclo de vida que abrange o projeto, a implantação e o uso/revisão (KAMBLE; GUNASEKARAN, 2020; MARTINS et al., 2014; BOURNE et al., 2003; BOURNE et al., 2000) e evolui se adaptando às mudanças na estratégia, nos processos produtivos, nas novas tecnologias e na estrutura organizacional (WANG et al., 2016; BOURNE et al., 2000).

O Quadro 1 apresenta os grupos de elementos que constituem um sistema de medição de desempenho. Os três grupos são: recursos, propósitos e processos (FRANCO-SANTOS et al., 2007).

Quadro 1 – Elementos dos SMDs

Elementos		
Recursos	Medidas de desempenho	
	Infraestrutura de apoio	Adquirir
		Armazenar
		Analisar
		Disseminar
Processos	Desenvolver medidas	
	Seleção de medidas	
	Coleta de dados	
	Manipulação de dados	
	Gestão da informação	
	Avaliação e recompensa	
	Sistema para revisão	
Propósitos	Medir o desempenho	
	Gerir a estratégia	
	Comunicar	
	Influenciar	
	Aprendizado	

Fonte: Adaptado de Franco-Santos et al. (2007)

As medidas de desempenho e uma infraestrutura de apoio para executar a coleta, manipulação e análise dos dados, formam um grupo de recursos necessários e suficientes para a existência do sistema (FRANCO-SANTOS et al., 2007). Outro grupo de elementos é formado pelos propósitos, os quais estão relacionados com os objetivos de uso de um SMD. Podem ser agrupados em cinco categorias (FRANCO-SANTOS et al., 2007):

- Medição de desempenho que inclui monitorar o progresso e avaliar o desempenho, sendo esse o papel fundamental de um SMD;

- A gestão da estratégia composta pelo planejamento, formulação, implantação e execução da estratégia;
- Comunicação interna e externa, *benchmarking* e cumprimento dos regulamentos;
- Influenciar o comportamento abrangendo a recompensa ou compensação comportamental e a gestão e controle de relações;
- Aprendizado e o aperfeiçoamento que compreende as funções de *feedback*, aprendizagem de ciclo duplo e ações de melhorias.

Os processos têm grande importância para que o sistema execute suas funções e são classificados em cinco categorias (FRANCO-SANTOS et al., 2007):

- Seleção e desenvolvimento de medidas de desempenho que inclui o processo de identificação das necessidades dos *stakeholders*, planejamento, especificação dos objetivos estratégicos, desenvolvimentos de medidas e definição de metas;
- Coleta, manipulação e análise dos dados;
- Gestão da informação que compreende os processos de fornecimento de informação, interpretação e tomada de decisão;
- Avaliação do desempenho e recompensas;
- Procedimentos de revisão que possibilitam um ciclo de *feedback*.

Atualmente os sistemas de gestão de desempenho são complexos, com diferentes abordagens e propósitos em ambientes organizacionais variados. Vale destacar que os SMDs não são universais e precisam ser adaptados às circunstâncias em que serão usados e aos objetivos pretendidos pelos gestores da organização (NUDURUPATI; GARNEGO; BITITCI, 2021; FRANCO-SANTOS et al., 2007).

Kennerley e Neely (2002b) destacam propriedades essenciais para um bom SMD:

- Possuir uma combinação equilibrada de medidas de desempenho financeiras e não financeiras;
- Ajudar a prever o que está para acontecer com o negócio;
- Incentivar as pessoas a terem o comportamento desejado pela organização;
- Ser parte integrante de um processo sistemático para revisar as métricas e garantir que elas estimulem uma ação proposital.

Um SMD eficaz deve monitorar o desempenho anterior e ajudar a planejar o desempenho futuro, fornecer um acompanhamento equilibrado do negócio, demonstrar como os resultados estão relacionados às decisões tomadas, prevenir a inclusão de medidas de desempenho conflitantes, reforçar estratégias organizacionais, ser compatível com a cultura

organizacional e os sistemas de recompensa disponíveis e fornecer dados para comparação (GUTIERREZ et al., 2015; NEELY, 1998).

### 2.1.3 Modelos de referência para sistemas de medição de desempenho

Os SMDs são geralmente definidos e implantados usando métodos diferentes (RAVELOMANANTSOA; DUCQ; VALLESPER, 2019), uma vez que precisam ser adaptados às circunstâncias em que serão usados (NUDURUPATI; GARNEGO; BITITCI, 2021; FRANCO-SANTOS et al., 2007). Assim, os modelos de referência podem ajudar no desenvolvimento de novos sistemas, principalmente ao fazê-lo pela primeira vez (FRANCESCHINI; GALETTO; MAISANO, 2019). Geralmente, os modelos de referência fornecem um processo ou mecanismo de apoio à gestão da organização para orientar o planejamento da medição do desempenho e a competitividade em longo prazo (YADAV; SAGAR, 2013).

Esses modelos de referência também podem possuir características que vinculam a estratégia às operações, e oferecem um conjunto equilibrado de medidas de desempenho financeiras e não financeiras, na tentativa de criar relações quantitativas e abordar a medição de desempenho como um processo cognitivo (TATICCHI; TONELLI; CAGNAZZO, 2010). Como não são concebidos para o mesmo propósito e nem no mesmo contexto, cada um dos modelos de referência tem vantagens e desvantagens para medir o desempenho de forma otimizada (RAVELOMANANTSOA; DUCQ; VALLESPER, 2019).

Apesar do foco de sua pesquisa ser as pequenas e médias empresas, Taticchi et al. (2010) analisam a evolução da literatura sobre SMDs e as forças e fraquezas dos modelos de referência de SMD. A Tabela 1 apresenta os principais modelos de SMD desenvolvidos até 2007.

Tabela 1- Principais modelos e estruturas de SMD desenvolvidos até 2007

<b>Período</b>	<b>Método/Framework</b>	<b>Autor</b>
Antes 1980	ROI, ROE, ROCE and derivates	Simons (2000)
1980	Economic Value Added Model (EVA)	Stewart (2007)
1988	Activity Based Costing (ABC)	Cooper; Kaplan (1988)
1988	Strategic Measurement Analysis Reporting Technique (SMART)	Cross; Lynch (1988)

1989	Supportive Performance Measures (SPA)	Keegan et al. (1989)
1990	Customer Value Analysis (CVA) Customer	Value Inc. (2007)
1991	Results and Determinants Framework (RDF)	Fitzgerald et al. (1991)
1992	Balanced Scorecard (BSC)	Kaplan and Norton (1992)
1994	Service-Profit Chain (SPC)	Heskett et al. (1994)
1995	Return on Quality Approach (ROQ)	Rust et al. (1995)
1996	Cambridge Performance Measurement Framework (CPMF)	Neely et al. (1996)
1996	Consistent Performance Measurement System (CPMS)	Flapper et al. (1996)
1997	Integrated Performance Measurement System (IPMS)	Bititci et al. (1997)
1998	Comparative Business Scorecard (CBS)	Kanji (1998)
1998	Integrated Performance Measurement Framework (IPMF)	Medori; Steeple (2000)
1999	Business Excellence Model (BEM)	EFQM (2007)
2000	Dynamic Performance Measurement System (DPMS)	Bititci et al. (2000)
2001	Action-Profit Linkage Model (APL)	Epstein; Westbrook (2001)
2001	Manufacturing System Design Decomposition (MSDD)	Cochran et al. (2001)
2001	Performance Prism (PP)	Neely et al. (2001)
2004	Performance Planning Value Chain (PPVC)	Neely; Jarrar (2004)
2004	Capability Econ Val Intangible Tan Assets Model (CEVITA)	Ratnatunga et al. (2004)
2006	Performance, Development, Growth Benchmarking Sy (PDGBS)	St-Pierre; Delisle (2006)
2007	Unused Capacity Decomposition Framework (UCDF)	Balachandran et al. (2007)

Fonte: Adaptado de Taticchi et al. (2010)

Entre os vários modelos de referência que podem ajudar no desenvolvimento de novos SMDs, esta pesquisa usa o *Integral Framework for Performance Measurement*, para criação do protótipo que não está vinculado a uma situação real. Esta escolha se justifica uma vez que o modelo de referência possibilita focar inicialmente nos processos dentro de uma sequência da cadeia de valor, não exigindo nesta fase conhecer a estratégia da organização.

### **2.1.3.1 *Integral Framework for Performance Measurement***

O *Integral Framework for Performance Measurement* fornece um modelo de referência integrado para medição de desempenho que aborda várias partes interessadas da

organização, reconhecendo que a avaliação de desempenho abrange uma infinidade de processos e ferramentas, e exige uma visão baseada em sistema (RENO, 2011; ROUSE; PUTTERILL, 2003), e não pode ser tratada com foco somente em medidas de desempenho isoladas (PRANCIC, 2008).

Contudo, diferente de outros modelos de referência que consideram a organização como um todo, o *Integral Framework for Performance Measurement* inicialmente foca os processos dentro de uma sequência da cadeia de valor da organização, estabelecendo as normas de desempenho dos processos (as instruções de trabalho ou de operação) e a medição do processo (RENO, 2011; PRANCIC, 2008; ROUSE; PUTTERILL, 2003). Desta forma, cada processo pode ser visto como uma coleção de atividades consumindo insumos para produzir resultados. Cada atividade é uma unidade de trabalho ou tarefa, com um objetivo específico. Esta visão é mostrada na Figura 2 e corresponde ao típico modelo de transformação geral usado para descrever a natureza da produção (KLEIN, 2011).

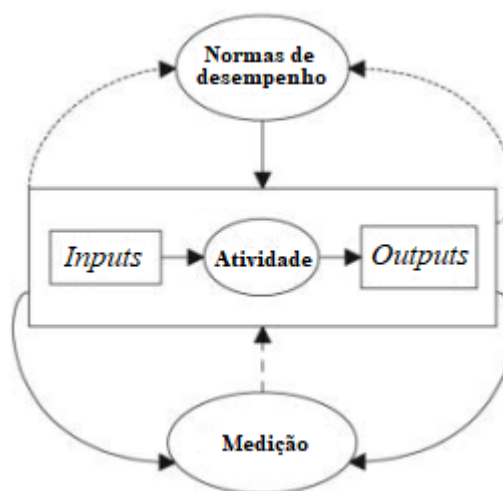
A Figura 3 introduz a noção básica de um controle de medição do processo que compara atividades contra padrões ou normas de desempenho. Assim, o controle é exercido em tempo real ou quase e tem impacto diretamente no processo e atividades (ROUSE; PUTTERILL, 2003).

Figura 2 – Modelo de transformação geral



Fonte: Rouse; Putterill (2003)

Figura 3 - Controle básico de medição do processo



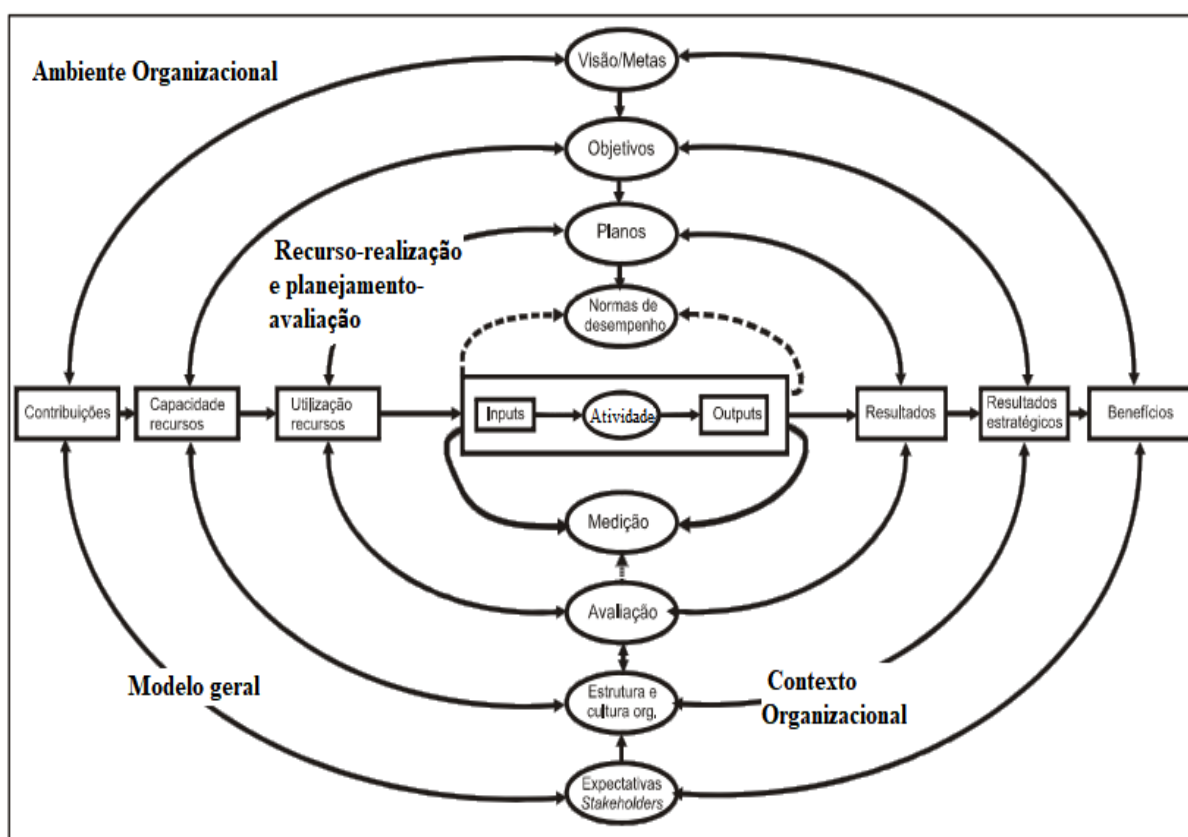
Fonte: Rouse; Putterill (2003)

O segundo passo da estrutura proposta trata das dimensões recurso-realização e o planejamento-avaliação. Desta forma, o modelo de controle é parte de um sistema mais amplo

que mostra quatro subsistemas ao longo de dimensões correspondentes ao planejamento, recursos, avaliação e realização.

A Figura 4 apresenta duas visões: a de recurso-realização (visão horizontal) e o planejamento-avaliação (visão vertical) (RENO, 2011; PRANCIC, 2008). A medição de desempenho é descrita como uma condição prévia e essencial do processo de avaliação, necessitando não apenas de informação sobre o processo, mas também do contexto. Posteriormente, incluem-se os fatores ambientais externos ao processo que afetam o desempenho. Este controle pode incluir *loops* de *feedback* e fluxos de informação para ações corretivas.

Figura 4 – Integral Framework for Performance Measurement



Fonte: Rouse; Putterill (2003)

Esta informação de contexto também inclui recursos utilizados e realizações na forma de resultados. A fase de avaliação introduz conotações comportamentais e a utilização de recursos e informações sobre resultados que podem ser usadas para gerar medidas de avaliação de efetividade, eficiência e economia (RENO, 2011; PRANCIC, 2008; ROUSE; PUTTERILL, 2003).



Um contexto organizacional é considerado no terceiro passo do modelo *Integral Framework for Performance Measurement*. Nos processos estratégicos tradicionais, os objetivos formam a base para os planos que são desdobrados em normas de desempenho. Para alcançar os objetivos, a organização deve possuir capacidade de produção alocada de forma apropriada, além de competência para administrar um empreendimento. As pessoas que fazem parte da organização unem a capacidade e competência com a maneira que a organização é estruturada e com a cultura dominante. A Figura 4 mostra que a estrutura e cultura de uma organização afetam o processo de avaliação bem como quais resultados são reconhecidos como estratégicos (PRANCIC, 2008; ROUSE; PUTTERILL, 2003)

A última camada forma o modelo geral de referência *Integral Framework for Performance Measurement*, onde se estabelece a conexão entre a organização e as partes interessadas (*stakeholders*). As exigências e expectativas dos *stakeholders* definem o ambiente e as restrições gerais em que a organização deve operar. Os *stakeholders* provêm contribuições em antecipação de benefícios comunicados explícita ou implicitamente. Essas contribuições fornecem os recursos utilizados como *inputs* para os processos de produção da organização, na forma de material, trabalho e capital. Os benefícios refletem o “valor” do impacto dos *outputs* da organização e resultados em expectativas dos *stakeholders* (RENO, 2011; PRANCIC, 2008; ROUSE; PUTTERILL, 2003).

Como o modelo de *Integral Framework for Performance Measurement* permite, desde modelos simples de controle de feedback até perspectivas de avaliação mais amplas e apropriadas aos requisitos das partes interessadas e ao propósito da organização (ROUSE; PUTTERILL, 2003), sua implantação pode começar pelo elemento central ou mesmo pelos níveis mais alto.

#### **2.1.4 Processos de desenvolvimento de um SMD**

O desenvolvimento de um SMD pode ser conceitualmente separado nas fases de *design*, implantação e uso (PAPULOVÁ et al., 2021; JÄÄSKELÄINEN; ROITTO, 2016; LOHMAN; FORTUIN; WOUTERS, 2004; PARIDA; KUMAR, 2006). Entretanto, junto com a fase de uso podem requerer as ações de revisão do sistema (KEATHLEY; VAN AKEN, 2013; BOURNE et al., 2000). Outras abordagens são apresentadas para o processo de desenvolvimento de SMDs, como detalhado na Tabela 2, que adicionam as fases de *design*, *implementation* e *use* a fase de *reviewing/updating* (GUTIERREZ et al., 2015;

NUDURUPATI et al., 2011), apesar de todos os conceitos serem muito semelhantes em suas essências.

Tabela 2 - Abordagens de desenvolvido de SMD

<b>Fases propostas</b>	<b>Autores</b>
<i>Design, implement, use/review</i>	Bourne et al. (2000) Keathley, Van Aken (2013)
<i>Design, implement, use</i>	Jääskeläinen, Roitto (2016) Lohman, Fortuin e Wouters (2004) Parida, Kumar (2006)
<i>Design, implementation, use and reviewing/updating</i>	Nudurupati (2011) Gutierrez et al., 2015

Fonte: elaborado pelo autor

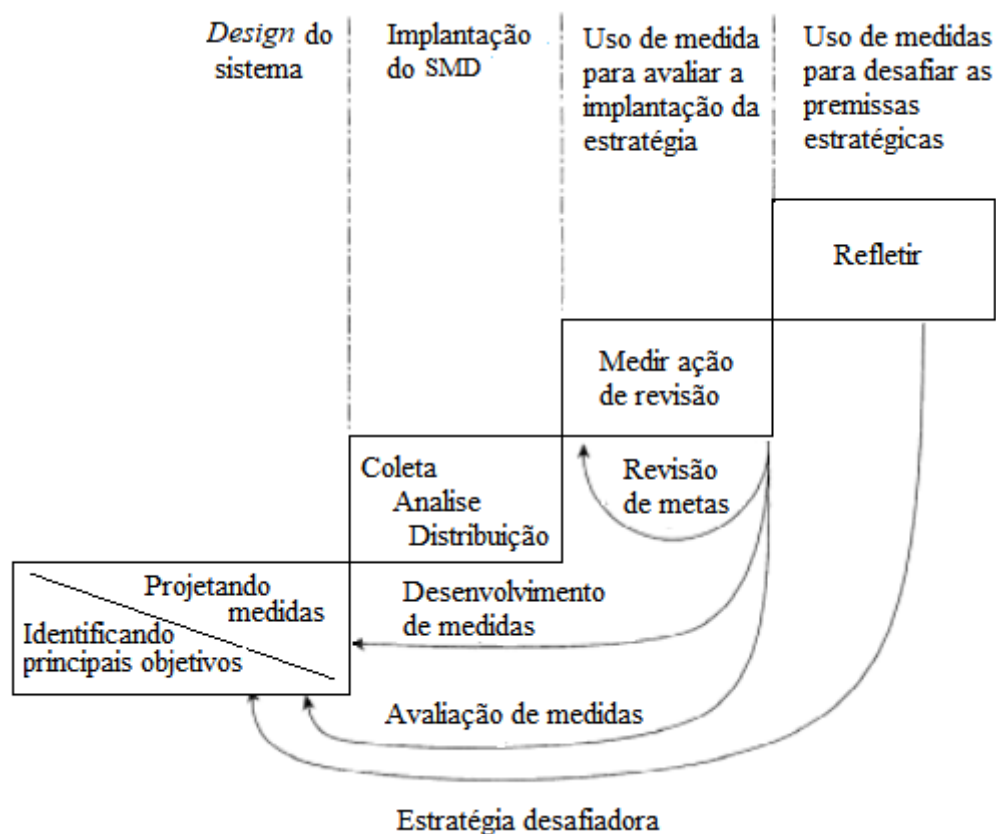
Apesar de conceitual esta divisão é útil, uma vez que as fases de desenvolvimento de um SMD requerem diferentes abordagens (BOURNE et al., 2000). A fase de *design* propõe identificar os principais objetivos do SMD e desenvolver as medidas de desempenho (BOURNE et al., 2000; KEATHLEY; VAN AKEN, 2013).

Na fase de implantação do SMD os sistemas e procedimentos são implantados para coletar e processar os dados que permitem que as medições sejam feitas regularmente de forma padronizada. Na fase de uso/revisão, são revisados os resultados da medição para avaliar se as operações são eficientes e eficazes e se a estratégia foi implantada com sucesso. A revisão prevista nesta fase tem como objetivo a atualização e adaptação constante do SMD (GUTIERREZ et al., 2015; PARIDA; KUMAR, 2006; LOHMAN, FORTUIN; WOUTERS, 2004).

Como a separação das fases, a sequência apresentada de como o SMD deve progredir também é conceitual, uma vez que as fases podem se sobrepor, conforme diferentes medidas individuais são implantadas em diferentes taxas. Assim, algumas medidas de desempenho podem ser implantadas antes que todas as medidas tenham sido completamente projetadas, sendo frequente ocorrer uma sobreposição entre implantação e uso (BOURNE et al., 2000). Neste processo, uma medida de desempenho pode ser excluída, substituída ou alterada, bem como a meta estabelecida para ela ser adaptada (GUTIERREZ et al., 2015; LOHMAN; FORTUIN; WOUTERS, 2004).

A Figura 5 apresenta o processo iterativo de desenvolvimento de um SMD e considera como fases deste processo, conforme Bourne et al. (2000) o *design* do sistema, a implantação do SMD e por fim uso e revisão.

Figura 5 – Processo iterativo de desenvolvimento de um SMD



Fonte: Bourne et al.,(2000)

### 2.1.5 Design dos sistemas de medição de desempenho

Às vezes o SMD não possui um *design* deliberado e suas medidas de desempenho são desenvolvidas e evoluem ao longo do tempo sem nenhuma iniciativa formal de projetar um sistema abrangente (OJIAKO et al., 2022). Outras vezes, as organizações começam a desenvolver um SMD de forma equivocada, tentando selecionar imediatamente os *Key Performance Indicator* (PARMENTER, 2015). Entretanto, a fase de *design* tem como foco identificar as necessidades dos *stakeholders* das partes interessadas e considerar os objetivos do negócio, junto com uma estrutura para medidas de desempenho adequadas e seus atributos

(GUTIERREZ et al., 2015; MARTINS et al., 2014). Desta forma, a fase pode ser subdividida em: identificar os objetivos principais a serem medidos e projetar as próprias medidas e indicadores de desempenho derivados da estratégia da organização (GUTIERREZ et al., 2015; LOHMAN; FORTUIN; WOUTERS, 2004; BOURNE et al., 2000).

Outro ponto que projetistas e usuários de SMD devem observar na fase de *design* está na importância de desenvolver um sistema apoiado por comunicações bidirecionais com objetivo de estimular o compartilhamento de conhecimento, gerar confiança e evitar resistência (PARIDA; KUMAR, 2006).

Quatro elementos devem ser considerados no *design* do SMD (MARTINS et al., 2014; FERNANDEZ et al., 2012):

- Ponto de entrada: o *design* e a implantação de medidas de desempenho são introduzidos no negócio;
- Participação: definição de profissionais a serem envolvidos nos trabalhos de *design* do sistema;
- Procedimentos: conjunto de ferramentas e técnicas por meio das quais a equipe de gestão trabalha em conjunto;
- Gestão do projeto: apoio administrativo, coordenação e facilitadores necessários para o progresso do projeto.

Apesar de não existir uma forma exata de planejar um SMD, uma vez que cada organização possui diferentes necessidades, rotinas, estruturas hierárquicas e modelos (NUDURUPATI; GARNAGO; BITITCI, 2021; PACKOVÁ; KARÁCSÓNY, 2010), a literatura apresenta várias abordagens para projetar estes sistemas (FRANCESCHINI; GALETTO; MAISANO, 2018; GUTIERREZ et al., 2015; FERNANDEZ et al., 2012; NUDURUPATI; BITITCI, 2005). Os métodos geralmente diferem no número de etapas e/ou na forma como essas etapas são seguidas; no entanto, todas demonstram a preocupação em conectar o sistema aos assuntos estratégicos da organização (GUTIERREZ et al., 2015). Na fase de *design* de um SMD, o plano estratégico da organização pode ser um ponto de partida importante para identificar os objetivos principais de sistemas de medição de desempenho (FRANCESCHINI; GALETTO; MAISANO, 2019; LOHMAN; FORTUIN; WOUTERS, 2004).

Após identificar os objetivos principais a serem medidos pelo SMD, as medidas de desempenho, derivadas da estratégia da organização, devem ser definidas (MIKUŠOVÁ; JANEČKOVÁ, 2010; AL-TURKI; DUFFUAA, 2003). A escolha de medidas de desempenho é um dos pontos críticos que as organizações enfrentam em todos os setores de negócios

(FRANCESCHINI; GALETTO; MAISANO, 2018; GUTIERREZ et al., 2015; FERNANDEZ et al., 2012; NEELY; GREGORY; PLATTS, 1995; ROCKART, 1979). Essa preocupação aparece na literatura pesquisada que é dominada por respostas à pergunta “o que devemos medir?” (BOURNE et al., 2000).

Um conjunto de medidas de desempenho inapropriado pode minar a missão estratégica de uma organização, perpetuando práticas de negócios que a impedem de ter uma visão correta de sua situação (FRANCESCHINI; GALETTO; MAISANO, 2018; ROCKART, 1979). A seleção de medidas de desempenho não é um processo fácil, com muitas possibilidades de erro (FREDERICO et al., 2020; FRANCISCHINI; FRANCISCHINI, 2018; FRANCESCHINI; GALETTO, MAISANO, 2007), tendo como questões fundamentais: “quais medidas de desempenho são usadas? Para que são usadas? Quanto elas custam? E que benefício elas oferecem?” (NEELY; GREGORY; PLATTS, 1995). Um erro comum que as organizações cometem em seus SMD é medir muitas variáveis, uma vez que nem tudo que pode ser medido é útil (FREDERICO et al., 2020; MARR, 2015a; LOHMAN; FORTUIN; WOUTERS, 2004; FRANCISCHINI; FRANCISCHINI, 2018), principalmente frente a grande disponibilidade de dados (MARR, 2015a).

Além da disponibilidade de dados, existem cinco outras questões que também devem ser tratadas no estabelecimento de procedimentos de medição de desempenho (MARTINS et al., 2014; GLOBERSON, 1985):

- Unidades de medição: a medida de desempenho pode ser expressa por diferentes variáveis com unidades distintas de medida, como volume, velocidade, peso, tempo, quantidade etc., e/ou relação entre duas variáveis (FRANCESCHINI; GALETTO; MAISANO, 2018, GLOBERSON, 1985);
- Nível de agregação: o desempenho pode ser medido em um nível individual ou de grupo, desta forma, quanto maior o nível de agregação, menor o custo associado à medição, porém com redução na precisão de relatórios e na capacidade de gerenciamento para detectar rapidamente a origem do problema operacional e adotar ações de resposta;
- Precisão da medição: trata da discrepância entre o valor relatado na medição e o real, e o período de tempo decorrido desde o momento em que o evento medido ocorreu até o momento relatado;
- Mecanismos de verificação cruzada: tem como objetivo aumentar a confiabilidade da medição, por meio do conflito de interesse entre as unidades;

- Coleta e análise de dados: esta questão pode ser dividida em duas possibilidades: coleta de dados como parte do processo (automatizada), ou a coleta de dados apenas quando houver necessidade, desta forma não sendo parte do processo.

Os procedimentos de coleta de dados, análise e divulgação devem ser automatizados ao máximo, com objetivo de economizar tempo e esforços, bem como para fornecer consistência das informações (BOURNE et al., 2000). Também é essencial verificar e documentar as fontes de informação para garantir que as medidas de desempenho serão calculadas com os melhores dados disponíveis (GUTIERREZ et al., 2015).

Al-Sarmi e Al-Hemyari (2014) e Al-Turki e Duffuaa (2003) também indicam algumas propriedades em comum que uma medida de desempenho deve possuir:

- Relevância: fornecer uma base para a compreensão do cumprimento das metas e objetivos da organização;
- Interpretabilidade: permite que o interessado possa entender facilmente e usar as informações geradas;
- Pontualidade: estar disponível para os usuários antes de perder seu valor na tomada de decisões;
- Confiabilidade: apresenta informações iguais quando aplicada ao mesmo período de tempo e objeto. Sendo importante para comparação entre diferentes elementos;
- Validade: representa com precisão o que está sendo avaliado.

As medidas de desempenho definidas devem ser descritas por um conjunto de atributos como: nome, objetivo ou finalidade, meta, frequência de atualização etc. Estas informações são responsáveis por definir as funções das medidas de desempenho, o momento e a forma de utilização de cada métrica (FERNANDEZ et al., 2012; BRAZ; SCAVARDA; MARTINS, 2011). A apresentação de uma medida de desempenho também deve vir seguida do detalhamento da meta a ser atingida com padrões numéricos específicos e desafios estabelecidos. Seis técnicas possíveis para atribuição de padrões a medida de desempenho são apresentadas em (GLOBERSON, 1985):

- Técnicas de medição de trabalho com estudo de tempo padrão predeterminado e amostragem de trabalho;
- Análise do desempenho organizacional anterior, de forma a mostrar não apenas desvios, mas também tendências que podem ser representadas;
- Gestão por abordagem de objetivos baseada em diferentes condições, tais como necessidades e disponibilidade de recursos;

- Comparação de dados entre organizações com características semelhantes, como tipo de negócio, tecnologia utilizada ou ambiente (*benchmarking*);
- Considerações econômicas, onde os lucros podem ser obtidos caso as despesas não excederem um certo nível considerado padrão;
- Considerações legais que podem estabelecer os níveis de desempenho exigidos;

As metas atribuídas a uma medida de desempenho devem ter, além do alto alinhamento estratégico (FRANCESCHINI; GALETTO; MAISANO, 2019; GUTIERREZ et al., 2015; LOHMAN; FORTUIN; WOUTERS, 2004), controlabilidade, tempestividade e validade técnica, principalmente quando utilizadas para fins de compensação (GUTIERREZ et al., 2015; PARIDA; KUMAR, 2006) e serem definidas de forma realista, pois uma vez que tenham sido alcançados, uma nova meta mais difícil deve ser definida (MARTINS et al., 2014).

### **2.1.6 Implantação do SMD**

A implantação é uma fase crítica para os SMD, sendo afetada por uma variedade de fatores que podem impedir o sucesso e limitar os benefícios recebidos com o projeto (KEATHLEY-HERRING, 2017; KEATHLEY; VAN AKEN, 2013; NUDURUPATI; BITITCI, 2005). Desta forma sua eficácia exige um alinhamento da estrutura e sistemas organizacionais (GUTIERREZ et al., 2015).

Para fins de categorização, a implantação é definida como a fase em que são estabelecidos os sistemas e procedimentos a serem utilizados nos processos de coleta, comparação, classificação e distribuição de dados (NUDURUPATI, et al., 2011; LOHMAN; FORTUIN; WOUTERS, 2004; BOURNE et al., 2000), de forma que a medição seja realizada regularmente (BOURNE et al., 2000). Desta forma, a implantação de medidas de desempenho requer (NUDURUPATI; BITITCI, 2005):

- Criação de dados: uso de políticas, procedimentos e sistemas para criar os dados necessários para as medidas de desempenho (NUDURUPATI; BITITCI, 2005), de forma que as informações atualmente não registradas passem a ser capturadas. Esta tarefa envolve iniciativas completamente novas, como a criação de uma pesquisa regular (BOURNE et al., 2000), mineração de dados e integração do SMD com outros sistemas;

- Coleta de dados: uso de políticas, procedimentos e sistemas necessários para a coleta regular de dados confiáveis em intervalos de tempo para medição de desempenho (GUTIERREZ et al., 2015; NUDURUPATI; BITITCI, 2005);
- Análise de dados: políticas, procedimentos e sistemas para converter os dados coletados em informações úteis como gráficos de tendências, comparações, relatórios de resumo, análises estatísticas etc. (NUDURUPATI; BITITCI, 2005);
- Distribuição da informação: recursos necessários para disponibilizar informações aos *stakeholders* no momento certo, apoiando a tomada de decisões.

Essas atividades exigem a implantação de novas ferramentas manuais ou a criação de programas de computador para fornecer as informações automaticamente com menor esforço e tempo de análise (BOURNE et al., 2000). Por isso, a tecnologia da informação é considerada como um dos principais fatores de sucesso para a implantação da medição de desempenho (NUDURUPATI; BITITCI, 2005) nas organizações. Entre os fatores que podem dificultar a implantação de indicadores de desempenho, podem ser destacados: a restrição de acesso aos dados, novas iniciativas e atividades da empresa, consequências da medição e esforços para análise e processamento (BOURNE et al., 2002).

### **2.1.7 Uso e revisão do SMD**

Da mesma forma que a implantação, dar continuidade ao uso do SMD, é um desafio para as organizações (FRANCESCHINI; GALETTO; MAISANO, 2007). O uso do SMD está associado a seus propósitos (FRANCO-SANTOS et al., 2007), como fornecer orientação e apoio à melhoria contínua, induzir as atitudes, avaliar grupos, permitir que o desempenho seja comparado contra pontos de referências, e ser parte da aprendizagem individual e organizacional, além de manter um equilíbrio entre o diagnóstico e usos interativos, e entre usos informativos e motivacionais (FRANCO-SANTOS; LUCIANETTI; BOURNE, 2012).

Martins (2000) apresenta como principais propósitos de uso do SMD:

- a) controle (correção de desvios);
- b) melhoria reativa;
- c) melhoria proativa;
- d) planejamento;
- e) pagamento de recompensas;
- f) reforço da retórica da gestão;
- g) indução de atitudes;



- h) benchmarking;
- i) aprendizado individual e organizacional;
- j) foco e justificativa de investimentos.

Assim, na fase de uso do SMD, os gerentes analisam os resultados da medição com objetivo de avaliar a eficiência e eficácia das operações e verificar se a estratégia foi implantada com sucesso (GUTIERREZ et al., 2015; LOHMAN; FORTUIN; WOUTERS, 2004; BOURNE et al., 2000). Portanto, “avaliar a implantação da estratégia” e “desafiar os pressupostos estratégicos” são as duas subdivisões principais do uso das medidas de desempenho (BOURNE et al., 2000). Esta fase também exige que as organizações evitem que os resultados das medidas de desempenho sejam considerados mais importantes que a própria estratégia (ROCKART, 1979).

Entretanto, a medição é apenas uma parte do uso do SMD, pois estes também devem ser dinâmicos e evoluírem conforme as necessidades organizacionais (NUDURUPATI; GARNEGO; BITITCI, 2021; SAHLIN; ANGELIS, 2019; NUDURUPATI; TEBBOUNE; HARDMAN, 2016). Assim, a revisão e atualização de sistemas de medição de desempenho com base nas mudanças dos ambientes internos e externos da organização, são tão importantes quanto seu desenvolvimento e implantação (BRAZ; SCAVARDA; MARTINS, 2011) e podem auxiliar nessa evolução. Desta forma, o sistema de medição de desempenho requer a revisão constante em vários níveis diferentes, incluindo um mecanismo eficaz de análise das metas e padrões; processos para desenvolver medições individuais conforme o desempenho e a mudança das circunstâncias; e verificar periodicamente o conjunto completo de medidas em uso (BOURNE et al., 2000). Neste processo interativo, as medidas de desempenho do SMD são ajustadas e ou mesmo desenvolvidas, conforme mais informações sobre estratégia, clientes, processos, ambiente etc., se tornam disponíveis (LOHMAN; FORTUIN; WOUTERS, 2004; BOURNE et al., 2000).

### **2.1.8 Infraestrutura de tecnologia da informação para SMDs**

Entre os recursos necessários para operacionalização do SMD, a infraestrutura de suporte, responsável pelos processos de coleta, ordenação, análise, interpretação e disseminação de dados é destaque (FRANCO-SANTOS et al., 2007). Desde o início dos anos de 1990, a tecnologia da informação já era considerada importante para infraestrutura dos SMD, atuando como suporte para esses sistemas de forma a proporcionar maior agilidade em seus processos (ECCLES, 1991).

Os SMDs adequadamente projetados, implantados e usados/revisados dependem de uma infraestrutura de tecnologia da informação que proporciona a identificação mais fácil de pontos fracos do negócio, tomada de decisão mais pró-ativa, melhorias contínuas, transparência dos processos, visibilidade, comportamento positivo das pessoas envolvidas (GUTIERREZ et al., 2015; NUDURUPATI; BITITCI, 2005), e informações que refletem o desempenho da organização (MARCHAND; RAYMOND, 2018; NUDURUPATI; BITITCI, 2005). A infraestrutura de suporte de TI para SMDs, além de proporcionar economia de tempo e esforços no processo de medição de desempenho, também viabiliza a consistência das informações geradas e disponibilizadas (BOURNE et al., 2000).

Os sistemas de medição de desempenho com suporte a tecnologia da informação podem ser obtidos de diferentes formas e fontes (MARCHAND; RAYMOND, 2018; NUDURUPATI; BITITCI, 2005) e até a primeira década de 2000 as principais possibilidades eram (NUDURUPATI; BITITCI, 2005):

- Construção pela organização de sua própria plataforma de TI para o SMD, como relatórios, alertas, consultas, *dashboards* etc., a partir de recursos disponíveis como planilhas eletrônicas, bancos de dados, *software* de análise de dados, ferramentas de desenvolvimento *web* etc.
- Uso de um sistema *Enterprise Resource Planning (ERP)* que inclui um banco de dados relacional central e vários módulos para gestão de compras, estoque, produção, pessoal, transporte, atendimento ao cliente, planejamento financeiro e outros aspectos importantes do negócio, integrados a medição de desempenho;
- Utilizar um conjunto de soluções de *software open source*, para auxiliar na coleta, manipulação, processamento e análise de dados;
- Adquirir uma solução de *business intelligence (BI)*, cujo elemento central, *data warehouse*, consolida dados de múltiplas fontes como objetivo de produzir informações para tomada de decisão tática e/ou estratégica;
- Contratar serviços de bancos de dados e/ou processamento analítico *on-line* para manipular e analisar um grande volume de dados sob múltiplas perspectivas em qualquer nível da organização (OLAP);
- Desenvolver ou contratar o desenvolvimento de *software* e/ou sistemas dedicados para medição de desempenho frente às particularidades da organização, considerando seus processos e propósitos do SMD.

No entanto, a partir da década de 2010, com o crescente aumento do volume, da variedade e da velocidade com que os dados passaram a ser gerados (ZHANG J. et al., 2021;

TANWAR et al., 2019; RUSSOM, 2011), essas infraestruturas de TI para SMDs se tornaram inadequadas. O *big data*, como ficou conhecido este volume de dados complexos e heterogêneos gerados por diferentes tipos de plataformas (MIRJALILI, 2019; SIVARAJAH et al., 2017; ANTONIOU et al., 2016; MARR, 2015a; NUDURUPATI; TEBBOUNE, HARDMAN, 2016) trouxe ainda mais destaque para o uso das análises de dados, por meio de uma infraestrutura de TI (KITCHIN, 2014; RUSSOM, 2011).

A possibilidade de diferentes análises avançadas deste grande volume de dados disponíveis no *big data*, apresenta oportunidades sem precedentes para melhorar o desempenho dos negócios por meio da informação e tomada de decisão (ALEXANDER; KUMAR; WALKER, 2018; ANWAR; KHAN; SHAH, 2018; GUPTA; GEORGE, 2016; ANTONIOU et al., 2016; WANG et al., 2016), caracterizando uma nova opção de infraestrutura e medidas de desempenho para os SMDs (KAMBLE; GUNASEKARAN, 2020; ASSANDRE; MARTINS, 2020b), e uma ruptura na forma como os dados devem ser utilizados (DAVENPORT, 2013a).

## **2.2 Big data**

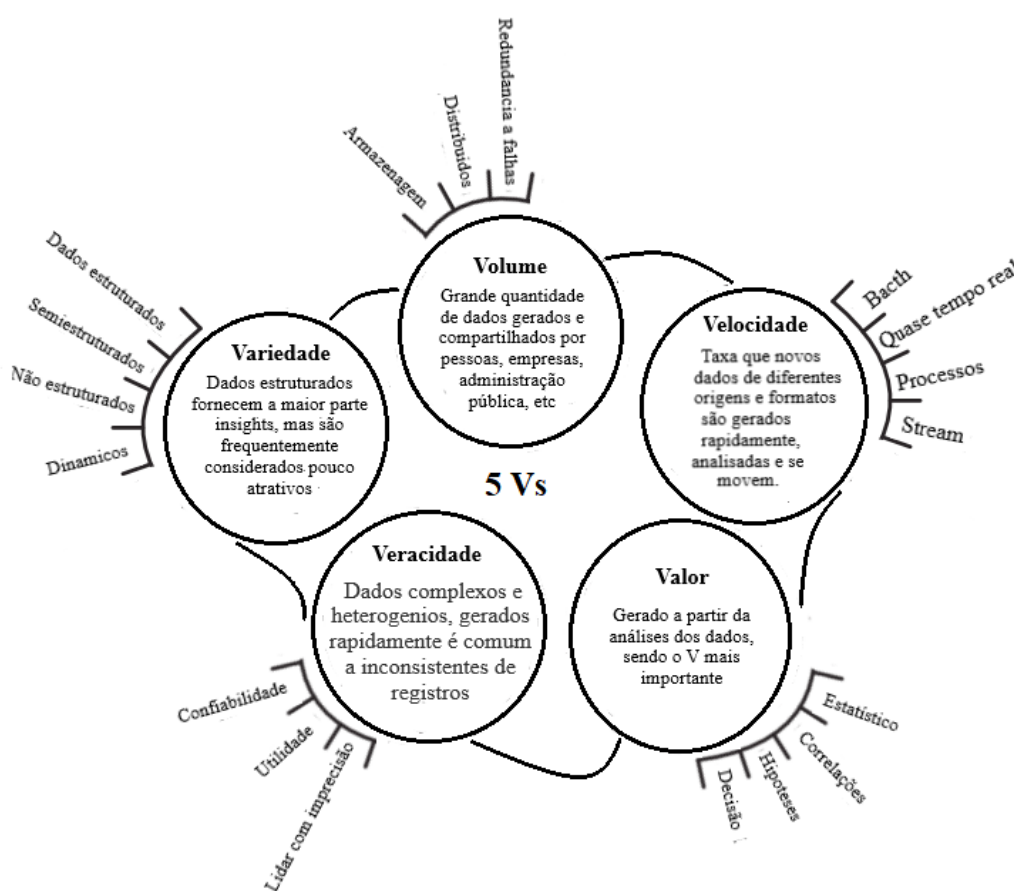
Além de áreas científicas distintas, como computação, engenharia elétrica, ciências sociais, dentre outras, estudos em estratégia e gestão também têm explorado a aplicação de *big data* como um vetor para revolução nos negócios e do modo como as empresas obtêm vantagens competitivas (FURLAN; LAURINDO, 2017). O conceito de *big data* está diretamente relacionado ao “rastros digital” (dados) deixado por todas as atividades diárias de humanos, organizações ou governos (MARR, 2015a), sendo gerados em grande quantidade, possuem diferentes formatos e inúmeras origens (TANWAR et al., 2019; GHAVAMI, 2019; RASCHKA; MIRJALILI, 2019; STAEGEMANN, VOLK; NAHHAS, 2019; SIVARAJAH et al., 2017; MARR, 2015a; NUDURUPATI; TEBBOUNE; HARDMAN, 2016).

Na década de 1990, o termo *big data* era usado com foco em dados não estruturados, mas atualmente, as mesmas abordagens também são propostas para dados estruturados. Assim, os grandes conjuntos de dados complexos gerados rapidamente com diferentes origens, que desafiam *software* de processamento e sistemas de gerenciamento de banco de dados, são frequentemente definidos como *big data* (JUUSO, 2018; DEDIĆ; STANIER, 2016; WU, et al., 2013). Geralmente, *big data* trata de dados que excedem a capacidade típica de armazenagem e processamento computacional de bancos de dados convencionais e técnicas de análise de dados. Assim, requer ferramentas e métodos que podem ser aplicados

para analisar e extrair padrões a partir de dados em grande escala (NAJAFABADI et al., 2015).

O *big data* é definido por vários autores como 5 Vs, ou seja, volume, variedade, velocidade, veracidade, e valor, dos dados gerados, armazenados, processados e analisados nas organizações (WANG et al., 2016; GUPTA; GEORGE, 2016; WAMBA et al., 2015; KITCHIN, 2014; RUSSOM; 2011; ZIKOPOULOS et al., 2011). Porém, deve ser destacado que a veracidade dos dados e o valor gerado por eles são intrínsecos a qualquer sistema de informação. *Big data* também pode ser definido como uma abordagem holística para gerenciar, processar e analisar os 5 Vs (volume, variedade, velocidade, veracidade e valor) e criar *insights* acionáveis para entrega de valor sustentável, medir desempenho e estabelecer vantagens competitivas (WAMBA et al., 2015; KITCHIN, 2014; RUSSOM; 2011). A Figura 6 ilustra a relação entre os 5Vs que formam o *big data*.

Figura 6 – 5Vs do *big data*



Fonte: elaborado pelo autor

A partir da definição de *big data* como 5 Vs, a grande quantidade de dados gerados e compartilhados de diversas formas por pessoas, empresas, administração pública, setores sem fins lucrativos, pesquisa científica, entre outras fontes, e inúmeros tipos de dispositivos corresponde ao volume (TANWAR et al., 2019; RASCHKA; MIRJALILI, 2019; SIVARAJAH et al., 2017; NAJAFABADI et al. 2015), e sua armazenagem uma das principais tarefas das plataformas (BELOV; TATARINTSEV; NIKULCHEV, 2021). Essa grande quantidade de dados gerada se apresenta em formatos estruturados, semiestruturados e não estruturados (TANWAR et al., 2019; GHAVAMI, 2019; RASCHKA; MIRJALILI, 2019) e caracteriza o V de variedade (MARR, 2015a; RUSSOM, 2011). Neste contexto, os dados armazenados em um campo fixo de um registro de tabela ou arquivos definidos são chamados de dados estruturados, como os dados contidos em bancos de dados relacionais e planilhas eletrônicas. Apesar de atualmente os dados estruturados fornecerem a maior parte dos *insights* de negócios, são frequentemente considerados “velhos” e pouco atrativos (JUUSO, 2018; DIVYA; BHARGAVI; JYOTHI, 2018; MARR, 2015a).

Estima-se que a maior parte das informações relevantes para os negócios têm origem em dados não estruturados ou semiestruturados (ZHANG J. et al., 2021), abrangendo todos os dados que não podem ser facilmente inseridos em colunas, linhas e campos (NAJAFABADI et al., 2015; MARR, 2015a; CHEN; CHIANG; STOREY, 2012; RUSSOM, 2011). Normalmente, os dados não estruturados contém muitos textos sem uma padronização, mas também podem conter dados como datas, números e imagens. Já os dados semi estruturados podem possuir alguma estrutura útil para análises, como *tags* ou outros tipos de marcadores, usados para identificar certos elementos nos dados, mas sem uma estrutura rígida (MARR, 2015a).

Os dados também podem ser classificados como internos e externos à organização (GUPTA; GEORGE, 2016; MARR, 2015a). Desta forma, os dados internos representam tudo o que sua empresa possui ou pode acessar, além de controlar seu acesso, como: *feedback* do cliente; desempenho de vendas; vídeo de monitoramento e segurança; transações financeiras; registros dos clientes; controle de estoque etc. Classificados como públicos ou privados, os dados externos existem fora da organização e podem ser obtidos sem pagamento como também por meio de terceiros que realizam coletas e tratamentos, e comercializam seu conjunto (MARR, 2015a).

A Velocidade está relacionada com a taxa que novos dados de diferentes origens e formatos são gerados rapidamente, analisados e se movem ao redor do mundo (JUUSO, 2018; GUPTA; GEORGE, 2016; WAMBA et al., 2015; MARR, 2015a; GANDOMI; HAIDER,

2015; NAJAFABADI et al., 2015). Como consequência do grande volume de dados complexos e heterogêneos, gerados rapidamente é comum a inconsistência de registros. Assim, a veracidade refere-se a confiabilidade ou utilidade dos resultados obtidos de um conjunto de dados, frente a necessidade de lidar com a imprecisão e incerteza nos registros (GUPTA; SHARMA, 2021; CAMM et al., 2020; MARR, 2015a; GANDOMI; HAIDER, 2015; NAJAFABADI et al., 2015; RUSSOM, 2011).

Por fim, a análise fornece o quinto e talvez o mais importante V de *big data* – Valor (MARR, 2015a; RUSSOM, 2011). A análise dos dados é de grande importância, uma vez que o uso de técnicas avançadas auxilia os gestores a entender os negócios das empresas, acompanhar comportamentos e tomar decisões (GANDOMI; HAIDER, 2015; RUSSOM, 2011).

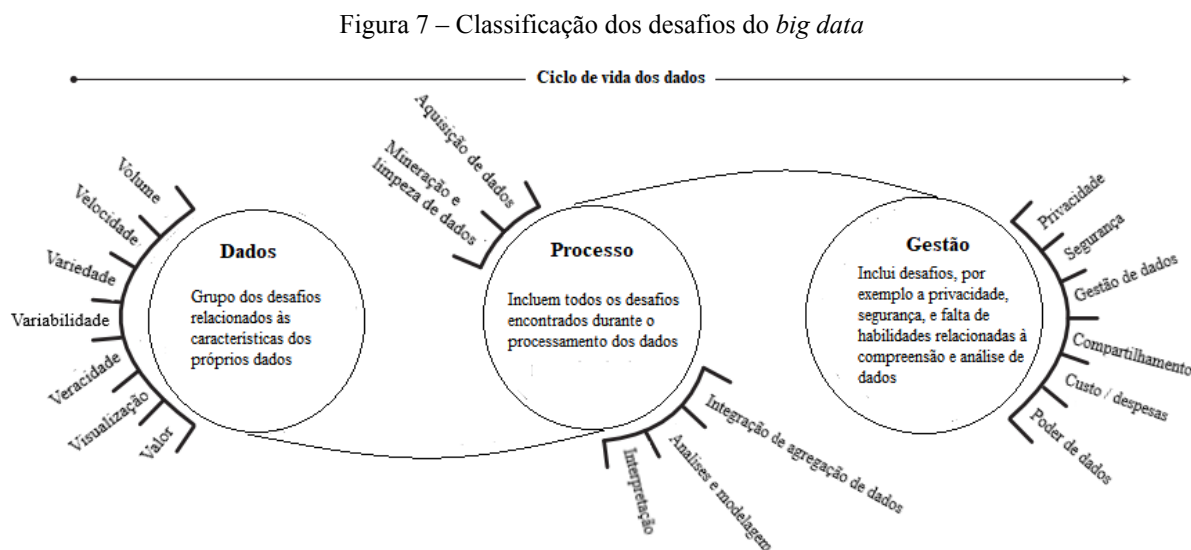
### **2.2.1 Desafios de uso do *big data***

Para facilitar a tomada de decisão baseada em *big data*, as organizações precisam de processos que transformam grandes volumes de dados em diversos formatos e de rápida movimentação em percepções significativas (MOUSANNIF et al., 2016; GANDOMI; HAIDER, 2015), que representa a superação de diversos desafios (SIVARAJAH et al., 2017). Os desafios a serem superados dependem das características de tecnologias usadas pelo *big data*, métodos de análise, limitações dos sistemas de processamento de dados, dificuldade de compreensão por membros da organização, tomada de decisão de quais dados deve ser gerados e coletados, questões de privacidade e éticas em relação a informações adquiridas (SIVARAJAH et al., 2017; MARR, 2015a; WU, et al., 2013).

Com base no ciclo de vida dos dados é possível agrupar os desafios do *big data* em 3 categorias (SIVARAJAH et al., 2017):

- Desafios de dados estão relacionados às características, por exemplo, volume, variedade, velocidade de geração, veracidade, volatilidade, qualidade, visualização e dogmatismo;
- Os desafios do processo estão relacionados a uma série de técnicas como: capturar, integrar e transformar dados, selecionar o modelo certo para análise, interpretar as informações e divulgar os resultados alcançados;
- Os desafios de gestão cobrem, por exemplo, privacidade, segurança, governança, propriedade dos dados, compartilhamento de informações e aspectos éticos a partir dos conhecimentos adquiridos.

A Figura 7 mostra a classificação dos desafios *big data*, conforme apresentado por SIVARAJAH et al., 2017.



Fonte: Adaptado de Sivarajah et al.,(2017)

Frente aos desafios, o uso de *big data* requer mudanças complexas das organizações, não apenas na infraestrutura de tecnologia da informação e formas de processar e aproveitar os dados, mas também em processos internos e políticas (MOUSANNIF et al., 2016; MARR, 2015a). Neste contexto, um conjunto de fases a serem seguidas para colocar em operação um projeto de *big data* e auxiliar a superar os desafios. A abordagem sugerida na Figura 8 consiste em três fases principais: elaboração da estratégia global, implantação do projeto de *big data* e pós-implantação (MOUSANNIF, et al. 2016).

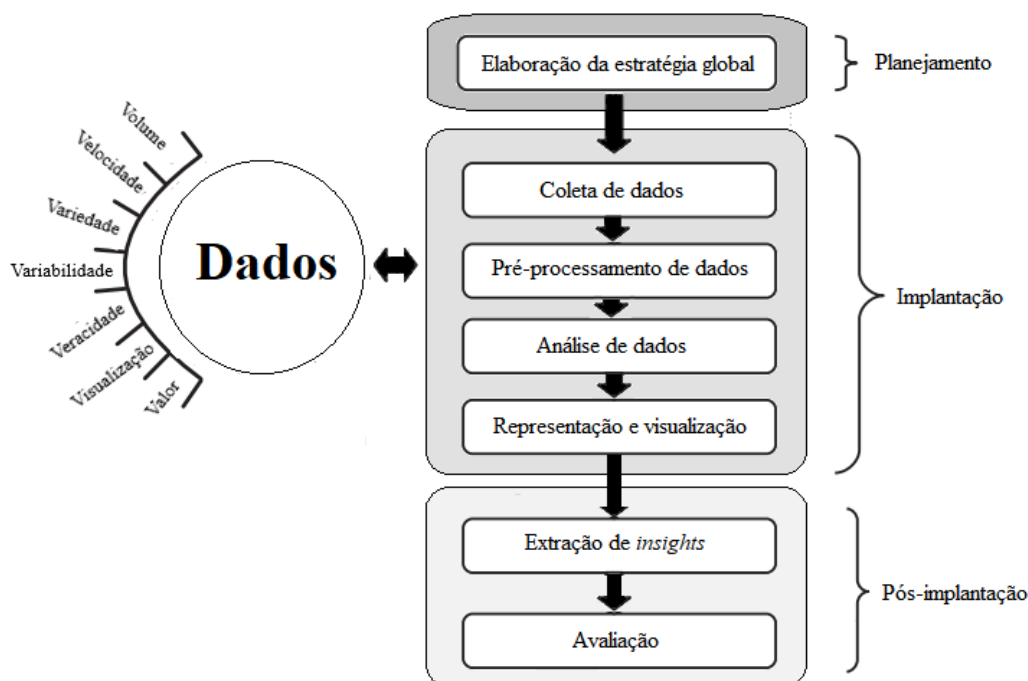
A fase de planejamento com a elaboração da estratégia global tem como função estabelecer os propósitos para adoção do projeto de *big data* e definir quais informações serão levantadas para tomada de decisão (MOUSANNIF, et al. 2016). Nesta primeira fase do projeto, também são analisadas as demandas por infraestrutura tecnológica para processamento de dados, melhor estrutura para armazenamento, meios de acesso, além de formas para manter seguras as informações adquiridas (MOUSANNIF, et al. 2016; MARR, 2015a).

O projeto de *big data* tem em sua fase de implantação primeiramente o objetivo definir os processos e formas para coleta de dados, frente às inúmeras fontes e formatos disponíveis. O segundo objetivo da fase de implantação, definido como pré-processamento de dados, trabalha os processos de manipulação, como a limpeza de valores incorretos ou

inconsistentes; integração de diferentes fontes (sites, bancos de dados, dispositivos de captura etc.); conversão de formatos; e discretizações de valores. Outro objetivo da fase de implantação é extrair valor do *big data*, por meio de um conjunto de análises avançadas de dados, como análises descritivas, preditivas e prescritivas. Por fim, o último passo desta fase é a representação e visualização dos resultados alcançados pelo conjunto de análises avançadas (MOUSANNIF, et al. 2016).

A terceira fase de um projetos de *big data*, definida como pós-implantação, é dividida em dois objetivos. O primeiro compreende a extração de *insights* a partir do grande volume de dados coletados e manipulados (MOUSANNIF, et al. 2016; MARR, 2015a), por meio de diferentes tipos de análises. Já o segundo objetivo desta fase trata da avaliação do processo, de forma a garantir que o sistema se mantenha atualizado frente às mudanças do ambiente da organização (MOUSANNIF, et al. 2016).

Figura 8 – Projeto de *big data*



Fonte: Mousannif (2016)

### 2.2.2 Big data analytics

BDA vem obtendo muita aceitação dos gestores ao ajudar entregar valor sustentável, melhorar o desempenho do negócio e proporcionar vantagem competitiva, por meio de novas maneiras de organizar e analisar processos, impulsionar a capacidade de operação, melhorar a



satisfação do cliente, reduzir custos e auxiliar na tomada de decisões mais adequadas (TALWAR; KAUR; WAMBA, 2021; KAMBLE; GUNASEKARAN, 2020; ANWAR; KHAN; SHAH, 2018). Estudos sobre o tema também apresentam uma tendência de crescimento para os próximos anos (ASSANDRE; MARTINS, 2020a; FURLAN; LAURINDO, 2017).

BDA é a combinação de processos de análises avançadas de dados no *big data* (KHANRA; DHIR; MÄNTYMÄKI, 2020; DEV et al., 2019; DAVENPORT, 2013a; RUSSOM, 2011). Também é definido como o conjunto de processos de coleta de dados, ferramentas analíticas, algoritmos de computador e técnicas para derivar percepções significativas e padrões dos grandes conjuntos de dados coletados em diferentes formatos e fontes (KAMBLE; GUNASEKARAN, 2020).

Em outra definição BDA é apresentado como as tecnologias de banco de dados e ferramentas de mineração de dados, acompanhadas de técnicas de análise avançadas, usadas para analisar dados complexos em grande escala com objetivo de aumentar o desempenho da empresa em várias dimensões. Nessa definição o armazenamento de dados, com alta tecnologia, seus procedimentos de gerenciamento, a capacidade de análise, e as tecnologias visuais de apresentação dos resultados alcançados, fazem parte do BDA (KWON, LEE e SHIN, 2014).

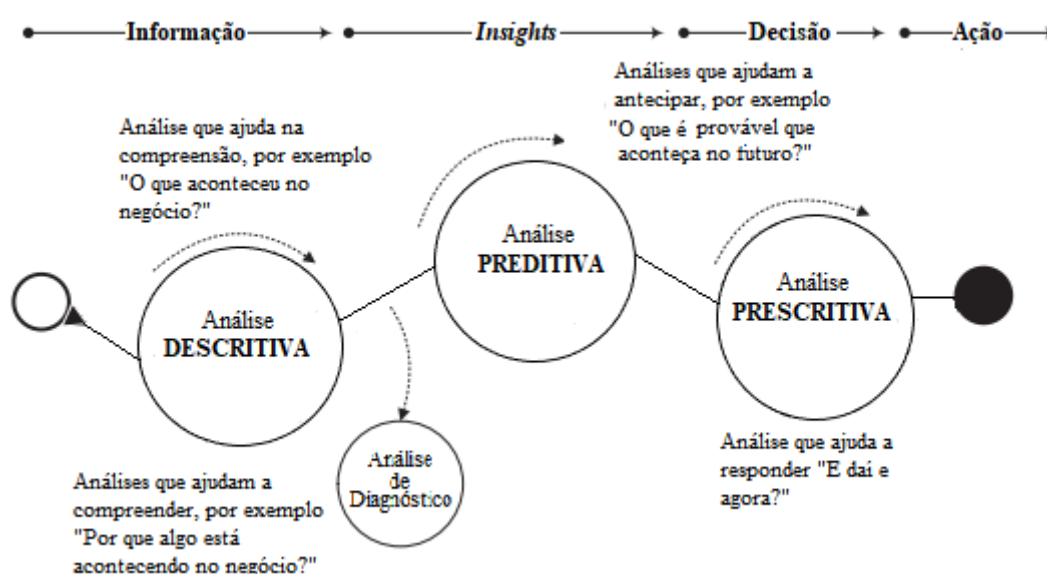
Com a visão do BDA ser um dos impulsionador da próxima onda de inovação econômica e gestão de desempenho organizacional (MAWED; AL-HAJJ, 2017), várias organizações têm investido em seu uso para abordar e melhorar o monitoramento, proporcionar experimentação, adotar novas análises de dados, viabilizar simulações e obter outros conhecimentos necessários para os negócios (SIVARAJAH et al., 2017; NAJAFABADI et al., 2015). Assim, uma arquitetura analítica é importante, uma vez que se refere às aplicações, infraestrutura, formas de análises e práticas de controle, para obter respostas rápidas (CARVALHO VICTORINO et al., 2017; LAMBA; DUBEY, 2015; FATTAH, 2014; WU, et al., 2013).

### **2.2.3 Formas de análise de grandes volumes de dados**

Existem diferentes formas de análise de uma grande massa de dados capturados, limpos, processados e armazenados pela organização (SIOW; TIROPANIS; HALL, 2018; MOUSANNIF, 2016; LAMBA; DUBEY, 2015). As análises descritiva, preditiva e prescritiva possibilitam obter informações e ter *insights*, para tomada de decisões e implantar novas

ações com diferentes objetivos (LEPENIOTI et al., 2020a; CAMM et al., 2020; LAMBA; DESHPANDE; SHARMA; PEDDOJU, 2019; DUBEY, 2015; DAVENPORT, 2013a; CHEN; CHIANG; STOREY, 2012). A Figura 9 apresenta estas três formas de análises que são as mais citadas, entre outras, pelos autores, bem como a análise de diagnóstico. Elas são apresentadas a seguir.

Figura 9 – Análise de grandes quantidades de dados



Fonte: adaptado de Mousannif (2016) e Davenport (2013a)

### 2.2.3.1 Análise descritiva

A análise descritiva usa informações extraídas de dados históricos brutos de fontes internas e externas da organização (CAMM et al., 2020; GHAVAMI, 2019; SOLTANPOO; SELLIS, 2016) para entender e apresentar o que aconteceu no passado (LEPENIOTI et al., 2020a; GHAVAMI, 2019; MOUSANNIF, 2016; SOLTANPOO; SELLIS, 2016; DAVENPORT, 2013a), desde minutos após o evento até períodos que compreendem muitos anos (MOUSANNIF, 2016). Para isso, reúne e analisa parâmetros relacionados às causas raízes do evento a ser eliminado ou mitigado, sendo capaz de detectar padrões que indicam um problema potencial ou uma oportunidade futura a ser aproveitada no negócio (LEPENIOTI et al., 2020a).

Este tipo de análise responde à pergunta “o que aconteceu?” (GHAVAMI, 2019; XU; DUAN, 2019; SOLTANPOOR; SELLIS, 2016), de forma a alertar, explorar e reportar a ocorrência de eventos (DAVENPORT; HARRIS, 2020), além proporcionar a generalizações

sobre uma população GHAVAMI, 2019). Como são geralmente análises simples, calculam algumas medidas de estatística básica como média, mediana, moda, desvio padrão, quartis, porcentagens e medição de frequência de eventos específicos (SIOW; TIROPANIS; HALL, 2018; SIVARAJAH et al., 2017; DAVENPORT, 2013a).

Contudo, a análise descritiva possui uma extensão chamada "análise de diagnóstico" que também relata o passado e envolve tanto a leitura passiva, quanto interpretação dos dados com objetivo de responder a perguntas como "por que isso aconteceu?" e ajudar a compreender as razões dos eventos ocorridos e os relacionamentos entre diferentes tipos de dados (SIVARAJAH et al., 2017; SOLTANPOO; SELLIS, 2016), por meio de um processo elaborado de mineração de dados (SIVARAJAH et al., 2017). A análise descritiva é a forma de análise mais usada pelo BDA, sendo aplicada normalmente em mecanismos de recomendação, relatórios de gestão de operações (SIVARAJAH et al., 2017; MOUSANNIF, 2016), resultados de unidades da organização em períodos de tempo, concentrações de vendas, classificações dos clientes, entre outras (DAVENPORT, 2013a). Dentre as técnicas usadas na análise descritiva para descrever eventos ocorridos e resultados, pode ser destacada:

- Consulta de dados: solicitação de informações com características e objetivos específicos em um banco de dados. Por exemplo, uma consulta ao banco de dados de uma fábrica de todos os registros de remessas para um distribuidor específico, para levantar informações descritivas como o número de remessas, data de inserção, envio etc.
- Estatísticas descritivas simples: usadas para localizar padrões ou relacionamentos em um grande banco de dados e muitas vezes são demonstradas por meio de ferramentas de visualização de dados como tabelas, gráficos e mapas em relatórios resumidos.
- *Dashboards*: como os relatórios resumidos, estas ferramentas, também usam coleções de tabelas, gráficos, mapas e estatísticas de resumo, porém atualizados à medida que novos dados se tornam disponíveis para o usuário (CAMM et al., 2020). Os *dashboards* são usados para ajudar a monitorar aspectos específicos do desempenho das empresas, além de facilitar a tomada de decisão (CAMM et al., 2020; FRANCESCHINI; GALETTO; MAISANO, 2019).

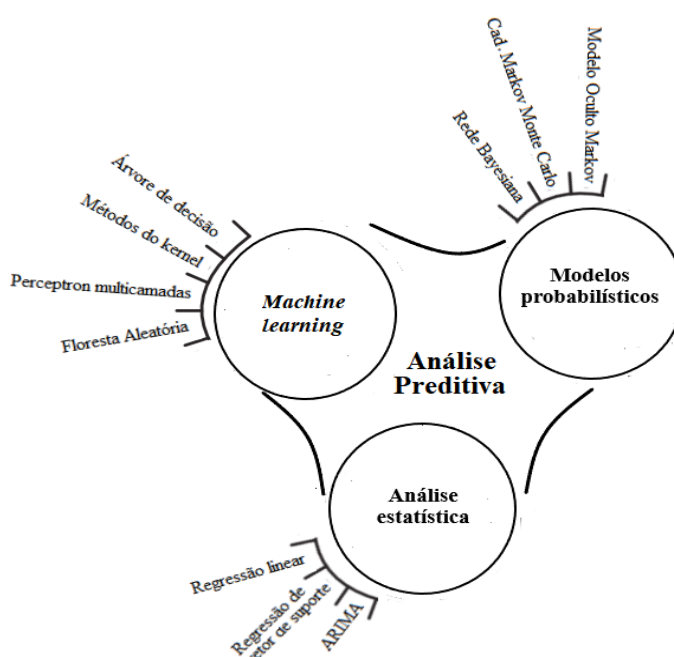
### 2.2.3.2 Análise preditiva

Este tipo de análise compreende uma variedade de técnicas que prevêm resultados futuros com base em dados históricos e atuais (LEPENIOTI et al., 2020a; CAMM et al., 2020; SIOW; TIROPANIS; HALL, 2018; GANDOMI; HAIDER, 2015; DAVENPORT, 2013b) sendo aplicada a quase todas as disciplinas. Em sua essência, a análise preditiva incorpora a saída da análise descritiva (SOLTANPOOR; SELLIS, 2016) e busca descobrir padrões e capturar relacionamentos em conjuntos de dados (GANDOMI; HAIDER, 2015) para prever um evento, bem como as razões pelas quais ele ocorrerá (LEPENIOTI et al., 2020a).

As técnicas de análise preditiva são subdivididas em dois grupos. Algumas técnicas, como médias móveis, tentam descobrir os padrões históricos no resultado e extrapolá-las para o futuro. Outras, como regressão linear, visam capturar as interdependências entre os resultados e variáveis explicativas, e explorá-los para obter previsões, podendo ser categorizadas em técnicas de regressão e técnicas de *machine learning*.

Os métodos de análise preditiva também podem ser classificados em três categorias, quando vistos como entradas necessárias para análises prescritivas (LEPENIOTI et al., 2020a). A Figura 10 apresenta alguns métodos levantados por Lepenioti et al (2020a), em sua revisão da literatura, e os classifica como modelos probabilísticos, *machine learning/data mining* e análise estatística.

Figura 10 – Métodos de análise preditiva



Fonte: adaptado de Lepenioti et al (2020a)

- Modelos probabilísticos representam as relações entre as causa e efeito, sendo usados para calcular a probabilidade de certos eventos ocorrerem. Para isso, monitoram dados reais em busca de eventos e pontos que conformam-se a um conjunto de regras definidas pela análise histórica (LEPENIOTI et al., 2020a).
- Os modelos baseados em machine *learning/data mining* usam algoritmos para inferência a partir do processamento de dados, sem o uso de instruções explícitas. Desta forma, é criado um modelo de dados de amostra, conhecido como "dados de treinamento", a fim de fazer previsões e descobrir padrões sem ser explicitamente programado para executar estas tarefas e proporcionar uma estrutura compreensível para uso posterior. Este tipo de análise envolve aspectos de gerenciamento de dados, pré-processamento, métricas de interesse, considerações de complexidade, pós-processamento de estruturas descobertas, visualização e atualização *online* (LEPENIOTI et al., 2020a).
- A análise estatística trata dos aspectos de dados e inclui o planejamento da coleta de dados em termos de *design* de pesquisas e estudos de experimentos, e resolve problemas relacionados a uma população estatística. Dentro da análise preditiva, a análise estatística é usada para extrair informações a partir de dados e usá-los para prever tendências e padrões de comportamento (LEPENIOTI et al., 2020a).

A evolução do *big data* tem facilitado a elaboração de análises preditivas nos últimos anos (BAG et al., 2021; ASSANDRE; MARTINS, 2020b). Contudo, como as técnicas de análise preditiva são baseadas principalmente em métodos estatísticos (LEPENIOTI et al., 2020a; CAMM et al., 2020; SIOW; TIROPANIS; HALL, 2018), vários fatores exigem uma abordagem adequada para o contexto de *big data*. Entre estes fatores a serem considerados pode ser destacado que métodos estatísticos convencionais são enraizados na significância estatística, em que uma pequena amostra é obtida a partir da população e o resultado é comparado com a chance de examinar o significado de um relacionamento particular e a conclusão é generalizada. Em contraste, as amostras de *big data* são enormes e representam a maioria ou toda a população. Como resultado, a noção de significância estatística não é relevante para *big data*. Outros fatores a serem considerados na análise preditiva quando aplicada no contexto de *big data* é quando a eficiência computacional, uma vez que muitos métodos convencionais para pequenas amostras não se adaptam a esta infraestrutura, além da heterogeneidade, do acúmulo de ruído, correlação espúria e a endogeneidade incidental (GANDOMI; HAIDER, 2015).

### 2.2.3.3 Análise prescritiva

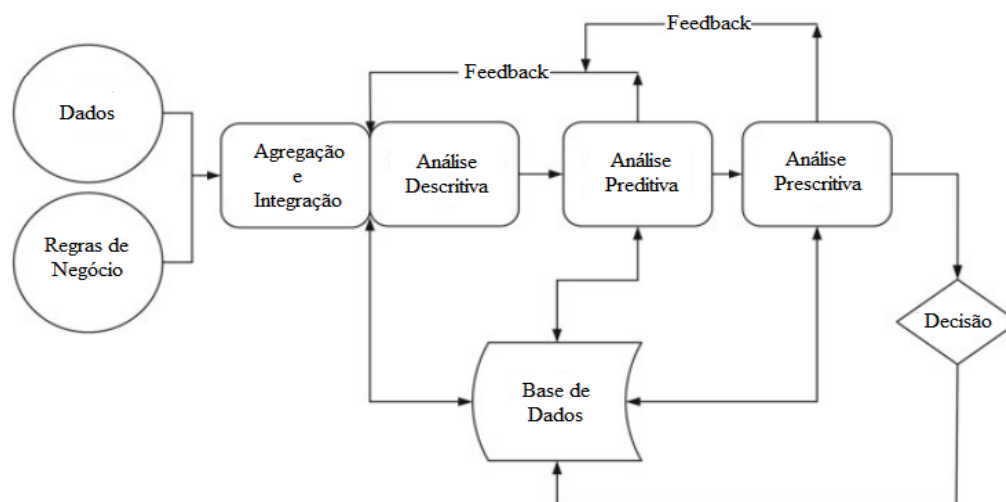
Análise prescritiva é relativamente nova, e ainda pouco usada pelas organizações (LEPENIOTI et al., 2020a; ASSANDRE; MARTINS, 2020b; MOUSANNIF, 2016; SOLTANPOO; SELLIS, 2016), porém vem atraindo cada vez mais o interesse (LEPENIOTI et al., 2020a), uma vez que tem como objetivo propor “o que deve ser feito” frente a um cenário (DAVENPORT; HARRIS, 2020; SIOW; TIROPANIS; HALL, 2018; MOUSANNIF, 2016; SOLTANPOO; SELLIS, 2016; DAVENPORT, 2013a).

Em sua essência, a análise prescritiva é uma análise preditiva que usa inteligência artificial, algoritmos de otimização e sistemas especialistas em um contexto probabilístico (LEPENIOTI et al., 2020a) para prescrever um ou mais cursos de ações e mostrar o provável resultado/influência de cada um em conformidade com o negócio e suas restrições (LEPENIOTI et al., 2020a; SOLTANPOO; SELLIS, 2016; MOUSANNIF, 2016). Assim, um método prescritivo inclui um modelo preditivo que gera decisões proativas com base nos resultados (LEPENIOTI et al., 2020a; MOUSANNIF, 2016), mas com mais dois componentes adicionados. No primeiro, o modelo deve apresentar um resultado acionável, com base em dados que os usuários podem tomar decisões. Em seguida, deve fornecer um sistema de feedback que seja capaz de compreender a relação complexa entre as ações do usuário e o resultado ajustado (SOLTANPOOR; SELLIS, 2016; MOUSANNIF, 2016).

Novas tecnologias de informação e comunicação como a Internet das coisas (IoT), *streaming* e operações de negócios orientadas por sensores reforçam as oportunidades que a análise prescritiva pode oferecer às empresas para tomada de decisões e alcançar o melhor curso de ação para o futuro (LEPENIOTI et al., 2020a). Este tipo de análise inclui tomada de decisão multicritério, otimização e simulação (WANG et al., 2016) e pode ser usada, por exemplo, para otimizar a programação de produção, o planejamento de estoque, recomendações e *design* de cadeia de suprimentos (XU; DUAN. 2019). No contexto da Indústria 4.0, a análise prescritiva inclui diferentes estratégias de otimização automática para cumprir metas determinadas em condições e demandas que mudam dinamicamente (XU; DUAN. 2019).

O processo de análise prescritiva está diretamente relacionado aos outros tipos de análises (LEPENIOTI et al., 2020a; DESHPANDE; SHARMA; PEDDOJU, 2019), uma vez que gera decisões proativas com base nos resultados das análises preditivas (LEPENIOTI et al., 2020a), a partir de dados históricos processados nas análises descritivas, como apresentado na Figura 11.

Figura 11 – Processo de análise prescritiva



Fonte: adaptado de Deshpande; Sharma; Peddoju (2019)

Na primeira fase deste processo os dados públicos ou privados, estruturados e não estruturados de diferentes formatos são coletados em diversas fontes considerando as várias regras e regulamentos de negócios. Em seguida, é realizada a agregação de dados, por meio de processos de mineração e integração, onde as informações são consolidadas para uso nas análises descritivas e formam a base para a análise preditiva. Frente aos parâmetros estabelecidos, a análise prescritiva usa os resultados da análise preditiva para sugerir as opções de decisão de forma a aproveitar oportunidades futuras ou mitigar riscos, além de ampliar junto com os recursos de *feedback*, sua base de dados para aprimorar o processo de prescrição (DESHPANDE; SHARMA; PEDDOJU, 2019).

#### 2.2.4 Técnicas de BDA

Além dos vários tipos de análises, existem diferentes técnicas de BDA a serem usadas, conforme as necessidades e objetivos da organização. Alguns exemplos das ferramentas analíticas são: o *text mining*, processamento de linguagem natural (RUSSOM, 2011), *social media analytics*, análise de imagens e vídeos (GANDOMI; HAIDER, 2015). Estas técnicas permitem, a partir de dados de diferentes formatos, massivos e brutos, estruturados, semi-estruturados e não estruturados (NAJAFABADI et al., 2015), obtidos interna e externamente às organizações, alcançar os benefícios do de BDA, uma vez que operacionalizam as análises descritivas, preditivas e prescritivas. Como estas técnicas estão além dos objetivos desta pesquisa, será apresentado a seguir apenas a *video analytics*.

### 2.2.4.1 *Video analytics*

Apesar de existir há várias décadas, a capacidade de perceber e reconhecer imagens por computador, às vezes rotulada como *computer vision* ou *machine vision*, alcançou avanços consideráveis na última década (DAVENPORT, 2018; WANG; LUO; JODOIN, 2017), viabilizando um maior uso das análises de vídeos. Desta forma, com milhões de horas de vídeos gravados diariamente no mundo, o *video analytics* (VA) ganhou destaque (WANG; LUO; JODOIN, 2017).

O VA, também conhecida como *video content analysis* (VCA), abrange o uso de *software* e *hardware* especializados, para analisar imagens capturadas e identificar automaticamente objetos, eventos, comportamentos ou atitudes específicas de uma ação, com objetivo de extrair informações significativas (TANWAR et al., 2019; TIROPANIS; HALL, 2018; GANDOMI; HAIDER, 2015; MARR, 2015a; SIOW; TIROPANIS; HALL, 2018). Embora já existam várias técnicas de processamento de vídeos armazenados ou gerados em tempo real, o VA ainda está em sua fase inicial comparado a outros tipos de mineração de dados, oferecendo muitos desafios e oportunidades (TANWAR et al., 2019; SIOW; TIROPANIS; HALL, 2018; GANDOMI; HAIDER, 2015; MARR, 2015a). As inúmeras aplicações de VA podem ser usadas para:

- Coletar informações demográficas de clientes como idade, sexo e características físicas;
- Contagem de pessoas na operação de um negócio;
- Medir o tempo que clientes permaneceram dentro de uma loja e qual funcionário fez o atendimento;
- Detectar padrões de movimentação de indivíduos, veículos, equipamentos etc.;
- Monitorar filas para processamento na operação em tempo real;
- Reconhecer o comportamento de grupos de pessoas em determinadas situações, atividades, locais e horários;
- Identificar oportunidades de vendas perdidas;
- Reconhecimento facial;
- Reconhecimento de defeitos de produtos em linhas de produção de manufatura;
- Acompanhamento de projetos de construção para comparação com prazos para conclusão frente ao projeto.



Em termos de arquitetura de sistema, existem duas abordagens para VA. A primeira consiste em um conjunto de recursos baseados em serviços *on-line*. A outra é baseada na borda da aplicação (CHOI, et al., 2020):

- Arquitetura baseada em serviços *on-line*: o vídeo capturado, por meio de câmera de vídeo ou outro *hardware* com esta capacidade, é enviado para servidores localizados em provedores de serviços, que realizam a centralização dos dados, o processamento e a análise. A abordagem baseada em serviços oferece economias de escala, facilita/elimina a manutenção, evita a aquisição de *hardware* e proporciona facilidades na escalabilidade de recursos. No entanto, a execução de inferência de aprendizagem profunda na nuvem, especialmente para análise de vídeo em tempo real, muitas vezes incorre em alto consumo de conexão, alta latência, problemas de confiabilidade e preocupações de privacidade. Frente às limitações de transferência, os vídeos são geralmente compactados, ocasionando muitas vezes a perda de qualidade. Em algumas aplicações, esta perda pode comprometer a análise das imagens e os resultados pretendidos (LIU; QI; BANERJEE, 2018);
- Arquitetura baseada em borda: nesta abordagem, as interpretações de imagem são realizadas na “borda” do sistema, ou seja, o processamento do vídeo é realizado localmente (na empresa, unidade de negócio, fábrica etc.), próximo a ocorrência do evento (TANWAR et al., 2019; LIU; QI; BANERJEE, 2018; GANDOMI; HAIDER, 2015). Assim, todo o conteúdo do *streaming* de vídeo está disponível para análise. No entanto, são mais caros de serem armazenados, exigem investimento em *hardware* e têm um poder de processamento em lote menor em comparação com os sistemas baseados em serviços na nuvem (GANDOMI; HAIDER, 2015; MOUSANNIF et al., 2016).

Contudo, este cenário começa a apresentar tendência de mudanças, pois apesar da economia de escala e facilidade de manutenção proporcionada pela abordagem baseada em serviços na nuvem (LI; OTA; DONG, 2018; LIU; QI; BANERJEE, 2018), o custo de transferência de grandes volumes dados que já era considerado caro (WU et al., 2013), passa a ser mais significativo quando cresce rapidamente. Outro fator que está contribuindo para esta mudança é a rápida evolução das tecnologias de inteligência artificial que viabilizam o processamento local (LI; OTA; DONG, 2018; LIU; QI; BANERJEE, 2018), com menor demanda de *hardware*.

### 2.2.5 Uso *deep learning* em BDA

Com origem na década de 1950, a inteligência artificial consiste na capacidade de sistemas de computador ou máquinas aprenderem de forma autônoma. Em sua forma mais básica, a inteligência artificial coleta dados, aplica algumas regras de cálculo (ou algoritmos) para os dados e, em seguida, faz decisões ou prevê resultados (MARR, 2019). Esta área da computação abrange diferentes técnicas, com aplicação nos mais variados campos (MARR, 2019; DIVYA; BHARGAVI; JYOTHI, 2018).

As técnicas de inteligência artificial fazem parte das tecnologias presentes na Indústria 4.0 que viabilizam sistemas de produção mais inteligentes e autônomos (TAMBARE et al., 2022). A medição de desempenho está entre as atividades com aplicações da inteligência artificial no âmbito da Indústria 4.0 (ASSANDRE; MARTINS, 2020a) e nos últimos anos passaram a serem utilizadas mais efetivamente nos SMDs (ASSANDRE; MARTINS, 2020a; SAHLIN; ANGELIS, 2019).

#### 2.2.5.1 *Machine learning*

Usada para identificar objetos, interpretar imagens, analisar vídeos, transcrever fala em texto, selecionar resultados de pesquisa relevantes, classificar diferentes tipos de comunicação, entre outras aplicações (LECUN; BENGIO; HINTON, 2015), a tecnologia de *machine learning* é um subcampo da área de inteligência artificial (LIU et al., 2020; SKANSI, 2018; DIVYA; BHARGAVI; JYOTHI, 2018; LECUN; BENGIO; HINTON, 2015) e estuda algoritmos inspirados na estrutura e funções do cérebro humano (DIVYA; BHARGAVI; JYOTHI, 2018).

Na área de BDA, *machine learning* é considerada uma combinação fundamental de ciência da computação, engenharia e estatística, que pode beneficiar qualquer campo que precise interpretar e agir sobre os dados (DIVYA; BHARGAVI; JYOTHI, 2018). Os algoritmos de *machine learning* podem ser divididos em duas categorias: aprendizagem supervisionada e aprendizagem não supervisionada. Assim, a partir de um conjunto de dados rotulados previamente definidos, o aprendizado supervisionado busca encontrar uma função que seja capaz de prever rótulos desconhecidos.

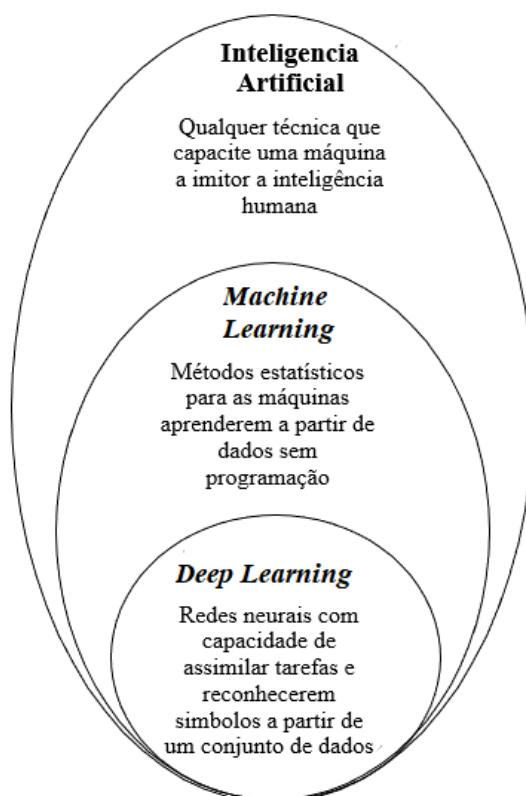
Na categoria de aprendizagem não-supervisionada, o conjunto de dados utilizado não possui nenhum tipo de rótulo, tendo como objetivo descobrir similaridades entre os objetos

analisados a fim de detectar similaridades e anomalias (DIVYA; BHARGAVI; JYOTHI, 2018; WANG; SNG, 2015).

As técnicas convencionais de *machine learning* são limitadas em sua capacidade de processar dados na forma bruta. Desta forma, exigem uma engenharia cuidadosa e considerável experiência do domínio para projetar um extrator de recursos que transforme os dados brutos (como os valores de pixel de uma imagem) em uma representação adequada para detectar ou classificar os padrões de entrada. Entretanto, cada vez mais, essas aplicações estão fazendo uso de uma forma de *machine learning* chamadas *deep learning* (LIU; QI; BANERJEE, 2018; LECUN; BENGIO, HINTON, 2015).

A Figura 12 ilustra a relação entre inteligência artificial, *machine learning* e *deep learning*.

Figura 12 – Relacionamento entre *Deep Learning* na IA



Fonte: elaborado pelo autor

### 2.2.5.2. *Deep learning* e BDA

*Deep learning* é uma sub-área de *machine learning* que usa redes neurais artificiais para solução de problemas complexos (LIU et al., 2020; SKANSI, 2018; JUUSO, 2018;

DRABAS; LEE, 2017; NAJAFABADI et al., 2015; LECUN; BENGIO; HINTON, 2015). As redes neurais artificiais são modelos computacionais desenvolvidos a partir da inspiração no cérebro humano enquanto recurso de aprendizado (DRABAS; LEE, 2017; LECUN; BENGIO; HINTON, 2015).

Nos últimos anos, cresceu o uso de *deep learning* e a tornou uma tecnologia importante em muitos campos da computação como reconhecimento de voz, visão computacional, processamento de linguagem natural e mineração de texto, além de ser uma ferramenta analítica para grandes volumes de dados (PATEL; THAKKAR, 2020; LI; OTA; DONG, 2018; JUUSO, 2018; POUYANFAR; CHEN, 2017).

Embora o *deep learning* possa ser aplicado para aprender a partir de dados rotulados, as grandes quantidades de dados não rotulados/não supervisionados, tornam este tipo de aprendizado de máquina interessante para extrair representações significativas (LIU et al., 2020; JUUSO, 2018; NAJAFABADI et al., 2015).

Por meio das técnicas de *deep learning*, os computadores aprendem com experiências e sem a necessidade de interferência humana para especificar formalmente todo o conhecimento necessário para compreender algo, na solução de uma ampla gama de problemas extremamente complexos (LIU et al., 2020; JUUSO, 2018; LI; OTA; DONG, 2018; POUYANFAR; CHEN, 2017; DRABAS; LEE, 2017; GOODFELLOW, 2016; LECUN; BENGIO; HINTON, 2015).

A exigência de pouca interferência manual para definição de parâmetros, a possibilidade de aproveitar facilmente o aumento na quantidade de dados disponíveis, e a capacidade de explorar dados brutos e não estruturados (LECUN; BENGIO; HINTON, 2015; NAJAFABADI et al., 2015) atraiu muito a atenção das empresas e meio acadêmico (POUYANFAR; CHEN, 2017; LIU; QI; BANERJEE, 2018), e tornou esta técnica uma ferramenta valiosa para BDA (LEPENIOTI et al., 2020b; NAJAFABADI et al., 2015). A capacidade de aprender a partir de grandes quantidades de dados permite que as técnicas de *deep learning* (LIU et al., 2020; ROH; HEO; WHANG, 2019; ZHAO et al., 2019; JUUSO, 2018) consigam alcançar resultados muito bons de extração de recursos na realização de tarefas discriminativas, representações e percepções significativas em padrões (LEPENIOTI et al., 2020b; DAVENPORT, 2018; NAJAFABADI et al., 2015). Desta forma, sendo viável para o BDA, principalmente, para tratar de questões relacionadas aos Vs de volume e variedade, entre os 5 do conceito de *big data*.

No entanto, há um trabalho considerável para explorar mais profundamente essas técnicas, uma vez que certas características associadas ao *big data* apresentam desafios para

modificar e adaptar seus dados para o *deep learning* (NAJAFABADI et al., 2015). Dentre os vários aspectos desafiadores para o uso de *deep learning* em BDA pode se destacar (NAJAFABADI et al., 2015):

- Adaptar o *deep learning* para lidar com dados de *streaming*, pois existe uma necessidade de algoritmos que possam lidar com grandes quantidades de dados de entrada contínua. Essa análise de dados é útil em tarefas de monitoramento, como detecção de fraude, tráfego de pessoas e veículos, funcionamento de máquinas, ações humanas etc.;
- Procurar alternativas que evitem que alguns algoritmos de *deep learning* se tornem proibitivamente caros em termos computacionais ao lidar com dados de alta dimensão e formatos, devido à lentidão do processo de aprendizagem, como uso de imagens de vídeo;
- Contornar problemas de tempo para treinar redes neurais de aprendizado profundo com muitos parâmetros (NAJAFABADI et al., 2015) e a necessidade de equipamentos com *Graphics Processing Unit* (GPU) - de alto desempenho, quando comparado com as técnicas de *machine learning* (PATEL; THAKKAR, 2020);
- Maior necessidade de uma estrutura de transmissão para transferência de dados coletados, tratados, armazenados e analisados;
- A privacidade das pessoas em situações onde existe o monitoramento por meio de sistemas com reconhecimento facial.

### **2.2.6 Vídeo analytics para SMDs com uso de *deep learning***

A visão computacional encontra várias dificuldades nos ambientes de operações das organizações, como a influência e irregularidades de iluminação, condições de fundo, reflexos, vibrações, variações de ângulo e posição de equipamentos (WÜRSCHINGER, et al., 2020). Contudo, nos últimos anos esta área aparece entre os avanços de TI em ambientes de operação, proporcionados pelas técnicas de *deep learning* (ORHEI et al., 2021; ZHANG A. et al., 2021; LIU et al., 2020; NEUPANE; SEOK, 2020; PATEL; THAKKAR, 2020; SHANAHAN; DAI, 2020; VOULODIMOS et al., 2018; DAVENPORT, 2018; POUYANFAR; CHEN, 2017), que se mostram promissoras na análise de vídeos em aplicações que antes não eram exploradas (ORHEI et al., 2021; AGHABABAEYAN; ABDELLATIF; BRIAND, 2021; LIU et al., 2020; ZHAO et al., 2019; JUUSO, 2018; LI;

OTA; DONG, 2018; LIU; QI; BANERJEE, 2018; WANG; SNG, 2015) e melhoram o processo de coleta de dados por meio de imagens.

Entretanto, este aumento do volume de entradas de dados, por meio de maiores oportunidades de coleta, torna o gerenciamento de dados cada vez mais difícil (FRANCESCHINI; GALETTO; MAISANO, 2007). Assim, as medidas de desempenho, que podem ser desenvolvidas a partir de novos tipos de dados, tem características diferentes das medidas tradicionais dos SMDs (KAMBLE, et al., 2020). Consequentemente estas diferenças também influenciam as características dos SMD, como a infraestrutura de apoio para coleta, manipulação e análise dos dados, além de processos do sistema.

Neste contexto, os próximos capítulos da presente tese abordam o desenvolvimento de um protótipo de sistemas de medição de desempenho, com uso de métodos e técnicas de BDA, *deep learning* e visão computacional para coleta, armazenagem, manipulação e análise de dados não estruturados de imagens de operações de fabricação, além da disseminação das informações e *insights* obtidos com estes recursos. Para isso são consideradas possíveis melhorias nas características dos SMDs, proporcionadas por este conjunto de tecnologias, e desafios a serem superados.

### 3 DELINEAMENTO DA PESQUISA

O conhecimento popular, às vezes denominado senso comum, não se distingue do conhecimento científico pela veracidade ou natureza do objeto conhecido, mas por meio da forma, método e instrumentos do "conhecer" (LAKATOS; MARCONI, 2003). Assim, para que o conhecimento científico gerado seja aceito, o processo de geração necessita seguir uma série de regras e procedimentos (LACERDA et al., 2013; FLEURY, 2010; KOTHARI, 2004).

Diante da importância do planejamento deste processo, este capítulo apresenta a concepção metodológica da pesquisa desenvolvida, além da abordagem adotada, método de pesquisa aplicado e a condução dos trabalhos.

#### 3.1 Concepção metodológica

A ciência caracteriza-se pela utilização de métodos científicos (KOTHARI, 2004; MARCONI; LAKATOS, 2003), sendo a cientificidade, o estilo de argumentação, a coerência categorial e a condição explicativa, as questões mais comprometedoras de uma tese e outros trabalhos científicos (DEMO, 2000 *apud* MARTINS, 2012). Não são sempre necessárias declarações, mas é importante deixar implicitamente claro que tipo de concepção metodológica está em jogo e onde o autor se coloca (MARTINS, 2012). Para definir entre as concepções metodológicas do indutivismo, falsificacionismo e programas de pesquisa, qual orientou o projeto, é importante considerar o objetivo proposto e o contexto onde está inserido.

O princípio básico do indutivismo é baseado na grande quantidade de informações obtidas por meio de observações. A partir de um conjunto particular de observações de determinado fenômeno de interesse, se passa para probabilidade de generalização, desde que satisfeitas as condições de um grande número de registros, as observações realizadas terem ampla variedade de condições, e nenhuma observação estar em conflito com a lei universal derivada. Com o conhecimento desta lei e teoria universal, é possível derivar consequências que permitem elaborar explicações e previsões, usando a dedução e caracterizar o processo de dedutivismo (MARTINS, 2012).

Em oposição ao indutivismo, o falsificacionismo defende um processo de investigação com uma proposta onde uma nova teoria consiste numa conjectura na forma de proposições que devem ser testadas. Se uma das proposições não superar os testes a qual é submetida, a

teoria estará falseada e caso supere estará provisoriamente corroborada (MARCONI; LAKATOS, 2003)

A concepção metodológica do programa de pesquisa de Lakatos é composta por uma heurística negativa e outra positiva. A heurística negativa testa um núcleo irreduzível que contém as suposições básicas subjacentes ao programa e um cinturão protetor de hipóteses auxiliares que o protege da falsificação. A heurística positiva estabelece como um programa de pesquisa pode ser desenvolvido e assim orienta modificações no cinturão protetor. No início do desenvolvimento de um programa de pesquisa a falsificação não tem papel importante até que o núcleo irreduzível e o cinturão protetor estejam bem definidos (MARTINS, 2012).

A falta de conhecimento estruturado sobre a utilização de BDA em SMD, identificada por estudos como de Mello, Leite e Martins (2014) e confirmada pela revisão bibliométrica de Assandre e Martins (2020), demonstram que o tema está em evolução, não sendo possível estabelecer uma hipótese falsificável para ser colocada à refutação.

A inviabilidade de generalização de conhecimento, a partir de problemas existentes nas organizações, que costumam ser específicos (LACERDA et al., 2013), combinada com o processo de evolução do tema, tornaria a concepção metodológica do Programa de Pesquisa de Lakatos com uma heurística positiva uma orientação indicada para pesquisa. Entretanto, com objetivo de prescrever soluções e métodos para resolver um determinado problema, melhorar sistemas ou mesmo projetar um novo artefato, o paradigma da *Design Science* vem se posicionando como uma nova alternativa para geração de conhecimento (GOECKS et al., 2021; DRESCH; LACERDA; ANTUNES, 2016; AKEN, 2004).

Neste contexto, o paradigma da *Design Science* se mostrou viável para orientação da pesquisa, uma vez que esta tinha como objeto desenvolver um protótipo de SMD utilizando BDA e *deep learning* na coleta, armazenagem e análise de dados não estruturados de vídeos e disseminação das informações levantadas, e desta forma contribuir para o aperfeiçoamento da prática das organizações.

### **3.2 Método de pesquisa**

O paradigma da *Design Science* não tem como objetivo descobrir leis naturais ou universais que explicam certos comportamentos dos objetos que estão sendo estudados, mas sim compreender o processo cognitivo pelo qual o *design* que os define foi desenvolvido (DRESCH; LACERDA; ANTUNES, 2015). *Design Science* é uma ciência que busca



desenvolver e projetar soluções para melhorar os sistemas existentes, resolver problemas ou criar novos artefatos que contribuam para um melhor desempenho da sociedade e organizações (AKEN, 2004), além de fomentar a produção de conhecimento científico na área que é aplicado (DRESCH; LACERDA; ANTUNES, 2015).

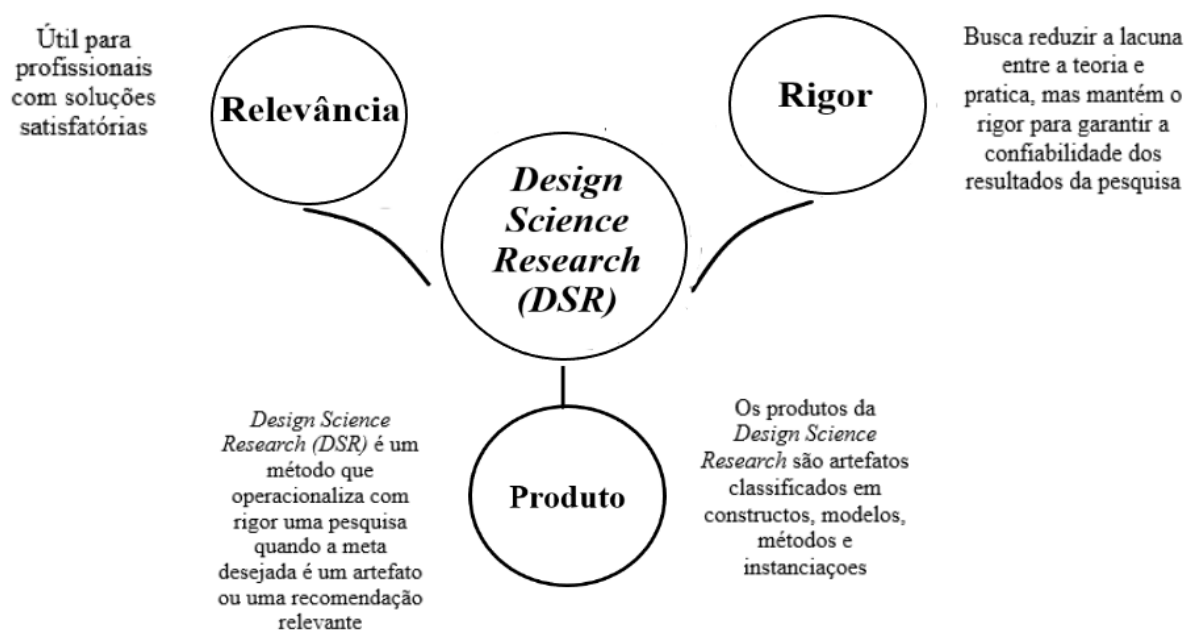
A produção de algoritmos computacionais, representações gráficas, protótipos, entre outros artefatos, e as soluções alcançadas, por meio da *Design Science*, não são apenas uma resposta pontual a certo problema em determinado contexto, mas conhecimento útil e possível de generalização para uma classe de problemas (AKEN, 2004; VENABLE, 2006; MARCH; SMITH, 1995), de forma a reduzir a lacuna existente entre teoria e prática (GOECKS et al., 2021; DRESCH; LACERDA; ANTUNES, 2016). Entretanto, a *Design Science* não deve ser vista como uma transposição do conhecimento científico para o ambiente das organizações (LACERDA et al., 2013; AKEN, 2004), mas uma forma de auxiliar a tarefa das escolas de engenharia de ensinar como usar este tipo de conhecimento para criar e projetar artefatos que tenham as propriedades desejadas e alcancem objetivos definidos (GOUVÊA DA COSTA; PINHEIRO DE LIMA, 2011; SIMON, 1996). Assim, além de rigorosa, para que seu conhecimento seja reconhecido pela comunidade acadêmica, a *Design Science* também tem como foco a relevância, ou seja, ser útil para profissionais da área, gerando soluções satisfatórias (AKEN, 2004).

Na condução de uma pesquisa no âmbito da *Design Science*, mais de um método científico pode ser usado, de acordo com a etapa que está sendo desenvolvida e a meta a ser alcançada (DRESCH; LACERDA; ANTUNES, 2015; LACERDA et al., 2013), como estudos de casos que avaliam um artefato já construído (KOTHARI, 2004) ou pesquisa-ação em que o desenvolvimento considera a interação e a coparticipação de membros das organizações. Contudo, sempre fazendo uso da *design science research* (DRESCH; LACERDA; ANTUNES, 2015; LACERDA et al., 2013).

O *design science research*, também conhecido como pesquisa construtiva, é um método que operacionaliza com rigor uma pesquisa quando a meta desejada é um artefato ou uma recomendação relevante, conforme apresentado na Figura 13. Ela é conduzida no ambiente acadêmico e/ou num contexto organizacional, de forma a produzir conhecimento científico prescritivo que envolve construções inovadoras, destinadas a solucionar problemas relevantes de um domínio (GOECKS et al., 2021; DRESCH; LACERDA; ANTUNES, 2015). Diferente de outros métodos de pesquisa, o método *design science research* busca produzir conhecimento na forma de uma receita ou de um *design* (DRESCH; LACERDA; ANTUNES, 2015; BAX, 2015), podendo ser usado para construir e avaliar artefatos que permitem a

transformação de situações e alterar suas condições para estados melhores ou desejáveis (MARCH; STOREY, 2008; MARCH; SMITH, 1995). Como em outras áreas a *design science research* tem potencial de desenvolver artefatos baseados em *big data*, *machine learning* etc., com objetivo de apoiar o sistema de decisão no contexto da Indústria 4.0 (GOECKS et al., 2021)

Figura 13 – *Design Science Research*



Fonte: adaptado de Dresch; Lacerda; Antunes (2015)

Neste contexto, a pesquisa utilizou somente o método o *design science research*, pois diante das características dos métodos de pesquisa, a utilização de estudo de caso se apresentou como inviável, uma vez que o objetivo do trabalho colocou o pesquisador em um papel ativo, e não apenas de avaliador de um artefato, já que buscava desenvolver um protótipo de sistema. Entretanto, apesar da atuação do pesquisador ser ativa sobre o objeto de estudo e o trabalho possuir foco em melhorias para as organizações, não se pretendeu ter a coparticipação de membros no projeto ou intervir nas operações, desta forma inviabilizando a utilização do método de pesquisa-ação.

### 3.3 Construção de artefatos por meio da *Design Science Research*

Cumprir o propósito ou adaptação de um artefato a um objetivo, com a aplicação do *design science research*, envolve uma relação entre três termos: o propósito ou objetivo, o

caráter do artefato e o ambiente em que atua. Assim, um artefato pode ser pensado como uma interface entre um ambiente “interno”, a substância e a organização do artefato em si, e um “ambiente externo”, o entorno em que opera. O artefato é desenvolvido para atingir metas em um ambiente externo específico, ou mesmo ser concretizado por meio de objetos artificiais que podem ser caracterizados em termos de objetivos, funções e adaptações (DRESCH; LACERDA; ANTUNES, 2015). Portanto, um artefato é a organização dos componentes do ambiente interno para atingir um objetivo específico no ambiente externo (SIMON, 1996), sendo desenvolvido com esta finalidade ou avaliado em outras situações como a operação em determinada organização (LACERDA et al., 2013). Os artefatos que são construídos ou avaliados desta forma, são classificados em *constructos*, modelos, métodos e instanciações (MARCH; SMITH, 1995), conforme as características apresentadas no Quadro 2.

Quadro 2 - Classificação de artefatos

<b>Constructos</b>	<i>Constructos</i> ou conceitos formam o vocabulário e um conjunto de símbolos de um domínio. Usados para descrever os problemas dentro do domínio e para especificar as respectivas soluções, definem os termos usados para descrever e pensar sobre as tarefas e podem ser extremamente valiosos para <i>designers</i> e pesquisadores.
<b>Modelos</b>	Conjunto de proposições ou declarações que expressam as relações entre os <i>constructos</i> . Em atividades de <i>design</i> , os modelos representam situações como problemas e soluções. Sendo visto como uma representação de como são as coisas no mundo real. Embora tenda a ser impreciso sobre detalhes, um modelo precisa sempre capturar a estrutura da realidade para ser uma representação útil. Exemplos: abstrações, declarações e representações.
<b>Métodos</b>	É um conjunto de passos como algoritmos ou orientações usados para executar uma tarefa. Métodos baseiam-se em um conjunto de <i>constructos</i> subjacentes (linguagem) e uma representação (modelo) em um espaço de solução. Os métodos podem ser ligados aos modelos, nos quais as etapas do método podem utilizar partes do modelo como uma entrada que o compõe. Além disso, os métodos são, muitas vezes, utilizados para traduzir um modelo ou representação em um curso para resolução de um problema.
<b>Instanciações</b>	Uma instanciação é a concretização de um artefato em seu ambiente. Instanciações operacionalizam <i>constructos</i> , modelos e métodos. No entanto, na prática pode preceder a articulação completa destes artefatos, demonstrando a viabilidade e a eficácia deles. Sendo possível afirmar que a instanciação do artefato consiste em um conjunto coerente de regras que orientam o uso de artefatos em um determinado ambiente real. Este ambiente real consiste nos limites da organização ou indústria.

Fonte: March e Smith (1995)

Um quinto tipo de artefato não apresentado na classificação de March e Smith (1995), mas apresentado por Dresch et al. (2015), são as contribuições teóricas que podem ser alcançadas por meio da aplicação de *design science research*. Esses artefatos são chamados de proposições de *design* e correspondem a um modelo genérico que pode ser usado para

desenvolver soluções para uma determinada classe de problemas (VAN AKEN, 2005).

Uma característica fundamental do método *design science research* está em ser orientado para resolução de problemas específicos e obter uma solução satisfatória para a situação mesmo que não seja a ideal. No entanto, as soluções geradas pela pesquisa devem ser passíveis de generalização para uma classe de problemas (DRESCH; LACERDA; ANTUNES, 2015; AKEN 2004), permitindo que outros pesquisadores e profissionais em várias situações usem o conhecimento gerado (VENABLE, 2006). Uma classe de problemas pode ser entendida como a organização de um conjunto de problemas, práticos ou teóricos, que contenha artefatos avaliados, ou não, úteis para a ação nas organizações (DRESCH, LACERDA; ANTUNES, 2015; LACERDA et al., 2013). A formação destas classes de problemas também pode ser induzida pela própria natureza dos artefatos desenvolvidos ou validados (DRESCH; LACERDA; ANTUNES, 2015).

### 3.4 Fase da pesquisa

Existem várias propostas para condução de *design science research* na literatura (LACERDA et al., 2013). O processo de pesquisa desta tese é estruturado em concordância com as fases do método preconizado por Dresch; Lacerda e Antunes (2013). A Figura 14 ilustra as fases planejadas e percorridas para conclusão desta pesquisa e destaca em quais delas estão presentes as fases de desenvolvimento do SMD para ter o protótipo desenvolvido e sua relação com as fases de um projeto de *big data*. Apesar das fases de identificação do problema; conscientização, revisão da literatura, identificação de artefatos e configuração das classes de problemas, e proposição do artefato, o processo de *design*, implantação e uso tem início apenas na fase de projeto do artefato.

A Tabela 3 relaciona as referências das teorias e trabalhos usados com as fases do método de pesquisa preconizado por Dresch; Lacerda e Antunes (2013), com exceção das fases 8, 9, 10 e 11. Estas fases apresentam o aprendizado alcançado com a construção e avaliação da instanciação, conclusões e limitações do trabalho, generalização para classes de problemas e comunicação dos resultados, e são atendidas por meio do desenvolvimento da tese e outros trabalhos a serem publicados. As relações entre as fases de um projeto de *big data*, as fases de construção de um SMD e as fases da pesquisa, por meio da *design science research*, preconizado por Dresch; Lacerda e Antunes (2013), são apresentadas na Figura 14.

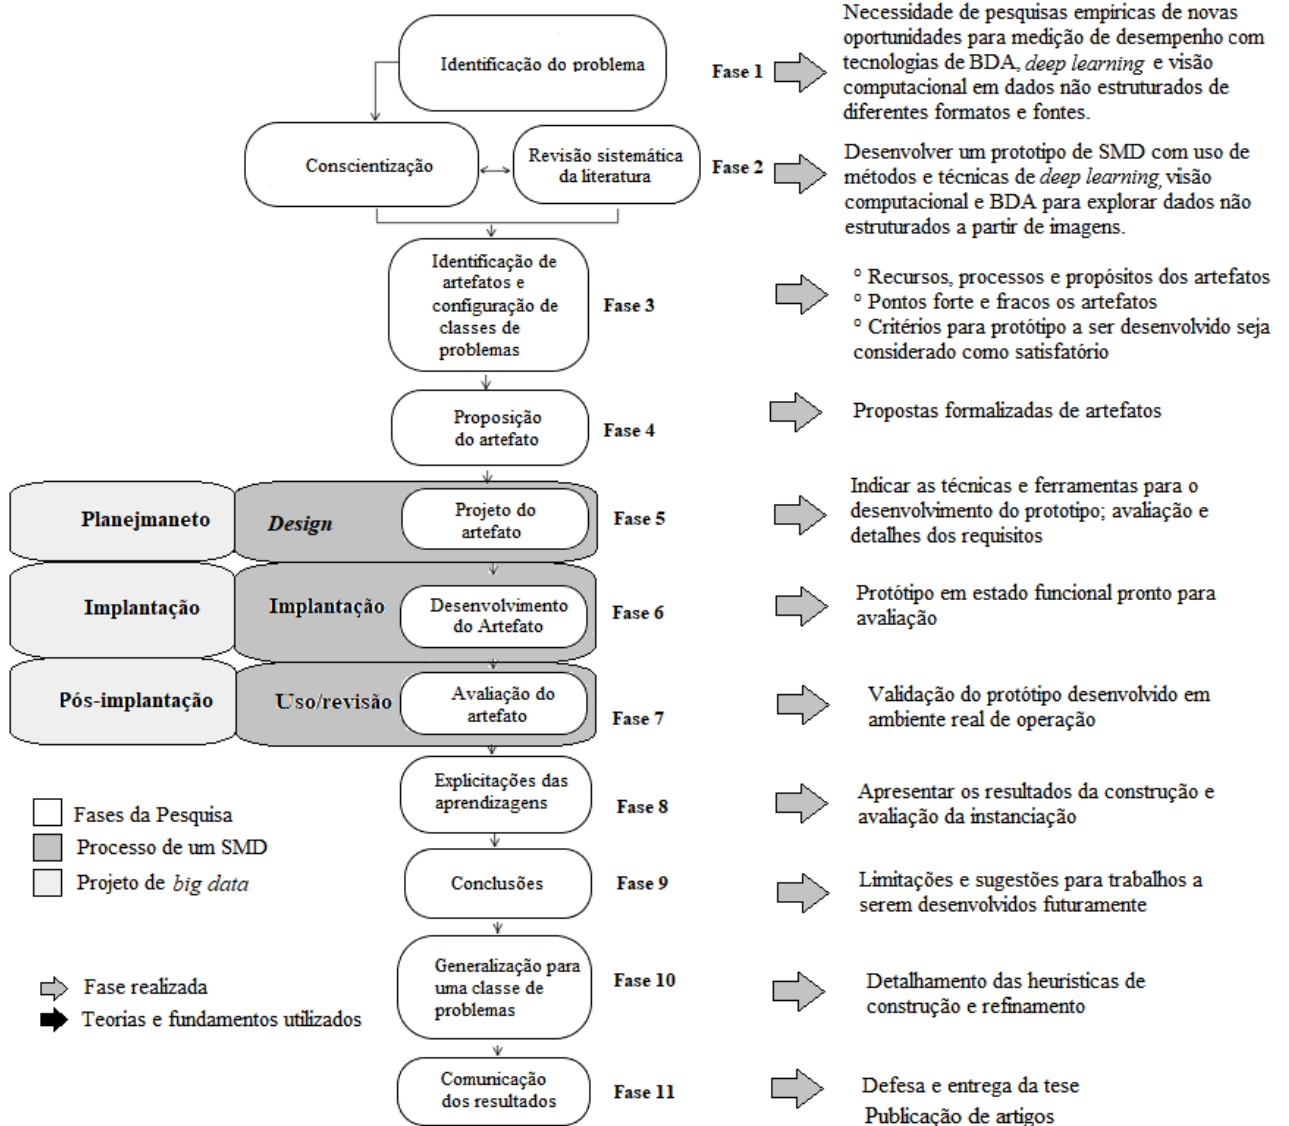
Tabela 3 - Relação entre referências teóricas e fases da pesquisa

<b>Fases</b>	<b>Autores</b>	
Fase 1: Identificação do problema	Orhei et al. (2021) Choi; Seo (2020) Assandre; Martins (2020) Kamble; Gunasekaran (2020) Patel; Thakkar (2020) Mahami et al. (2019)	Sahlin; Angelis (2019) Li; Ota; Dong (2018) Juuso (2018) Mawed; Al-Hajj (2017) Lima e Carpinetti (2010)
Fase 2: Conscientização e revisão sistemática da literatura	Yuan et al. (2021) Choi et al. (2020) Deshpande et al. (2020)	Hwang et al. (2017) Kim, et al. (2015)
Fase 3: Identificação de artefatos e configuração de classes de problemas	Choi et al. (2020) Yuan et al. (2021) Deshpande et al. (2020)	Hwang et al. (2017) Kim et al. (2015) Franco-Santos et al.(2007)
Fase 4: Proposição do artefato	Franco-Santos et al. (2007) Neely et al. (1995) Bourne et al. (2000) Sivarajah et al. (2017) Najafabadi et al. (2015) Kennerley; Neely (2002b) Martins et al. (2014)	Rouse; Putterill (2003) Kamble; Gunasekaran (2020) Al-Sarmi; Al-Hemyari (2014) Al-turki; Duffuaa (2003) Globerson (1985) ISO 22400 Revisão da literatura
Fase 5: Projeto do artefato	Zhang A. et al. (2021) Gupta; Sharma (2021) Lepeniotti et al. (2020a) Camm et Al. (2020) Staegemann, Volk; Nahhas (2019) Gulzar, Mardani, Musuvathi (2019) Franceschini; Galetto; Maisano (2018) Voulodimos et al. (2018) Guedes (2018) Hwang et al. (2017) Sivarajah et al. (2017) Mousannif, et al. (2016)	Soltanpoo; Sellis (2016) Najafabadi et al. (2015) Al-Sarmi; Al-Hemyari (2014) Nidhra; Dondeti (2012) Reno (2011) Klein (2011) Al-Turki; Duffuaa (2003) Rouse; Putterill (2003) Freeman (2002) ISO 22400 Revisão da literatura
Fase 6: Desenvolvimento do artefato	Suraya; Sholeh (2022) Belov; Tatarintsev; Nikulchev (2021) Choi, et al. (2020) Camm et al. 2020 Gulzar, Mardani, Musuvathi (2019) Barba-González, et al. (2019) Raschka; Mirjalili (2019) Voulodimos et al. (2018) Li; Ota; Dong (2018) Ferrer et al. (2018)	Hwang et al. (2017) Kerzner (2017) Abadi et al. (2016) Jääskeläinen; Roitto (2016) Bhosale; Patil (2015) Willoughby et al. (2010) Howse (2013) Pressman (2005) Revisão da literatura
Fase 7: Avaliação do artefato	Choi, et al. (2020) Camm et al. (2020)	Davenport (2013b) Franco-Santos et al. (2007)

	Lepeniotti et al. (2020a) Siow; Tiropanis; Hall (2018) Soltanpoor; Sellis (2016) Gandomi; Haider (2015)	Rouse; Putterill (2003) Neely (2002) Bourne et al. (2000)
Fase 8: Apresentação do aprendizado no desenvolvimento	Dresch; Lacerda e Antunes (2013) Van Aken et al. (2018)	
Fase 9: Conclusões	Dresch; Lacerda e Antunes (2013)	
Fase 10: Generalização para uma classe de problema	Dresch; Lacerda e Antunes (2013)	
Fase 11: Comunicação resultados	Dresch; Lacerda e Antunes (2013)	

Fonte: elaborado pelo autor

Figura 14 – Etapas previstas e realizadas da *Design Science Research* neste trabalho



Fonte: elaborada pelo autor

## 4 DESENVOLVIMENTO DO PROTÓTIPO

Este capítulo apresenta as fases executadas no desenvolvimento do protótipo de SMD, seguindo o método para construção de artefatos, preconizado por Dresch; Lacerda e Antunes (2013).

### 4.1 Identificação do problema

Conforme proposta de Dresch; Lacerda e Antunes (2013), na primeira fase foi identificado, a partir da análise da produção científica feita por Assandre e Martins (2020b), a necessidade de pesquisas empíricas que estudem e façam a validação das novas oportunidades para medição de desempenho (KAMBLE; GUNASEKARAN, 2020; SAHLIN; ANGELIS, 2019; MAWED; AL-HAJJ, 2017; LIMA; CARPINETTI, 2010) com uso de BDA e dados não estruturados em diferentes formatos e fontes. Como o estudo da literatura sobre o tema, também demonstrou, uma tendência de evolução no uso de tecnologias de inteligência artificial para medição de desempenho (ASSANDRE; MARTINS, 2020a; SAHLIN; ANGELIS, 2019), principalmente voltadas à análise de dados não estruturados por meio de técnicas de *deep learning* (ASSANDRE; MARTINS, 2020a), e a utilização de imagem em atividades de produção estar presente em várias indústrias (CHOI; SEO, 2020; MAHAMI, et al., 2019; DESHPANDE, et al., 2020), foi possível identificar uma oportunidade para desenvolvimento da relação entre SMDs e BDA.

### 4.2 Conscientização

Após a definição do problema e identificação de oportunidades de melhorias nos SMD, o direcionamento da pesquisa seguiu para a fase 2. Esta fase de conscientização consistiu em compreender a problemática envolvida, e algumas vezes entender os problemas de uma perspectiva mais ampla (GOECKS et al., 2021). Desta forma, criando um contorno inicial do problema e suas fronteiras no ambiente externo (LACERDA et al., 2013), além de identificar quais objetivos ou metas são necessários para que o problema, transitoriamente, seja considerado satisfatoriamente resolvido. Neste contexto foi definida a produção de um artefato na forma de instanciação e estabelecido objetivo da pesquisa: **desenvolver um protótipo de sistema de medição de desempenho, com uso de métodos e técnicas de BDA e *deep learning* para explorar dados não estruturados a partir de imagens de vídeo.**

A conscientização também buscou compreender as possíveis funcionalidade do artefato, bem como o desempenho esperado e os respectivos requisitos de funcionamento (GOECKS et al., 2021; DRESCH, 2013). Para isso, usou uma revisão sistemática na literatura (LACERDA et al., 2013) com objetivo de estabelecer um quadro de soluções empíricas conhecidas (SILVA; MENEZES, 2005).

A revisão sistemática da literatura é imprescindível, pois permite ao pesquisador levantar o conhecimento existente, por meio de outros estudos que abordam o mesmo problema ou semelhantes (DRESCH; LACERDA; ANTUNES, 2015), além de uma melhor compreensão do que está sendo estudado (GOECKS et al., 2021; DRESCH, 2013) e garantir o ineditismo da pesquisa.

#### 4.2.1 Revisão sistemática da literatura

A consulta por artefatos desenvolvidos para problemas não necessariamente iguais ao objetivo da pesquisa, mas com algumas semelhanças, possibilitou que o protocolo apresentado no Quadro 3, não buscasse apenas trabalhos envolvendo visão computacional ou *deep learning*, mas também outras tecnologias que podem ser usadas em conjunto com as análises de BDA e com possibilidade de serem aplicadas no protótipo de SMD de forma viabilizar o uso de dados não estruturados.

A revisão sistemática da literatura, realizada em novembro de 2020, usou como banco de dados a base de trabalhos *Scopus*, uma vez que esta possui uma cobertura mais ampla (ZUPIC; ČATER, 2015), além de abranger mais de 20.000 periódicos revisados por pares e indexar documentos relevantes para a área de *big data* (SINGH et al., 2021; MISHRA et al., 2016).

Quadro 3 – Protocolo de coleta de dados para análise bibliométrica

Tipo de documento	<i>Articles, Articles in Press, Conference Paper, Proceedings Paper, Review, Book, Book Chapter</i>
Termos de pesquisa	Grupo 1: <i>performance measur*</i> ; <i>performance metric*</i> ; <i>key-performance indicator*</i> ; <i>measur* performance</i> ; <i>performance indicator*</i> ; <i>KPI*</i> , Grupo 2: <i>unstructured data</i> ; <i>big data</i> ; <i>deep learning</i> ; <i>machine learning</i> Grupo 3: <i>empirical</i> ; <i>prototype</i> ; <i>artifact</i>
Operadores booleanos	<i>AND</i> entre grupos e <i>OR</i> entre os termos de pesquisa



Base dados	<i>Scopus</i>
Áreas de pesquisa	<i>Engineering; Decision Sciences; Business, Management and Accounting; Economy and Social Sciences;</i>
Língua	Inglês
Ano de publicação	Sem restrição

Fonte: elaborado pelo autor

O protocolo de busca apresentou inicialmente 128 trabalhos, os quais foram filtrados a partir da leitura do título e resumo. Esta análise inicial resultou em apenas 31 documentos. Em seguida, foi realizada nestes trabalhos uma revisão bibliográfica sistemática com objetivo de localizar artefatos já desenvolvidos e com características para colaborar com os objetivos da pesquisa. O resultado da busca de artefatos com capacidade de solucionar o problema levantado durante a conscientização e trazer alternativas para o desenvolvimento de um protótipo de SMD com uso de métodos e técnicas de *deep learning* e BDA, aplicadas a dados não estruturados a partir de imagens, demonstrou várias sugestões na forma de modelos, instanciações e métodos, mas não possibilitou identificar soluções já desenvolvidas com estas técnicas.

Assim, entre os 31 trabalhos selecionados, por meio da revisão bibliográfica sistemática, apenas os artigos de Choi et al. (2020) e Yuan et al. (2021) foram analisados quanto às características dos artefatos. Contudo, a leitura destes 31 trabalhos possibilitou conhecer os tipos de artefatos pesquisados e desenvolvidos, as tecnologias usadas e seus objetivos nestas pesquisas empíricas sobre SMD.

O Quadro 4 apresenta o resultado da análise dos 16 artefatos localizados, por meio da análise dos 31 trabalhos selecionados. Estes artefatos são classificados de acordo com seu tipo e mostram uma predominância na elaboração de instanciações, seguida por artefatos desenvolvidos como modelos.

Quadro 4 – Artefatos analisados

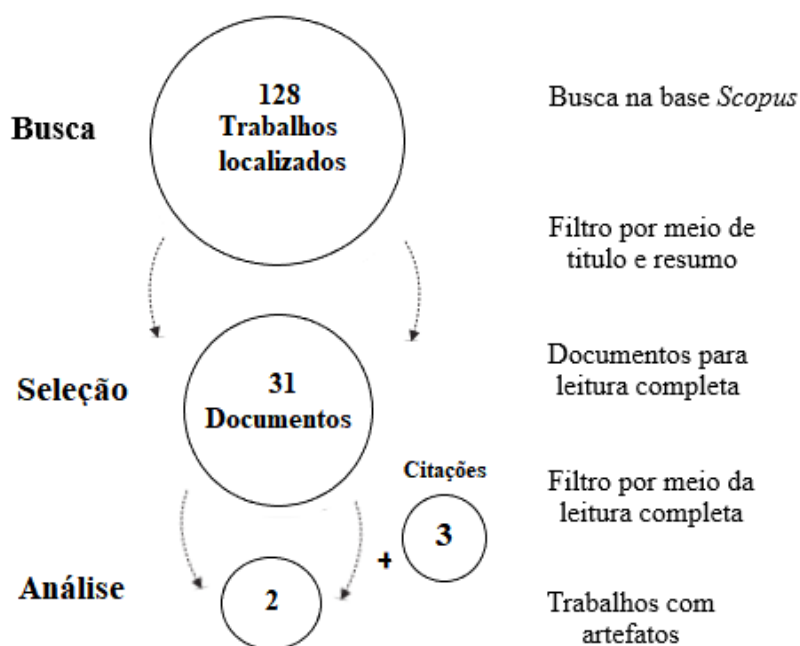
<b>Tipo</b>	<b>Objetivo</b>	<b>Tecnologias</b>	<b>Referência</b>
Modelos	Indicador de desempenho de clientes	Formulários <i>web</i>	Elkmash et al. (2021)
	Análise prescritiva em Kaizen	<i>Machine learning</i>	Thakur, et al. (2020)

	Análise preditiva de rentabilidade	<i>Deep learning</i>	Lado-Sestayo; Vivel-Búa (2019)
	Indicadores em tempo real	RFID	Bertolini, et al. (2017)
	Resiliência cadeias verdes	BDA	Rajesh (2016)
Métodos	Análise preditiva de vendas	<i>Deep learning</i>	Koehn, et al. (2020)
	Análise preditiva de demanda	<i>Deep learning</i>	Punia, et al. (2020)
Instanciação	Indicadores em tempo real	<i>Deep learning</i> /visão computacional	Choi, et al. (2020)
	Indicadores mercado de aviação	BDA	Holland, et al. (2020)
	Análise de sentimento	<i>Deep learning</i>	El-Alfy; Al-Azani (2020)
	Indicadores para protótipos	BDA	Mohamed et. al. (2019)
	Indicadores em tempo real	BDA	Agostino; Arnaboldi (2019)
	Indicadores em transporte	BDA	Shang et. al. (2017)
	Classificação de problemas	<i>Machine learning</i>	Sharma (2012)
	Indicadores em tempo	IoT	Hwang et al. (2017)
	Análise de sentimentos	<i>Deep learning</i> /visão computacional	Yuan, et al. (2021)

Fonte: elaborado pelo autor

Frente à falta de artefatos para medição de desempenho com uso da combinação de visão computacional e *deep learning*, foram acrescentados à análise os trabalhos de Deshpande et al. (2020), Kim, et al. (2015) e Hwang et al. (2017). Estas pesquisas foram localizadas a partir das citações dos trabalhos analisados durante a revisão bibliográfica sistemática e apesar de também não utilizarem a tecnologia de *deep learning*, o uso de visão computacional e IoT para medição de desempenho tornou seus artefatos uma fonte importante de informação. O processo geral de busca e seleção dos possíveis artefatos utilizados na pesquisa é apresentado na Figura 15.

Figura 15 – Seleção de artefatos para análise



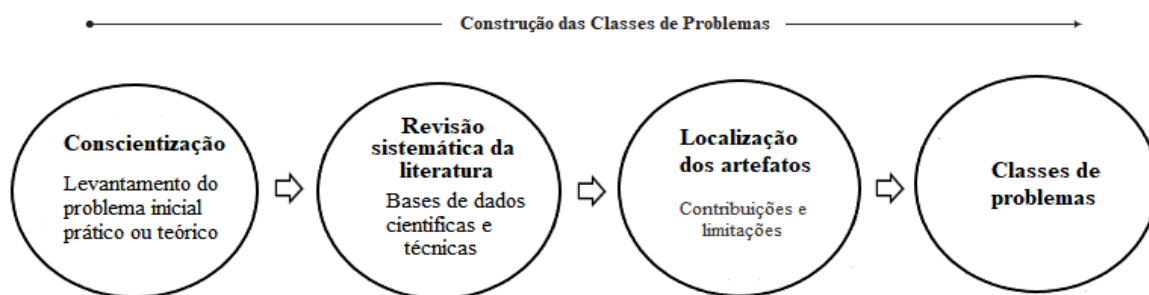
Fonte: elaborado pelo autor

### 4.3 Identificação dos artefatos e configuração de classes de problemas

A revisão sistemática da literatura, como realizada na fase 2, ajuda o pesquisador a evidenciar artefatos em potencial e classes que abordam problemas semelhantes a aquele a ser resolvido por meio de soluções consideradas satisfatórias. Também auxilia a identificar as melhores práticas e lições aprendidas, adquiridas e desenvolvidas por outros estudiosos e garantir que a pesquisa realizada seja uma contribuição relevante para uma classe de problemas e assertiva para propostas de desenvolvimento de novos artefatos (GOECKS et al., 2021; DRESCH; LACERDA; ANTUNES, 2015).

A fase 3 do método de pesquisa prevê a partir dos resultados alcançados, realizar uma análise estruturada que possibilita a visualização dos critérios utilizados em cada classe de problemas e artefatos existentes. Tal cuidado viabiliza analisar as contribuições e as limitações dos estudos dos artefatos selecionados (DRESCH, 2013), como apresentado na Figura 16.

Figura 16 – Classes de problemas



Fonte: elaborado pelo autor

#### 4.3.1 Análise dos artefatos selecionados

O primeiro artefato analisado neste processo foi desenvolvido por CHOI et al. (2020) e propõe um método para a medição objetiva do progresso do processo de produção de montagem sem julgamento dos gestores. Para tanto, uma forma para medição de desempenho automática foi definida e trabalhada na pesquisa. O artefato proposto tem entre suas características a coleta automática de dados dividida em duas formas.

Por meio de visão computacional, realidade aumentada (RA) e sensores em equipamentos com transmissão baseada em IoT, os dados são coletados automaticamente a partir de marcadores fixados nas peças que compõem os conjuntos em montagem e identificados nas imagens captadas. Após o tratamento das imagens e conversão dos dados, estes são comparados com os projetos de engenharia, por meio de uma verificação da posição de cada marcador identificado e a posição planejada para cada etapa do processo de montagem.

A segunda proposta de coleta automática de dados tem como foco as atividades de desempenho de trabalhos de soldagem. Neste contexto, foi apresentado um método baseado em aprendizado de máquina, usando dados coletados por sensores e IoT. Após a coleta automática dos dados, são utilizadas técnicas de inteligência artificial para classificação das operações executadas.

O artefato desenvolvido reduziu o tempo e a mão de obra necessária para a coleta de dados no ambiente de produção e possibilitou uma gestão de desempenho objetiva, em tempo real e comunicação mais eficiente de resultados. A instanciação foi validada em ambiente real com seu uso em uma planta de estaleiro de montagem de blocos de navios. Apesar da pesquisa usar no desenvolvimento do artefato técnicas de *deep learning* e visão computacional, estas não foram combinadas diretamente em uma medida de desempenho,

sendo usadas separadamente.

Yuan et al. (2021) investiga as relações dinâmicas entre as informações de sentimento presentes em postagens de mídia social e o desempenho de ações na bolsa de valores. Os métodos propostos extraíram o sentimento das modalidades de postagens verbais e visuais de mídias sociais, com a apresentação de implicações teóricas e práticas. Para análise de texto, foi construído um novo léxico para calcular o sentimento embutido nas postagens escritas, e para a análise de sentimento em fotos foi explorada uma estrutura de *deep learning*.

A pesquisa revelou que o sentimento de ambas as modalidades têm impactos de curto e longo prazo sobre o volume de negócios, ao mesmo tempo que têm efeitos de curto prazo sobre o risco das ações. Neste contexto, as partes interessadas precisam acompanhar não apenas postagens de mídia social baseadas em texto, mas também informações pictóricas nas postagens, com a possibilidade de alavancar informações para apoiar outros serviços financeiros e evidências eficazes para previsões.

O artefato desenvolvido também possibilita detectar qualquer fenômeno anormal com antecedência e fazer estratégias correspondentes para melhor controle, apesar de não proporcionar o acompanhamento de tendências em tempo real. Yuan et al. (2021) usou a combinação de visão computacional e *deep learning*, porém sem considerar a infraestrutura de BDA e procedimentos automáticos.

Deshpande et al. (2020) desenvolveu uma instância de artefato na forma de kit de ferramentas “*plug and play*” para oferecer suporte às operações no chão de fábrica. O artefato desenvolvido foi projetado para adquirir e digitalizar dados de vários componentes de máquina legadas, como medidores, posições de discagem, nível de fluido, fixação de chaves seletoras, curso percorrido e outros instrumentos de controle do chão de fábrica. O sistema se apresenta não invasivo, ou seja, sem a necessidade de conexões físicas e/ou modificações internas nas máquinas legadas.

O artefato desenvolvido permite o monitoramento em tempo real de equipamentos não projetados para o contexto de fábricas conectadas ou Indústria 4.0. O *design* do artefato teve como condição o baixo custo de aquisição e manutenção, o que influenciou em sua arquitetura de processamento na ponta, uso de equipamentos já disponíveis no mercado e adoção de tecnologias *open source* de visão computacional. A validação da instância foi realizada em ambiente controlado pelos desenvolvedores, simulando um contexto de chão de fábrica. A pesquisa apresenta maior preocupação com a infraestrutura quando o artefato é analisado no contexto de medição de desempenho, principalmente na coleta e processamento de dados.

Kim et al. (2015) propôs um artefato na forma de instanciação baseado em visão

computacional para monitorar o andamento da montagem do bloco em uma fábrica. O artefato teve como exigência uma quantidade mínima de *hardware* e ser empregado sem alterar significativamente o processo de fabricação já existente. Neste contexto, o procedimento proposto para monitorar uma montagem, usa imagens geradas e processadas para extrair dados e comparar com um modelo *CAD - computer-aided design*, a fim de estimar o status atual do trabalho. Desta forma, o sistema de monitoramento baseado em visão é capaz de estimar o progresso atual da montagem do bloco de forma automática e eficiente e, portanto, pode agilizar o fluxo de informações do projeto e fornecer um cronograma de produção.

O artefato desenvolvido consiste em câmeras, estações de trabalho computacionais, *software* de processamento de imagem e gerenciamento de dados. A validação do artefato foi realizada com várias imagens adquiridas em um ambiente real de produção, especificamente na operação de montagem de blocos para máquinas que demonstrou a capacidade de estimar o progresso de forma automática e eficiente. Também foi possível agilizar o fluxo de informações do projeto, fornecendo um cronograma de produção ideal e melhoria do processo geral de construção de produção.

Hwang et al. (2017) desenvolveu um modelo e posteriormente uma instanciação de SMD com foco na gestão de produção, utilizando para isso os padrões ISA-95 e ISO-22400, que definem processos de fabricação e fórmulas de indicadores de desempenho, além da tecnologia de *Internet of Things*. Este artefato proporcionou o uso de *Overall Equipment Effectiveness* (OEE), um indicador utilizado na indústria para gerir a efetividade global de equipamentos, em tempo real.

Os cinco artefatos selecionados podem ser entendidos como SMD, uma vez que apresentam medidas de desempenho e infraestrutura de suporte. Estes elementos são considerados por Franco-Santos et al. (2007), como suficientes para caracterizar um SMD. Contudo com objetivo de identificar as contribuições e limitações dos artefatos, eles também foram analisados considerando os outros elementos de um SMD, apresentados por Franco-Santos et al. (2007). O Quadro 5 apresenta os principais aspectos identificados nos artefatos analisados. O Quadro 6 resume os recursos, processos e propósitos, dos artefatos analisados. Estas informações auxiliaram na detecção de aspectos importantes para o desenvolvimento do artefato objeto desta pesquisa, uma vez que os pontos fortes consolidam vantagens e os pontos fracos se tornam oportunidades de melhorias.

Quadro 5 – Aspectos identificados nos artefatos analisados

Artefato	Pontos Fortes	Pontos Fracos
Choi et al. (2020)	<ul style="list-style-type: none"> <li>● Análise com uso de tecnologia de inteligência artificial;</li> <li>● Solução de baixo custo de implantação;</li> <li>● Disponibilidade de informações em tempo real;</li> <li>● Manipulação de dados coletados na “borda” do sistema, permitindo um custo menor de infraestrutura de redes e processamento;</li> </ul>	<ul style="list-style-type: none"> <li>● Solução projetada para acompanhamento de processos de montagem;</li> <li>● Coleta de dados por posto operativo utiliza sensores instalados de forma evasiva nos equipamentos;</li> <li>● Não contempla acompanhamento de operações detalhadas com uso de visão computacional;</li> <li>● Os recursos de <i>deep learning</i> para reconhecimento de imagens não foram explorados;</li> <li>● Armazenamento sem uso de <i>big data</i>;</li> </ul>
Yuan et al. (2021)	<ul style="list-style-type: none"> <li>● Disponibilidade de informações para <i>stakeholders</i>;</li> <li>● Análise avançada de imagens com uso de tecnologia de inteligência artificial;</li> <li>● Baixo custo de implantação;</li> </ul>	<ul style="list-style-type: none"> <li>● Não foram desenvolvidos recursos para coleta de dados automatizada;</li> </ul>
Deshpande et al. (2020)	<ul style="list-style-type: none"> <li>● Coleta de dados automatizada;</li> <li>● Baixo custo de implantação e aquisição de recursos;</li> <li>● Tecnologia com potencial de ser utilizada em implantações da indústria 4.0;</li> <li>● Recurso que considera o parque industrial legado;</li> <li>● Pode ser implantado sem a necessidade de intervenções invasivas em equipamentos;</li> <li>● Dados gerados em formato padronizado;</li> <li>● Disponibilidade de informações em tempo real;</li> <li>● Uso de equipamentos padrão de mercado;</li> </ul>	<ul style="list-style-type: none"> <li>● Foco na coleta de dados de equipamentos;</li> <li>● Armazenamento sem uso de <i>big data</i>;</li> <li>● Os recursos de <i>deep learning</i> para reconhecimento de imagens não foram explorados;</li> </ul>
Kim et al. (2015)	<ul style="list-style-type: none"> <li>● Coleta de dados automatizada;</li> <li>● Baixo custo de implantação e aquisição de recursos;</li> <li>● Maior agilidade na disponibilidade de informações com potencial de serem ofertadas em tempo real;</li> </ul>	<ul style="list-style-type: none"> <li>● Armazenamento sem uso de <i>big data</i>;</li> <li>● Os recursos de <i>deep learning</i> para reconhecimento de imagens não foram explorados;</li> <li>● Solução projetada para acompanhamento de processos de montagem;</li> </ul>
Hwang et al. (2017)	<ul style="list-style-type: none"> <li>● Coleta de dados automatizada;</li> <li>● Maior agilidade na disponibilidade de informações com oferta em tempo real;</li> <li>● Apresentou modelo que pode ser usado como referência para pesquisa;</li> <li>● Uso do padrão ISO 22400;</li> </ul>	<ul style="list-style-type: none"> <li>● Armazenamento sem uso de <i>big data</i>;</li> </ul>

Fonte: elaborado pelo autor

Quadro 6 – Recursos, processos e propósitos, dos artefatos analisados

Elementos		Choi et al. (2020)	Yuan et al. (2021)	Deshpande et al. (2020)	Kim et al. (2015)	Hwang et al. (2017)	
Recursos	Medidas de desempenho	Quantitativas, não financeiras do progresso do processo de montagem e soldagem	Quantitativas de retorno Dimensão de Risco Volume	Quantitativas, não financeiras e operacionais de equipamentos	Quantitativas, não financeiras do progresso do processo de montagem	Quantitativas, não financeiras	
	Infraestrutura de apoio	Adquirir	Visão computacional e sensores de IoT	Disponíveis na internet	Visão computacional	Visão computacional	IoT - <i>Internet of Things</i>
		Armazenar		Banco de dados			Banco de dados Oracle
		Analisar	Uso de IA	<ul style="list-style-type: none"> <li>• Visão computacional</li> <li>• Análise de sentimentos</li> </ul>		Bibliotecas de visão computacional e CAD	
		Disseminar	Em tempo real			Mas rápida	
Processos	Desenvolver medidas	Medição do progresso do processo em tempo real	Análise de sentimentos de imagens	Desempenho de equipamentos		OEE com maior precisão	
	Seleção de medidas					ISO 22400	
	Coleta de dados	Automatizado		Automatizada	Automatizada	Automatizada	
	Manipulação de dados	Conversam de imagem em dados tabulados	Conversam de imagem em dados tabulados	Conversam de imagem em dados tabulados no padrão <i>MTCconnect</i>	Conversam de imagem em dados tabulados		
	Gestão da informação	Em tempo real		Em tempo real	Com maior velocidade	Em tempo real	



	<b>Avaliação e recompensa</b>					
	<b>Sistema para revisão</b>					
<b>Propósitos</b>	<b>Medir o desempenho</b>	Progresso do processo de produção	Ações	Equipamentos		Equipamentos
	<b>Gerir a estratégia</b>					Estratégia de produção
	<b>Comunicar</b>	Interna	Externa	Interna	Interna	Interna
	<b>Influenciar</b>					
	<b>Aprendizado</b>					

Fonte: elaborado pelo autor

### 4.3.2 Síntese dos artefatos estudados

Apesar das técnicas de *deep learning* se mostrarem muito promissoras no reconhecimento de vídeo (LI; OTA; DONG, 2018; LIU; QI; BANERJEE, 2018) e terem melhorado o desempenho dos sistemas de visão computacional nos últimos anos (LONG; HE; YAO, 2021; ZHANG A. et al., 2021; LIU et al., 2020; PATEL; THAKKAR, 2020; SHANAHAN; DAI, 2020), apenas um objeto de estudo utilizou tal tecnologia. Todavia, tal artefato conseguiu resultados satisfatórios que reforçaram a necessidade de estudar mais a combinação de *deep learning*, visão computacional e BDA para enriquecer os SMDs.

Convém mencionar que apesar de não utilizarem as técnicas de *deep learning*, os artefatos desenvolvidos com bibliotecas tradicionais de visão computacional apresentaram resultados satisfatórios na geração de dados a partir da coleta automática e conversão. A análise dos artefatos estudados também permitiu verificar que eles não foram desenvolvidos considerando os recursos, propósitos e processos dos SMDs, tendo foco principal na coleta de dados automática e manipulação de dados. Os artefatos também não utilizaram o conceito de *big data* para armazenagem e processamento de dados. Quatro das instanciações tiveram como preocupação a gestão da informação, esse foco proporcionou a medição de desempenho em tempo real ou com uma melhora no tempo para disponibilização de resultados, porém apenas informações operacionais.

Com exceção do artefato desenvolvido para análise de sentimentos, as outras instanciações apresentaram foco na medição de desempenho operacional, como situação de funcionamento de máquinas, acompanhamento de processo de fabricação, conversão de dados e comunicação interna. Em nenhum dos casos foi explorado os recursos das técnicas de *deep learning* que pode proporcionar novas medidas de desempenho como diferenciação de operações, uso de ferramentas, comportamentos dos trabalhadores em postos de trabalho etc., que antes eram inviáveis quando adotadas outras tecnologias como sensores ou RFID. Outra característica importante a ser observada nos artefatos estudados é o baixo custo de implantação, independente da solução adotada e do foco da medição de desempenho, sendo que na maior parte dos elementos analisados, foi verificado o uso de *software* livre.

Neste contexto, utilizar BDA em SMDs, combinando *deep learning* e técnicas de visão computacional para explorar a grande quantidade de imagens geradas pelas mais variadas plataformas (dados não estruturados), mostrou-se como uma alternativa viável de ser explorada no desenvolvimento de um protótipo de SMD, uma vez que não foram encontrados artefatos para aproveitar possíveis oportunidades. Consequentemente, este artefato pode

caracterizar uma nova classe de problema, quanto ao uso de visão computacional, *deep learning* e BDA em SMDs, além de contribuições na coleta, manipulação, armazenagem e análise de dados. Uma vez identificadas as soluções satisfatórias e os artefatos que podem auxiliar no processo para alcançá-las, é iniciada a fase seguinte da pesquisa, a proposição de artefatos a ser desenvolvido (DRESCH; LACERDA; ANTUNES, 2015).

#### **4.4 Proposição do protótipo de SMD com uso de *deep learning* e visão computacional**

A etapa de proposição aborda a visualização de possíveis artefatos genéricos para resolver uma classe de problema, no qual o pesquisador utiliza os conhecimentos obtidos nas fases anteriores da pesquisa e sua criatividade para propor os artefatos, considerando o contexto do problema, desempenho pretendido e viabilidade, entre outras características (DRESCH; LACERDA; ANTUNES, 2015), na busca por uma solução satisfatória (SIMON, 1996). A proposição do artefato desta tese procurou uma solução mais genérica possível com a combinação de técnicas BDA, *deep learning* e visão computacional para coleta, manipulação, armazenagem e análise de dados em SMD. Como SMD não são universais e precisam ser adaptados às circunstâncias às quais são usados e aos objetivos pretendidos (PAPULOVÁ et al., 2021; KAMBLE; GUNASEKARAN, 2020; FRANCO-SANTOS et al., 2007), o artefato desenvolvido nesta pesquisa teve apenas a função de exemplo de aplicação e definição dos recursos necessários.

Frente a proposta de desenvolver um protótipo genérico para sua classe de problema, os ambientes interno e externo em que os SMD operaram não foram contemplados. Assim, a fase de proposição não considerou como base uma organização específica e suas particularidades. A escolha da situação a ser alterada, também considerou a generalização do conhecimento, o uso de medidas de desempenho consolidadas com possibilidade de serem adaptadas às técnicas de *deep learning* e que os dados gerados pudessem ser usados em análises de BDA.

Assim, foram selecionadas para geração de dados e elaboração dos indicadores de desempenho algumas medidas conhecidas e já utilizadas com frequência em diferentes segmentos, além do acompanhamento do processo de produção como objeto de BDA. Da mesma forma que na fase anterior, os grupos de elementos dos SMD, organizados por Franco-Santos et al. (2007), foram usados para apresentar os requisitos de desempenho do artefato para uma solução ser considerada satisfatória.

Quadro 7 – Requisitos do artefato para uma solução satisfatória

Elementos		Requisitos	Referências	Objetivos específicos da tese
Recursos	Medidas de desempenho	Medidas de desempenho com uso de dados não estruturados a partir de imagens;	Orhei et al. (2021) Long; He; Yao (2021) Chollet (2021) Liu et al. (2020) Choi; Seo (2020) Zhao et al. (2019) Mahami et al. (2019) Ramis Ferrer, et al. (2018) Hwang et al. (2017) Najafabadi et al. (2015) Franco-Santos et al. (2012) Franco-Santos et al. (2007) Rouse, Putterill (2003)	Aprimorar o uso de medidas de desempenho, tendo como fonte, dados não estruturados de imagens;
	Infraestrutura de apoio	Adquirir	<ul style="list-style-type: none"> <li>• Visão computacional combinada com <i>deep learning</i> para interpretação das imagens e geração de dados a serem estruturados;</li> <li>• Equipamento para coleta de dados de baixo custo;</li> <li>• Coleta de dados automatizada;</li> <li>• <i>Softwares open source</i>;</li> </ul>	Definir uma infraestrutura para coleta, análise e armazenagem de dados a partir de imagens de vídeo com uso de <i>deep learning</i> ;
		Armazenar	<ul style="list-style-type: none"> <li>• Arquitetura de <i>big data</i> para armazenagem de dados coletados e manipulados;</li> <li>• Baixo custo de implantação e manutenção;</li> <li>• <i>Hardware</i> de baixo custo;</li> </ul>	
		Analisar	<ul style="list-style-type: none"> <li>• Análise descritiva;</li> <li>• Análise preditiva;</li> <li>• Baixo custo de uso;</li> </ul>	
			Orhei et al. (2021) Long; He; Yao (2021) Chollet (2021) Liu et al. (2020) Neupane; Seok (2020) Choi; Seo (2020) Tanwar et al. (2019) Li; Ota; Dong (2018) Liu; Qi; Banerjee (2018) Voulodimos et al. (2018) Davenport (2018) Skansi (2018) Divya et al. (2018) Sivarajah et al. (2017) Mousannif et al. (2016) Najafabadi et al. (2015) Gandomi; haider (2015)	

				Skansi (2018) Juuso (2018) Siow et al. (2018) Sivarajah et al. (2017) Mousannif (2016) Lamba; Dubey (2015) Lecun et al. (2015) Davenport (2013)	de técnicas de BDA e visão computacional
		<b>Disseminar</b>	Disponibilidade indicadores de desempenho pré definidos.	Franco-Santos et al. (2007) Nudurupati; Bititci (2005) Neely (1998)	Definir uma infraestrutura para coleta, análise e armazenagem de dados a partir de imagens de vídeo com uso de <i>deep learning</i> ;
<b>Processos</b>	<b>Desenvolver medidas</b>		Usar como fonte de dados não estruturados imagens de vídeo.	Orhei et al. (2021) Long; He; Yao (2021) Chollet (2021) Liu et al. (2020) Choi; Seo (2020) Zhao et al. (2019) Mahami et al. (2019) Deshpande et al. (2019) Davenport (2018) Ramis Ferrer, et al. (2018) Najafabadi et al. (2015) Franco-Santos et al. (2007) Rouse, Putterill (2003)	Aprimorar o uso de medidas de desempenho, tendo como fonte, dados não estruturados de imagens;
	<b>Seleção de medidas</b>				
	<b>Coleta de dados</b>		<ul style="list-style-type: none"> <li>• Coleta de dados automatizada com uso de visão computacional</li> <li>• Permitir várias instâncias simultâneas de medição;</li> </ul>	Lepeniotti et al. (2020a) Deshpande et al. (2019) Voulodimos et al (2018) Ramis Ferrer, et al. (2018) Najafabadi et al. (2015) Franco-Santos et al. (2007) Rouse, Putterill (2003)	Definir uma infraestrutura para coleta, análise e armazenagem de dados a partir de imagens de vídeo com uso de <i>deep learning</i> ;
	<b>Manipulação de dados</b>		<ul style="list-style-type: none"> <li>• Conversam de imagem em dados tabulados;</li> <li>• Processamento com <i>deep learning</i>;</li> </ul>		

	<b>Gestão da informação</b>	<ul style="list-style-type: none"> <li>• Disponibilizar os resultados das análises em tempo real para tomada de decisão em nível operacional e tático.</li> <li>• Uso de <i>software</i> livre;</li> <li>• Acesso por diferentes plataformas;</li> </ul>	<p>Franco-Santos et al. (2007)  Nudurupati; Bititci (2005)  Bourne et al. (2000)  Neely (1998)</p>	<p>Propor um painel de indicadores de desempenho considerando as características de dados coletados, armazenados, manipulados e analisados a partir de imagens e vídeos;</p>
<b>Propósitos</b>	<b>Medir o desempenho</b>	<p>Possibilidade de melhorias nos processos de coleta e interpretação de dados, além da criação de novas medidas de desempenho e análises preditivas..</p>	<p>Najafabadi et al. (2015)  Lohman; Fortuin; Wouters (2004)  Bourne et al. (2000)</p>	<p>Aprimorar o uso de medidas de desempenho, tendo como fonte, dados não estruturados de imagens;</p>

Fonte: elaborado pelo autor

Como na fase de conscientização da *design science research*, que a partir da compreensão do problema e possíveis oportunidades, foi definido o objetivo geral da tese, nesta fase da pesquisa foram identificados os objetivos específicos. Assim, o Quadro 7 também apresenta a relação entre cada um dos requisitos do protótipo com os objetivos específicos apresentados no capítulo 1 desta tese.

Além das características apresentadas no Quadro 7, também foram considerados na proposição do artefato os três níveis de análise de um SMD, descritos por Neely et al. (1995), o modelo de referência *Integral Framework for Performance Measurement*, apresentado por Rouse e Putterill (2003) e analisado por Klein (2011), o equilíbrio entre recursos para diagnóstico e uso interativo indicado por Franco-Santos, Lucianetti, Bourne (2012), e as orientações de Bourne et al. (2000) e Kamble e Gunasekaran (2020), além dos desafios para uso do *big data* agrupados por Sivarajah et al. (2017) e aspectos importantes no uso de *deep learning* em BDA destacados por Najafabadi et al. (2015). Também foram consideradas as propriedades essenciais para um bom SMD, segundo Kennerley e Neely (2002b), as características importantes para as medidas de desempenho (AL-SARMI; AL-HEMYARI, 2014; AL-TURKI; DUFFUAA, 2003; GLOBERSON, 1985) e os padrões *ISO 22400-Automation systems and integration—Key performance indicators (KPIs) for manufacturing operations management*.

O protótipo proposto teve como foco o nível das medidas de desempenho individuais e análises operacionais, ao considerar que cada atividade é uma unidade de trabalho ou tarefa, com um objetivo específico, conforme típicos modelos de produção, mas com a introdução do controle de processo de medição comparando atividades contra padrões ou normas de desempenho. Esta configuração é proposta pelo modelo de referência *Integral Framework for Performance Measurement* e contempla as recomendações para coleta, armazenagem, manipulação, análise e divulgação dos dados de Bourne et al. (2000), além de ser generalizável.

Este foco se justifica uma vez que a principal contribuição prática do protótipo está na coleta, manipulação, armazenagem e análise de dados não estruturados de imagem de forma automatizada. Além disso, como apresentado por Rouse e Putterill (2003), os processos podem ser vistos como uma coleção de atividades. A atenção para medidas de desempenho individuais também foi justificada pela visão que um SMD pode ser formado com uma lógica no agrupamento das medidas de desempenho (NEELY; GREGORY; PLATTS, 1995) e os dados coletados durante a medição serem usados em análises avançadas como as técnicas de BDA, uma vez que a estrutura organizacional não influencia a implantação da tecnologia

(WIECH et al., 2022)

Como fonte de informação para o desenvolvimento de medidas de desempenho, foram usados os padrões *ISO 22400-Automation systems and integration—Key performance indicators (KPIs) for manufacturing operations management*. Os padrões ISO 22400 definem KPIs para manufatura e gestão de operações e consistem na visão geral e conceitos básicos da estrutura de KPIs, além de oferecer definições claras para os cálculos, com a proposta de ser um conjunto genérico para apoiar diferentes tipos de indústrias de manufatura (TAMBARE et al., 2022; RAMIS FERRER, et al., 2018; ZHU, et al., 2018; HWANG et al., 2017; KANG, et al., 2016).

O uso de KPIs definidos nos padrões ISO 22400, nesta fase da pesquisa, substituiu a necessidade de seleção de medidas de desempenho alinhadas a estratégia da organização, pois Ramis Ferrer et al. (2018) prevêem em sua concepção, o envio de resultados apurados para o nível de planejamento de negócios e logística, e posterior utilização na tomada de decisão. Também corresponde ao processo de medição que compara atividades contra padrões ou normas de desempenho e controle em tempo real ou quase, do modelo de referência de SMD *Integral Framework for Performance Measurement*, além de ser um padrão aplicável na busca pela melhoria contínua de desempenho operacional na Indústria 4.0 (TAMBARE et al., 2022).

Os KPIs selecionados dentro do padrão ISO 22400 também pode ser considerado como base para o desenvolvimento de novas medidas de desempenho para acompanhar o progresso do processo de produção de operações (TAMBARE et al., 2022) como estação de trabalho, atendimento ao público, prestação de serviços etc., além de proporcionar informações em tempo real. Neste contexto, a proposta de protótipo contou com uma análise preditiva do processo de produção em andamento com uso dos dados coletados para 4 (quatro) KPIs referentes ao desempenho de equipamentos que Hwang et al. (2017) e Tambare et al. (2022) sugerem para ambientes de fábricas inteligentes: índice de qualidade; índice de disponibilidade; índice de eficiência; *Overall equipment effectiveness* (OEE).

Calcular esses KPIs, obriga o uso de outros indicadores, ou seja, tempo ocupado planejado, tempo real de produção, tempo de execução, quantidade produzida e conforme (HWANG et al., 2017), que também foram contemplados no artefato. Além da análise para previsão de encerramento e os KPIs selecionados, são propostas formas de visualização de desvios no processo de produção por meio de uma comparação com o planejado.



#### 4.5 Projeto do artefato

Após a proposta de artefatos ter sido devidamente formalizada na fase 4 do método de pesquisa *design science research*, a opção selecionada é desenhada na fase seguinte, conforme suas características já definidas. O pesquisador também considera quais soluções são aceitas como satisfatórias para o problema em estudo (VAN AKEN et al. 2018; DRESCH; LACERDA; ANTUNES, 2015) e os objetivos específicos da tese.

Nesta fase, também devem ser descritos todos os procedimentos que serão empregados, não apenas para a construção do artefato, mas também para a avaliação do desempenho esperado, após a conclusão do desenvolvimento. Assim, os requisitos de desempenho do artefato são avaliados para garantir que uma solução satisfatória tenha sido alcançada, além de assegurar o rigor da pesquisa (DRESCH; LACERDA; ANTUNES, 2015; DRESCH, 2013).

Como apresentado na Figura 13, esta fase de projeto do artefato na *design science research* corresponde a fase de *design* no processo de construção de um SMD e a implantação, quando comparado com as fases de um projeto de *big data*. Como em outras fases da pesquisa já apresentadas, foi usado no projeto do protótipo o conjunto de elementos proposto por Franco-Santos et al. (2007), junto com outras contribuições abordadas na revisão da literatura como o modelo de referência de SMDs, *Integral Framework for Performance Measurement* proposto por Rouse e Putterill (2003) e as orientações de Bourne et al. (2000), os desafios para uso do *big data* agrupados por Sivarajah et al. (2017), os aspectos importantes no uso de *deep learning* em BDA destacados por Najafabadi et al. (2015) e fases dos projetos de *big data* indicadas por Mousannif, et al. (2016).

O ponto de partida do projeto foi o propósito do SMD de medir o desempenho com uso de dados não estruturados a partir de imagens, além da fase de planejamento para o uso de *big data* apresentada por Mousannif et al. (2016). Desta forma, foram definidos os recursos necessários e essenciais para o SMD, divididos entre medidas de desempenho e infraestrutura, e processos. As medidas de desempenho trabalhadas no protótipo compõem o *Overall Equipment Effectiveness*, conforme detalhado na Figura 17, e o acompanhamento do processo de fabricação uma análise preditiva de forma a prever possíveis atrasos. Também são apresentados a fundamentação teórica aplicada nos processos.

Figura 17 – Propósito do protótipo

Recursos		Processos	Fundamentação
Medidas de Desempenho	Infraestrutura		
Disponibilidade (Dis) $Dis = \frac{\text{tempo de produção}}{\text{tempo de prod.} + \text{paradas}}$	<b>Adquirir</b> Imagens capturadas CAM Visão Computacional Deep Learning Video analytics	<b>Coleta</b> A imagem é capturada por CAM e transmitida a uma estação de trabalho para interpretação utilizando Deep Learnig	2.2.1 Desafios de uso do <i>big data</i> 2.2.4 <i>Video analytics</i> 2.2.5 Uso <i>deep learning</i> em BDA 2.2.6 VA para SMD com uso de <i>deep learning</i>
	<b>Armazenar</b> Distribuida Plataforma Hadoop	<b>Manipulação</b> As imagens interpretadas são convertidas para dados estruturados e armazenados em servidores Hadoop	2.1.5 Design dos SMD 2.2 <i>Big data</i> 2.2.1 Desafios de uso do <i>big data</i> 2.2.2 <i>Big data analytics</i>
	<b>Analisar</b> Calcular Dis	Calculado tempo de produção e tempo de paradas não planejadas	
Desempenho (Des) $Des = \frac{\text{tempo ideal}}{\text{tempo real}}$	<b>Adquirir</b> Imagens capturadas CAM Visão Computacional Deep Learning Video analytics	<b>Coleta</b> A imagem é capturada por CAM e transmitida a uma estação de trabalho para interpretação utilizando Deep Learnig	2.2.1 Desafios de uso do <i>big data</i> 2.2.4 <i>Video analytics</i> 2.2.5 Uso <i>deep learning</i> em BDA 2.2.6 VA para SMD com uso de <i>deep learning</i>
	<b>Armazenar</b> Distribuida Plataforma Hadoop	<b>Manipulação</b> As imagens interpretadas são convertidas para dados estruturados e armazenados em servidores Hadoop	2.1.5 Design dos SMD 2.2 <i>Big data</i> 2.2.1 Desafios de uso do <i>big data</i> 2.2.2 <i>Big data analytics</i>
	<b>Analisar</b> Calcula Des	Calculado tempo real, uma vez que o ideal será fornecido como parametro	
Qualidade (Qua) $Qua = \frac{qt.prod + refug + retra}{qt.prod}$	<b>Adquirir</b> Imagens capturadas CAM Visão Computacional Video analytics	<b>Coleta</b> Análise da imagem para contagem de produção e falhas	2.2.4 <i>Video analytics</i>
	<b>Armazenar</b> Distribuida Plataforma Hadoop	<b>Manipulação</b> As imagens interpretadas são convertidas para dados estruturados e armazenados em servidores Hadoop	2.1.5 Design dos SMD 2.2 <i>Big data</i> 2.2.1 Desafios de uso do <i>big data</i> 2.2.2 <i>Big data analytics</i>
	<b>Analisar</b> Calcular Qua	Somatoria qt.produzida, refugada e retrabalhada	
Overall Equipment Effectiveness (OEE) $OEE = Dis \times Des \times Qua$	<b>Adquirir</b> Dados obtidos na plataforma Hadoop (distribuidos)	<b>Coleta</b>	2.2.1 Desafios de uso do <i>big data</i> 2.2.4 <i>Video analytics</i> 2.2.5 Uso <i>deep learning</i> em BDA 2.2.6 VA para SMD com uso de <i>deep learning</i>
	<b>Armazenar</b> Distribuida Plataforma Hadoop	<b>Manipulação</b> Os dados estruturados são usados em análises descritivas e preditivas	2.1.5 Design dos SMD 2.2 <i>Big data</i> 2.2.1 Desafios de uso do <i>big data</i> 2.2.2 <i>Big data analytics</i>
	<b>Analisar</b> BDA	<b>Gestão</b> Os resultados das análises são disponibilizados por meios de Dashboard	2.1 Sistemas de medição de desempenho 2.1.5 <i>Design</i> dos SMD 2.1.6 Implantação do SMD 2.1.7 Uso e revisão do SMD 4.4 Proposição do protótipo de SMD
Comparação processo em andamento e padrões	<b>Armazenar</b> Distribuida Plataforma Hadoop	<b>Manipulação</b> Os dados estruturados são usados em análises descritivas e preditivas	2.1.3 Modelos de referência 2.1.3 IFPM 2.1.4 Processos de um SMD 2.1.5 Design dos SMD 2.2.2 <i>Big data analytics</i>
	<b>Analisar</b> BDA	<b>Gestão</b> Os resultados das análises são disponibilizados por meios de Dashboard	2.1.3 IFPM 2.2.2 <i>Big data analytics</i> 2.2.3 Análise preditiva

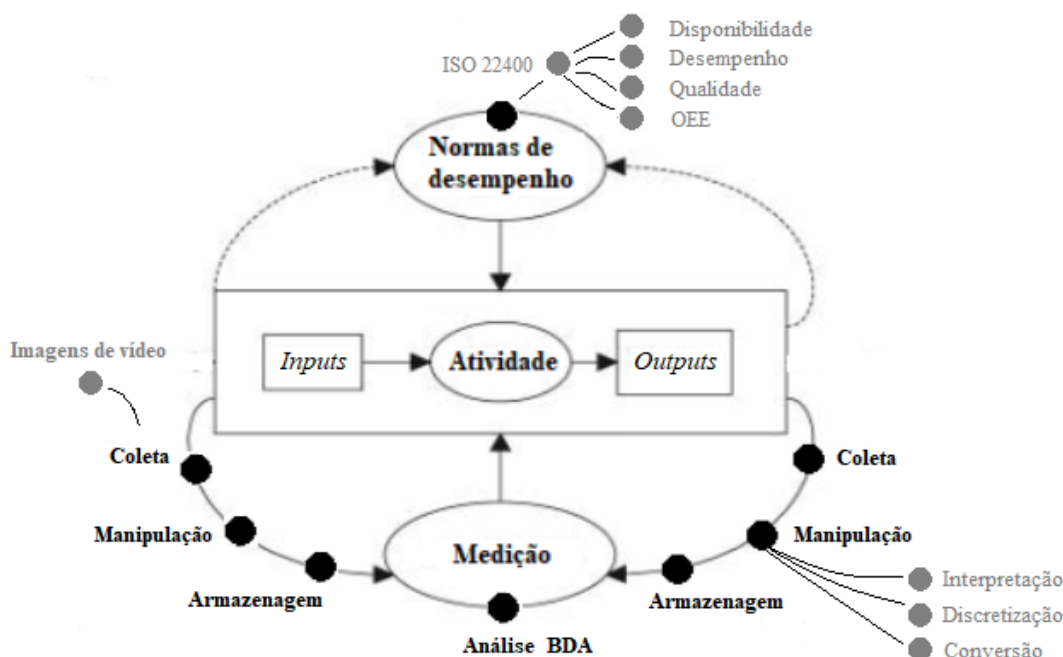
Fonte: elaborado pelo autor

#### 4.5.1 Levantamento de requisitos

Como um sistema a ser desenvolvido pode ter sua modelagem feita de diferentes perspectivas, conforme a necessidade de apresentação e decisões a serem tomadas (BOOCH; RUMBAUGH; JACOBSON, 2006), a Figura 18 apresenta a integração entre os recursos e processos do SMD necessários para operacionalizar a coleta, manipulação, armazenagem e análise dos dados, além da disseminação das informações. Esses elementos do SMD são aplicados ao modelo de transformação geral usado para descrever a natureza da produção, representando a parte inicial do modelo de referência *Integral Framework for Performance Measurement*. Assim a integração dos elementos do SMD no modelo *Integral Framework for Performance Measurement*, apresentada na Figura 18, representa uma perspectiva de uso do sistema e o comportamento planejado para o protótipo.

A combinação desta perspectiva do sistema com as informações geradas a partir dos propósitos do SMD, detalhadas na Figura 16, foi considerada como o levantamento de requisitos. Estas informações são previstas na primeira etapa de uso do padrão *Unified Modeling Language* (UML) para elaboração da estrutura do projeto do *software*.

Figura 18 - Levantamento de requisitos do SMD



Fonte: elaborado pelo autor

O padrão UML é uma linguagem visual para elaboração de estruturas de *software* orientados a objeto, sendo empregada para a visualização, especificação, construção e a documentação de artefatos complexos de qualquer abrangência (GUEDES, 2018; BOOCH; RUMBAUGH; JACOBSON, 2006) e amplamente adotada na engenharia de *software* (GUEDES, 2018; STÖRRLE, 2017; BOOCH; RUMBAUGH; JACOBSON, 2006; PRESSMAN, 2005). A UML propõe vários tipos de diagramas para analisar o sistema ou parte dele sob uma determinada óptica e descreve a arquitetura estática, sua interação com o ambiente interno e externo e ações durante uma análise temporal (GUEDES, 2018, PRESSMAN, 2005).

O padrão UML foi usado durante o processo de projeto do protótipo de SMD, com objetivo de considerar características internas e o contexto de operação, estabelecidos para esta fase do método de pesquisa *design science research*. Assim, no projeto do artefato proposto nesta pesquisa, os diagramas de casos de uso, diagrama de sequência, diagrama de comunicação e diagrama de máquina de estados foram adotados para detalhar o funcionamento geral do sistema

#### **4.5.2 Visão geral - Caso de uso**

Usado durante todo o processo de modelagem como base para outras representações, o diagrama de casos de uso apresenta uma visão geral e informal do sistema, por meio de uma linguagem simples e de fácil compreensão de suas funcionalidades oferecidas aos usuários, e sua elaboração corresponde às fases iniciais dos projetos de *software* (GUEDES, 2018; BOOCH; RUMBAUGH; JACOBSON, 2006). Desta forma, um caso de uso corresponde a uma sequência de transações executadas em um sistema, que produzem resultados para um ator específico que interage (BOOCH; RUMBAUGH; JACOBSON, 2006; PRESSMAN, 2005).

Para representação do protótipo de SMD proposto na pesquisa, foram feitos 6 diagramas de casos de uso. O primeiro diagrama representa as informações disponibilizadas de forma contínua, como qualidade, desempenho, disponibilidade do equipamento, OEE, principais operações, etc. por meio de um *dashboard*. O segundo caso de uso, disponibiliza as informações para representação de uma análise preditiva para previsão do encerramento do processo que está em andamento e acompanhado pela aplicação. Na terceira representação, o processo de treinamento dos modelos de *deep learning* para classificação das operações em execução é descrito Também com foco no treinamento de modelos de inteligência artificial, o

quarto diagrama de caso de uso apresenta o procedimento para esta tarefa com objetivo de disponibilizar modelos para previsão de encerramento do processo. O quinto diagrama de caso de uso representa a infraestrutura para BDA e mostra o processo para acesso aos dados armazenados na arquitetura de *big data*, por meio de ferramentas de análises de dados, não desenvolvidas na pesquisa. Por fim, o sexto diagrama de caso de uso apresenta uma visão geral do protótipo.

A representação gráfica do sistema, por meio do diagrama de casos de uso, se concentra em dois itens principais. O primeiro item indica os atores que representam alguns *hardware* especiais, *software*, recursos e usuários que interagem com o sistema. O segundo item corresponde às funções que representam aos serviços, tarefas ou funcionalidades (GUEDES, 2018).

#### 4.5.2.1 Diagrama de caso de uso do *dashboard*

A Figura 19 apresenta o diagrama de casos de uso do protótipo de SMD desenvolvido e o planejamento de seu comportamento quanto à disponibilidade de informações relacionadas ao OEE do equipamento e operações realizadas no processo produtivo acompanhado, por meio de um painel de indicadores. A representação possibilita identificar os atores envolvidos com estes elementos. Neste contexto, o primeiro ator identificado corresponde ao usuário tomador de decisão, tendo como interface de entrada para o sistema um painel de indicadores na forma de *dashboard*, considerando as características de dados coletados e armazenados. Este recurso é definido entre os requisitos do artefato a ser desenvolvido, além de ser um dos objetivos específicos da tese.

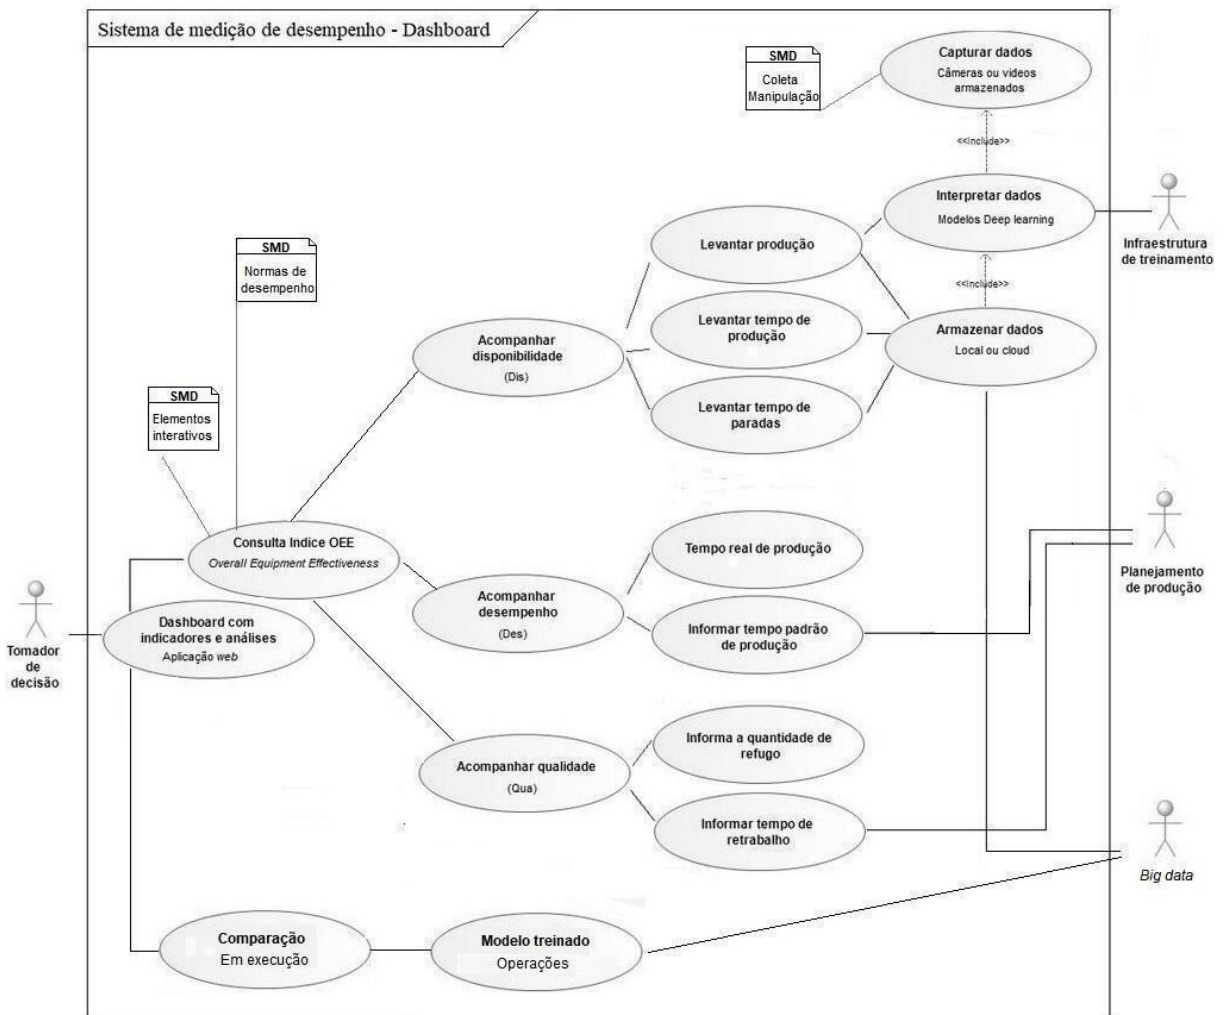
O segundo ator identificado por meio do caso de uso é a figura do planejamento de produção, na forma de provedor de informações necessárias para elaboração das medidas de desempenho. Na fase de projeto do protótipo, não foi considerada uma forma específica para este ator, uma vez que poderia ser uma integração com outro sistema, informações fornecidas por um usuário, banco de dados específico etc.

O outro ator envolvido com o sistema e identificado por meio do diagrama de casos de uso é a infraestrutura para treinamento de modelos de inteligência artificial com técnicas de *deep learning*, a qual disponibiliza recursos para classificação das imagens obtidas. Os treinamentos dos modelos de inteligência artificial podem ser realizados em *software as a service* (SAAS) ou equipamentos específicos para este fim, da mesma forma que a infraestrutura de *big data*. Assim, neste diagrama de estudo de caso aparece como um ator que

interage com o *dashboard*. Porém, em outros diagramas de caso de uso a infraestrutura para treinamento de modelos é considerada parte do sistema e recebe influência de atores diferentes.

A Figura 19 também apresenta a representação do procedimento de comparação entre o processo em andamento e o planejado. O recurso não fornece um resultado como as medidas de desempenho e a previsão de encerramento, porém tem como função apresentar, de forma gráfica, o histórico dos eventos identificados e conseqüentemente indicar desvios no processo. Desta forma, uma vez identificados os desvios, eles podem ter seu impacto acompanhado e analisado.

Figura 19 - Caso de uso *dashboard*



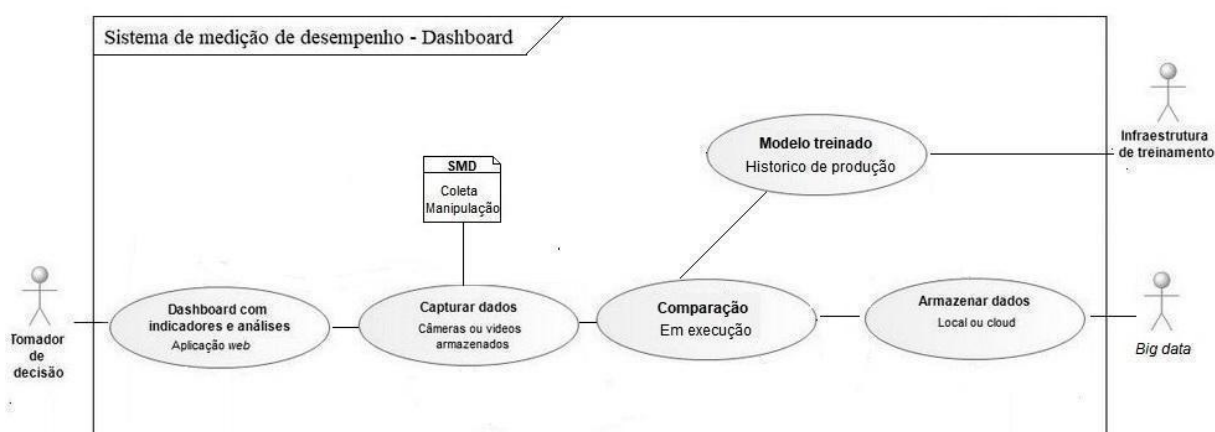
Fonte: elaborado pelo autor

#### 4.5.2.2 Diagrama de caso da análise preditiva de encerramento

A Figura 20 corresponde ao diagrama de casos de uso da análise preditiva para previsão de encerramento do processo. Da mesma forma que as medidas de desempenho relacionadas ao OEE do equipamento, a interface utilizada para esta análise é concretizada como um elemento do *dashboard*, previsto entre os requisitos do sistema. O recurso permite ao tomador de decisão, de forma gráfica, prever o encerramento das operações a partir de uma interpretação do processo de produção realizado até o momento da captura da imagem. Neste estudo de caso, o único ator externo ao sistema é o tomador de decisão, uma vez que a arquitetura de *big data* é usada apenas para treinamento dos modelos de *deep learning*.

A análise preditiva é realizada em momentos distintos, em que a imagem do processo de produção em andamento é classificada por meio de um modelo de *deep learning* previamente treinado. A previsão de encerramento do processo de produção tem como saída da análise realizada, pelo modelo de *deep learning*, a previsão de encerramento no prazo ou atrasado. Estes resultados também são armazenados na arquitetura de *big data*, de forma a proporcionar futuras consultas.

Figura 20 - Caso de uso da análise preditiva



Fonte: elaborado pelo autor

#### 4.5.2.3 Diagrama de caso de uso do treinamento de modelos para classificação

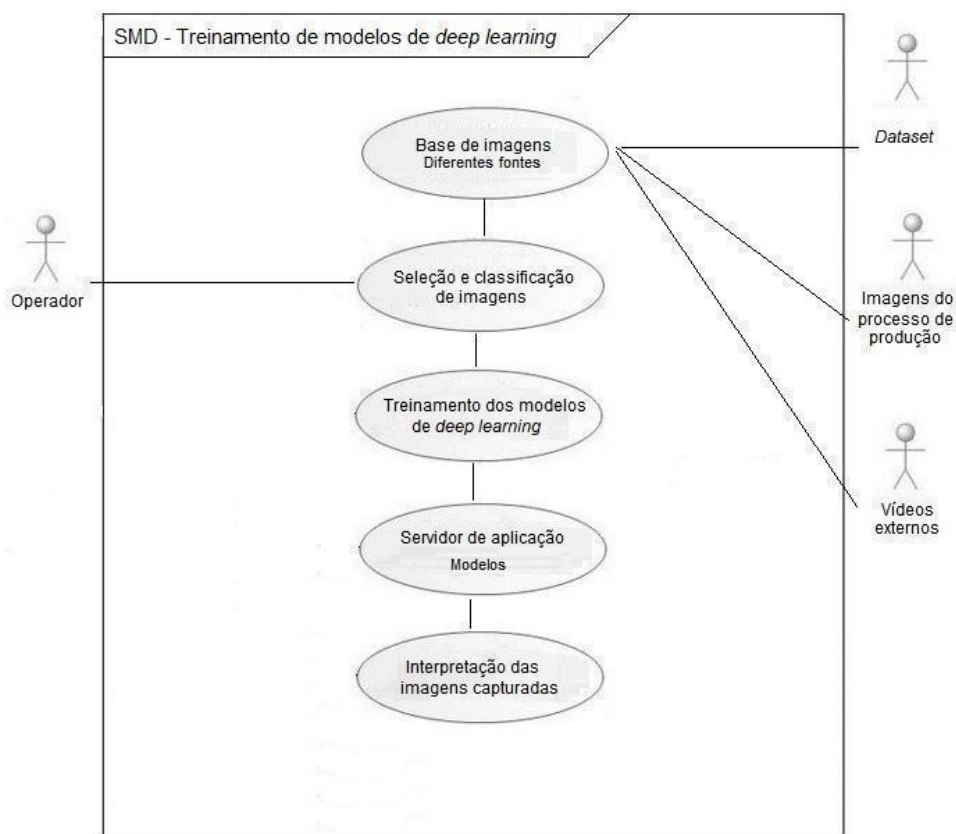
O diagrama de caso de uso apresentado na Figura 21 corresponde ao treinamento dos modelos de *deep learning* destinados à classificação de operações de produção. Como mencionado, o processo de treinamento de modelos de *deep learning* pode ser realizado em

uma infraestrutura planejada ou utilizar serviço de terceiros na forma de SAAS por meio da internet.

Para a representação do caso de uso, foi considerada a estrutura de treinamento dos modelos de *deep learning* com um sistema separado, em que todas as atividades são realizadas em uma mesma plataforma, porém separada dos outros elementos do protótipo. O diagrama de caso de uso permitiu identificar 4 atores externos. O primeiro ator representa o usuário como a função de selecionar e classificar as imagens para treinamento a partir de diferentes fontes.

Como cada fonte de imagens possui suas características e pode ser viabilizada de diferentes formas e envolver processos e usuários específicos, elas foram consideradas como atores externos. Assim, os outros 3 atores apresentados no diagrama de caso de uso correspondem aos processos de produção filmados, vídeos de fontes externas à organização e *datasets* criados/obtidos etc. Após o treinamento os modelos de *deep learning* são armazenados, por meio do servidor de aplicação e disponibilizado conforme a demanda de outros elementos do protótipo.

Figura 21 - Caso de uso do treinamento de modelos



Fonte: elaborado pelo autor

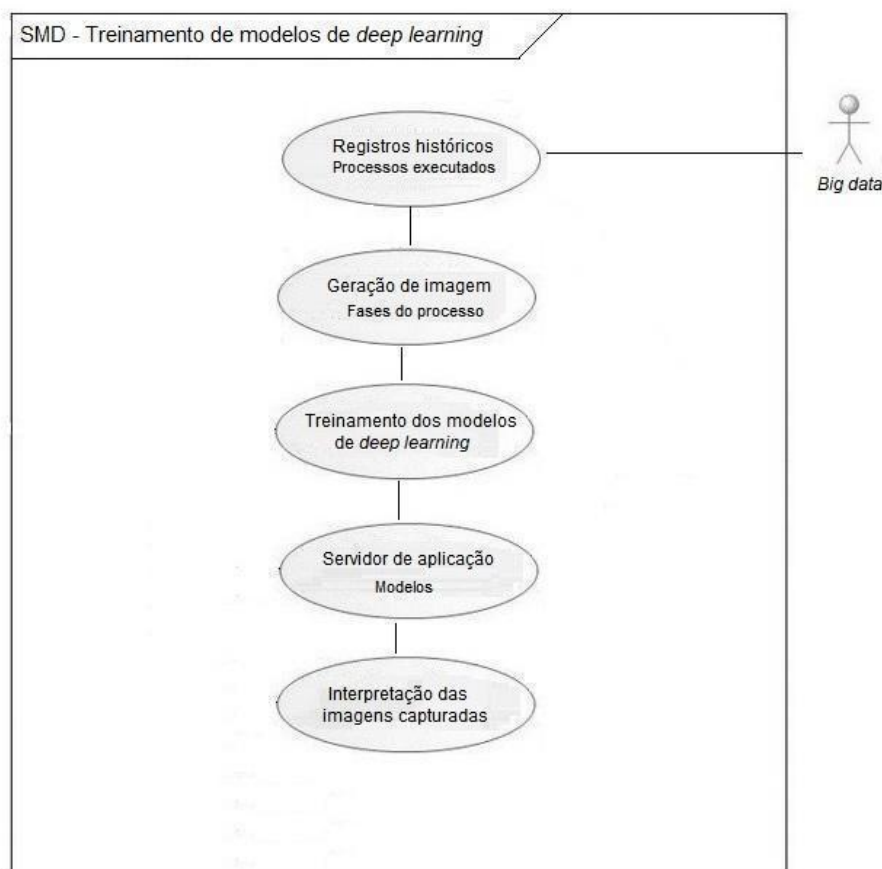


#### 4.5.2.4 Diagrama de caso de uso do treinamento de modelos para previsão

A Figura 22 apresenta o diagrama de caso de uso para treinamento de modelos de inteligência artificial com técnicas de *deep learning* para previsão do encerramento do processo em andamento. Nesta representação também é considerada a infraestrutura como um sistema separado, porém recebendo a interação do ator externo. No contexto deste processo, a arquitetura de *big data*, provedora de dados históricos de processos executados, foi identificada como o único ator externo.

Assim, a partir dos dados armazenados na arquitetura de *big data*, na forma de registros gerados durante o acompanhamento das operações de produção, pelo próprio protótipo, são criadas representações gráficas com *labels* para treinamento dos modelos. Após serem disponibilizados estes modelos, o protótipo usa imagens capturadas do processo de produção em andamento e submete para classificação.

Figura 22 - Caso de uso do treinamento de modelos



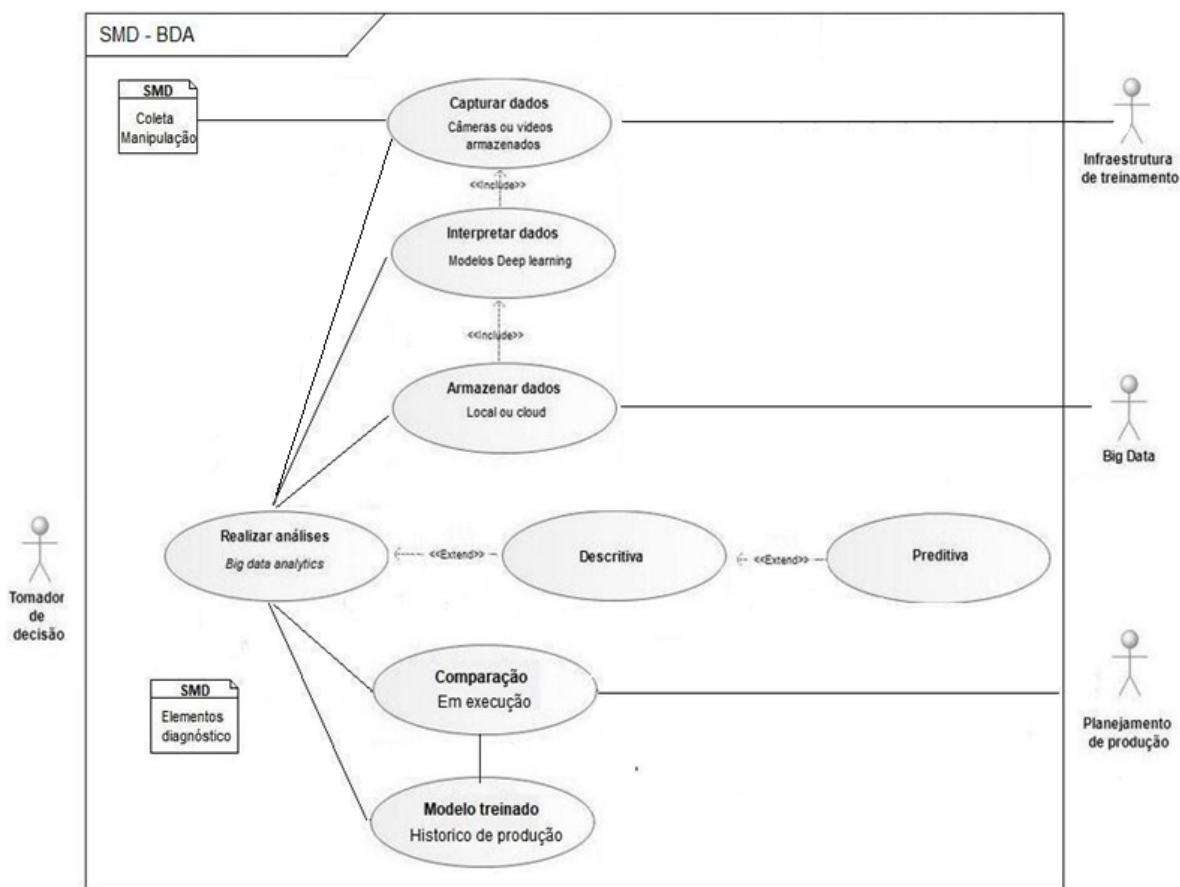
Fonte: elaborado pelo autor

Em uma visão mais ampla do protótipo e seus principais elementos, tanto os modelos de inteligência artificial com técnicas de *deep learning* para classificação de operações, como os modelos para previsão do resultado do processo de produção, são disponibilizados para outras partes do protótipo de SMD, por meio de um servidor de aplicação.

#### 4.5.2.5 Diagrama de caso de uso para BDA

O quinto diagrama de caso de uso representa o processo para aplicação de dados armazenados na arquitetura de *big data* em análises avançadas especificadas de dados. Estas análises foram consideradas na proposta do protótipo de SMD como técnicas de BDA. Para viabilizá-las, foi considerado na fase de projeto o uso de ferramentas *open source* disponíveis para acesso e manipulação de dados, bem como para apresentação dos resultados. Este caso de uso identificou três atores externos, porém com níveis de interação dependentes de cada análise realizada.

Figura 23 - Caso de uso análise BDA



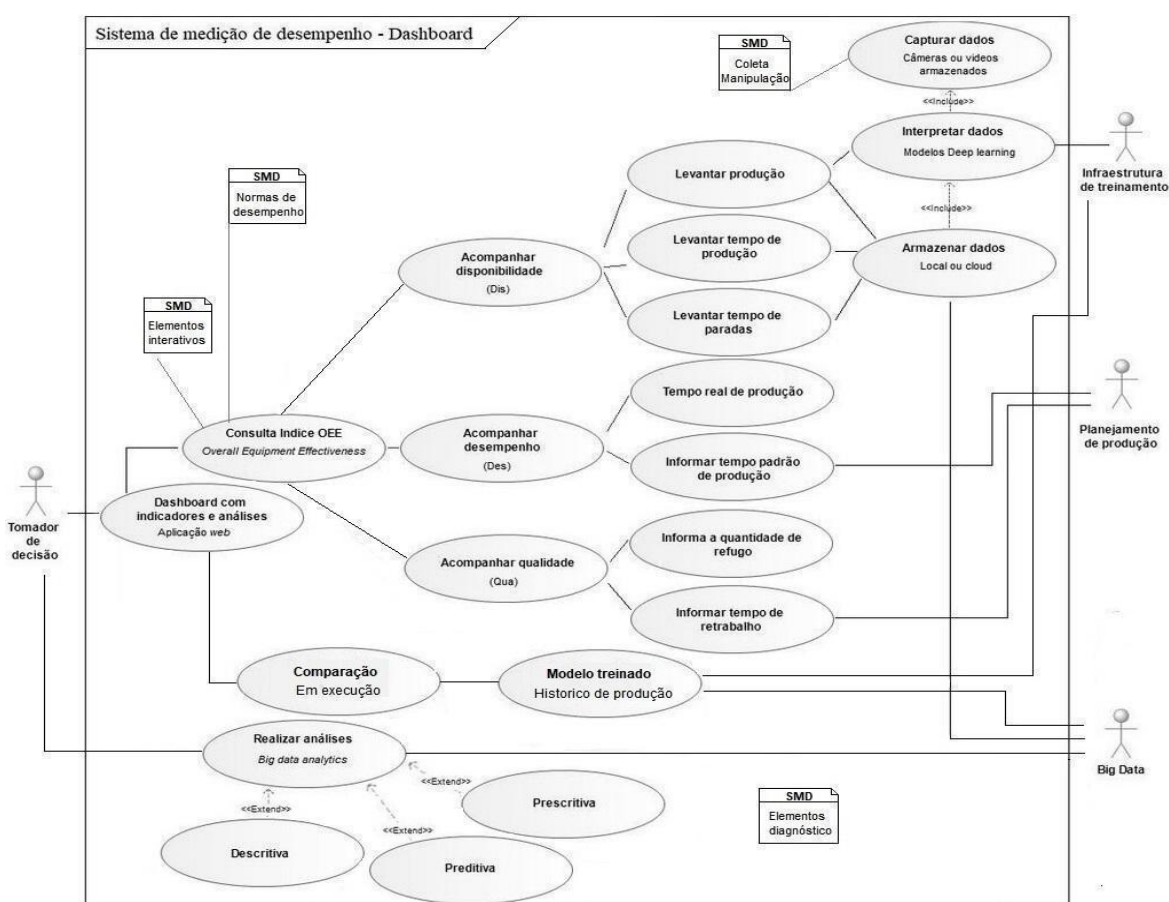
Fonte: elaborado pelo autor

Além da interação com os atores externos representados pela arquitetura de *big data*, infraestrutura de treinamento de modelos de inteligência artificial e planejamento de produção, o processo para elaboração do diagrama de caso de uso, destacou a possibilidade de utilização de recursos internos do protótipo em conjunto com técnicas de BDA. Entre as possibilidades identificadas estão a captação de imagens em tempo real, o uso dos modelos de inteligência artificial já treinados para outros fins, dados armazenados localmente, resultados de outras análises etc.

#### 4.5.2.6 Diagrama de caso de uso geral do SMD

A Figura 24 apresenta o diagrama de caso de uso a partir de uma visão geral do artefato proposto, porém sem os elementos de treinamento de modelos de inteligência artificial, uma vez que são considerados armazenados e disponibilizados nas funções para interpretar os dados capturados e o histórico de produção.

Figura 24 - Diagrama de casos de uso do protótipo de SMD



Fonte: elaborado pelo autor

Esta representação permite visualizar a integração dos elementos com mais interação com o usuário, além da dependência entre as funções previstas.

Diante das representações do protótipo, por meio dos diagramas de caso de uso, foi possível identificar a consulta do OEE, as análises avançadas de dados para previsão, os acompanhamentos de disponibilidade, desempenho, qualidade e produção em execução, como processos primários, segundo o padrão UML, e consequentemente com maior interação com o usuário. Enquanto armazenagem de dados, captura de imagens, levantamentos de produção, tempo real de produção, tempo de paradas, quantidade de refugos e informações fornecidas pelo planejamento, foram classificados como secundários.

#### 4.5.2.7 Especificações dos casos de uso

Além da representação gráfica, a UML prevê o uso de um documento de especificação do caso de uso, com objetivo de detalhar o comportamento dos elementos, por meio do fluxo básico de eventos. Entretanto, a UML não define um padrão específico para este documento, permitindo que o mesmo seja criado conforme as necessidades do projeto que está sendo desenvolvido (GUEDES, 2018).

Diante da possibilidade de adaptação do documento e das características do protótipo desenvolvido na pesquisa, em que as ações dos atores secundários são automatizadas ou com poucas interações pontuais como a entrada de dados para treinamento e padrões de desempenho, a especificação do caso de uso contemplou apenas as ações do tomador de decisão. Assim, o Quadro 8 corresponde a especificação combinada dos 6 diagramas de casos de uso do protótipo a partir das ações do ator principal. As interações da infraestrutura de treinamento, planejamento de produção e arquitetura de *big data*, são descritas como pré-condições para operação do sistema. Embora o objetivo da especificação de caso de uso seja auxiliar na construção dos diagramas de sequência, na presente pesquisa também foi usada na fase de validação do artefato, prevista no método de pesquisa *design science research*.

Quadro 8 - Especificações do caso de uso

Caso de uso	
Nome	<i>Dashboard SMD</i>
Caso de uso geral	
Ator principal	Tomador de decisão

Atores secundários	<i>Big data</i> , planejamento de produção e infraestrutura de treinamento
Resumo	Este caso de uso descreve as funcionalidades disponíveis ao tomador de decisão, por meio de uma <i>dashboard</i> de SMD, tendo os dados não estruturados de vídeos, coletados, interpretados, armazenados e analisados.
Pré-condições	<ol style="list-style-type: none"> <li>1. Deve ser criado um conjunto de imagens das atividades a serem interpretadas/identificadas pelos modelos de inteligência artificial, especificamente <i>deep learning</i>, tendo como foco as operações dos postos ou células de trabalho executadas durante os processos de produção acompanhados e analisados;</li> <li>2. Treinamento do modelo de <i>deep learning</i> a partir do conjunto de imagens pré selecionadas, com uso de uma infraestrutura na nuvem na forma de serviço;</li> <li>3. Iniciar infraestrutura de <i>big data</i>;</li> <li>4. Treinamento de modelos para análise preditiva a partir de dados históricos armazenados na infraestrutura de <i>big data</i>.</li> </ol>
Pós-condições	<ol style="list-style-type: none"> <li>1. Novos treinamentos do modelo de <i>deep learning</i> a partir do resultados da classificação das imagens como forma de aumentar a precisão das classificações de operação;</li> <li>2. Criação de novo modelo de classificação por meio de <i>deep learning</i> com o uso de gráficos correspondentes ao processo de produção de peças.</li> </ol>
<b>Fluxo principal</b>	
Ações dos atores	Ações do sistema
	Acessa a infraestrutura de <i>big data</i> na nuvem ou local;
Captura de imagens	
	Iniciar dispositivos de captura de imagens, sendo possível a análise em tempo real ou já armazenadas.
	Iniciar servidor de aplicação.
Acessar <i>dashboard</i>	
	Carrega informações sobre OEE, disponibilidade, desempenho e qualidade, já processadas pelo servidor de aplicação periodicamente e apresenta na <i>dashboard</i> .
	Disponibiliza periodicamente o resultado da análise preditiva para previsão de encerramento do processo.
	Apresenta análise descritiva compilada dos dados gravados do processo, além de acesso aos registros armazenados na arquitetura de <i>big data</i> .
	Disponibiliza, por meio de imagens, o processo de produção executado até o momento.
	Atualiza as informações da <i>dashboard</i> em intervalos de tempo de 5 segundos.
Seleciona opções de análises de dados	
	Disponibiliza opções de análise avançadas e acesso a dados armazenados na infraestrutura de <i>big data</i> .

Fonte: elaborado pelo autor

Os diagramas de caso de uso do protótipo e especificações, a partir da visão do tomador de decisão, mostraram um equilíbrio entre recursos para diagnóstico e usos interativos, conforme apresentado por Franco-Santos, Lucianetti, Bourne (2012). Desta forma, alguns recursos são direcionados para informações disponibilizadas de forma contínua como os indicadores de desempenho e outros para atender a demandas de dados armazenados na infraestrutura de *big data* para análises avançadas.

A Tabela 4 descreve os componentes planejados para atender os requisitos do protótipo quando a recursos para diagnóstico e agrupados no *dashboard*, com as referências usadas no planejamento.

Tabela 4 - Componentes do *dashboard*

Nome	Descrição	Referência
Índice de Desempenho	A partir da classificação de imagens pelo modelo de <i>deep learning</i> é fornecido ao servidor de aplicação informações sobre a capacidade de produção e produção atual. Desta forma, possibilita a apresentação do índice no <i>dashboard</i> , além do armazenamento da informação.	Hwang et al. (2017) Ferrer et al. (2018)
Índice de Disponibilidade	Calculado a partir do tempo total disponível e de execução, fornecidos a partir dos dados não estruturados de imagens e interpretados pelo modelo de <i>deep learning</i> , estas informações são disponibilizadas pelo servidor de aplicação e para armazenamento.	Hwang et al. (2017) Ferrer et al. (2018)
Índice de Qualidade	Calculado a partir da saída de produção e produtos em conformidade, esta medida de desempenho foi programada para obter os dados em duas fontes. Para saída de produtos é utilizado o modelo de <i>deep learning</i> treinado para identificar peças acabadas. Enquanto que o número de peças em conformidade foi informado por arquivo externo.	Hwang et al. (2017) Ferrer et al. (2018)
OEE	A partir dos valores dos índices de qualidade, desempenho e disponibilidade, o servidor de aplicação calcula o OEE e disponibiliza os dados em um banco de dados com registros provisórios para que estes sejam usados pelo <i>dashboard</i> . Os valores alcançados também são armazenados na estrutura de <i>big data</i> .	Hwang et al. (2017) Ferrer et al. (2018) Willoughby et al. (2010)
Detalhamento OEE	Ferramenta com objetivo de apresentar os dados utilizados nos índices de desempenho, disponibilidade e qualidade. As informações apresentadas são resultado da interpretação e classificação das ações a partir das imagens de	Ferrer et al. (2018)

	vídeo.	
Histórico do processo	Representação gráfica de todas as ações reconhecidas ou não, a partir da interpretação das imagens de vídeo pelo modelo de <i>deep learning</i> . Esta ferramenta permite identificar ações não conhecidas pelo modelo, além de apresentar informações como paradas, ajustes etc.	Rouse e Putterill (2003)
Principais operações	Apresenta o percentual das principais operações identificadas no processo tendo como referência o tempo total de execução.	Voulodimos et al. (2018) Rouse e Putterill (2003)
Histórico de operações	Apresenta a sequência de operações identificadas, desconsiderando ações não interpretadas, período que a máquina está parada, etc	Rouse e Putterill (2003)
Análise preditiva do processo	A partir dos registros históricos do processo, 4 modelos de <i>deep learning</i> foram treinados. Estes modelos correspondem a 4 pontos de análises do processo de produção. Esta estrutura permitiu realizar previsões do resultado do processo quanto ao prazo de encerramento.	Ferrer et al. (2018) Rouse e Putterill (2003)

Fonte: elaborado pelo autor

#### 4.5.3 Ordem de execução e integração entre as partes do sistema

Tendo como base os diagramas de casos de uso e especificações, o diagrama de sequência procura identificar a ordem de execução da comunicação entre os elementos envolvidos nos processos do sistema, além de apresentar como essas partes interagem em cada momento (GUEDES, 2018; BOOCH; RUMBAUGH; JACOBSON, 2006). A Figura 20 ilustra o diagrama de sequência do protótipo de SMD e foi usada para o detalhamento das tarefas a serem executadas, definir a ordem de execução dos eventos e período de tempo que cada elemento deve ficar ativo, além de informações necessárias para sua instanciação. Apesar dos objetos apresentados no diagrama de sequência serem descritos em outro diagrama, a Figura 25 auxiliou na validação do projeto, uma vez que ao modelá-la foi possível identificar quais métodos eram necessários no protótipo, bem como a distribuição deles no sistema.

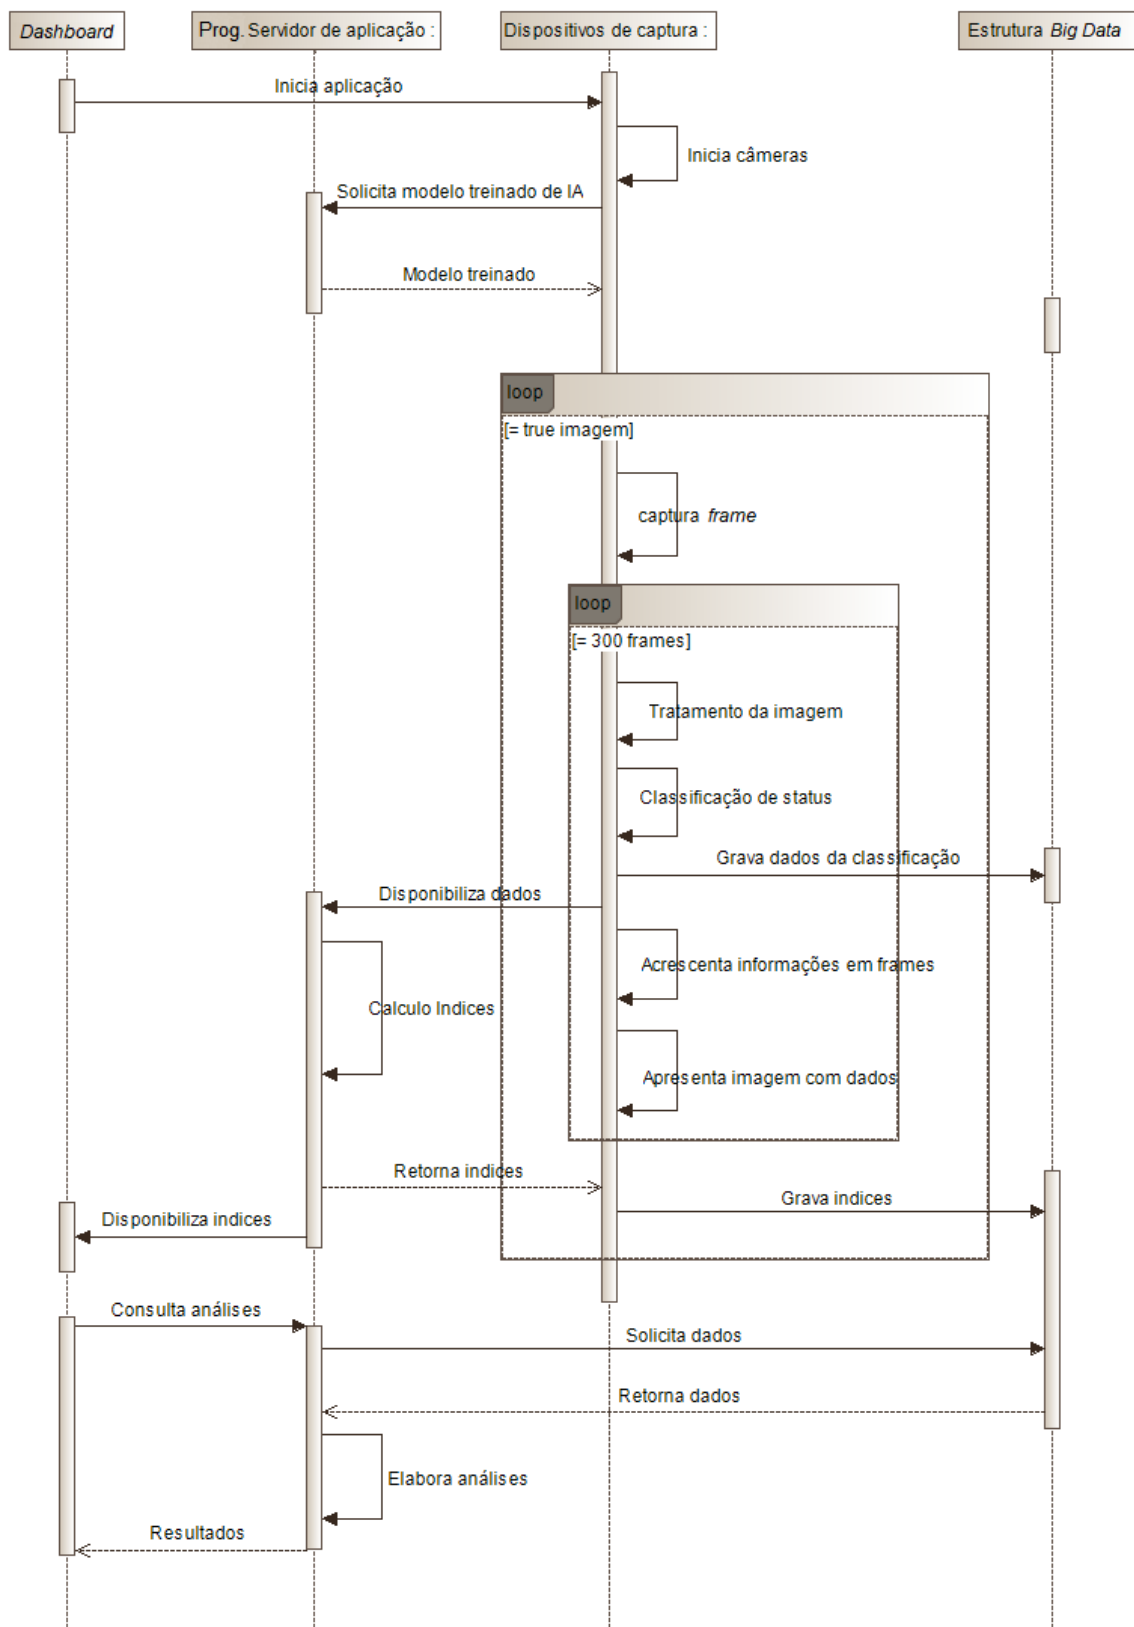
A estrutura de distribuição de recursos de sistema, por meio da representação de componentes (aplicações, bancos de dados, arquivos etc.), auxilia no desenvolvimento dos *software*, uma vez que proporciona melhor compreensão e aproveitamento de códigos (GUEDES, 2018). Nesta representação são considerados os componentes já previstos nos

casos de uso, bem como outros identificados durante a produção do diagrama. Desta forma, o diagrama de sequência, definiu 5 componentes principais de interação:

- *Dashboard*: é uma ferramenta prática que sintetiza o nível de desempenho do processo. Consiste basicamente em um painel de indicadores-chave de desempenho, projetado para diferentes fins (CAMM et al., 2020; FRANCESCHINI; GALETTO; MAISANO, 2019; KERZNER, 2017; JÄÄSKELÄINEN; ROITTO, 2016) e disponibilizado em servidor *web* para acesso, por meio de *browser*, com objetivo de disseminar informações e proporcionar o acompanhamento em tempo quase real das medidas de desempenho e análises de BDA;
- Servidor de aplicação: programa desenvolvido para armazenar os modelos de *deep learning* e controlar suas atualizações. O pré-treinamento do modelo de *deep learning* é realizado em uma infraestrutura própria, projetada para este tipo de processamento ou por meio de serviços comerciais prestados na forma de SAAS e disponibilizado ao sistema no servidor de aplicação para interpretação das imagens. A aplicação também tem a função de efetuar os cálculos de indicadores de desempenho e processamento de análises de dados avançadas, como análises preditivas e descritivas;
- Programa para dispositivos de captura: programa a ser executado em equipamentos como computadores que centralizam as instâncias executadas na mesma quantidade de *hardware* com capacidade de captura de imagens ou com conectividade a dispositivos como câmeras. Assim, após a ação de captura é realizado o processamento local de interpretação dos eventos registrados, com uso do modelo de *deep learning* disponibilizado pelo servidor de aplicação. Apesar do nome utilizado, esta aplicação também realiza a discretização das entradas e apenas parte das imagens são manipuladas de forma a melhorar a interpretação;
- Estrutura de *big data*: estrutura de armazenamento e processamento distribuída em *clusters* de computadores, com possibilidade de uso na forma de SAAS;
- Estrutura de treinamento de modelos de inteligência artificial: consiste em um conjunto de programas escritos com o objetivo de separar imagens de vídeos pré-selecionados, organizá-las e usá-las no treinamento dos modelos de *deep learning*.



Figura 25 - Diagrama de sequência



Fonte: elaborado pelo autor

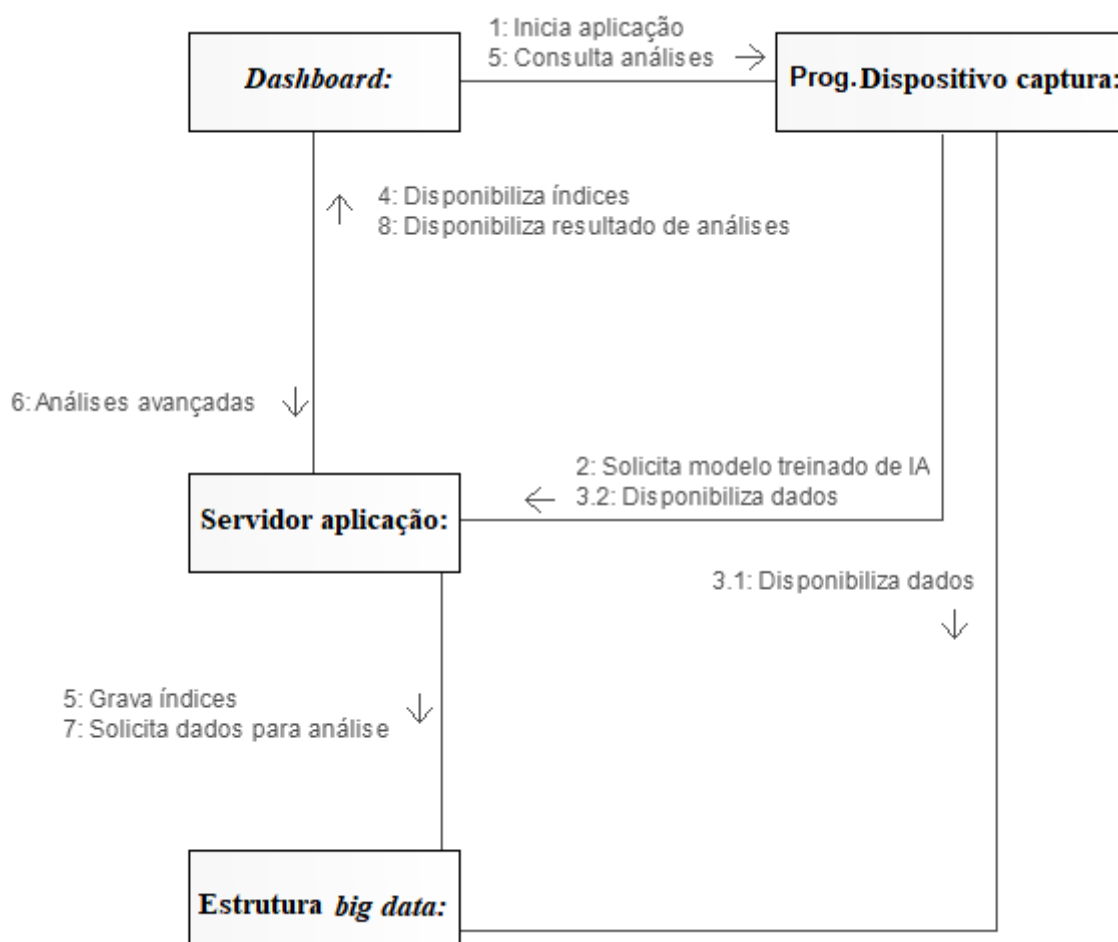
Como previsto no diagrama de caso de uso, o diagrama de sequência tem como interação inicial a comunicação da *dashboard* para iniciar a captura de imagens em dispositivos instalados para este fim na borda da aplicação. Estes dispositivos locais realizam outra comunicação, após iniciar a captura de imagens, solicitando ao servidor de aplicação o modelo de *deep learning* previamente treinado. Com o modelo de *deep learning* pré-treinado, o dispositivo na ponta da aplicação efetua a interpretação da imagem, classificando a operação executada, conforme previamente definido. Contudo, antes desta classificação é necessária uma discretização do vídeo capturado. Desta forma, o *software* decompõe o vídeo em *frames* e realiza o tratamento da imagem em intervalos regulares, conforme a precisão necessária para análise.

Após a classificação esses dados são utilizados pelo servidor de aplicação para elaboração dos cálculos referentes a cada indicador de desempenho, descritos na Figura 19, e os disponibiliza para apresentação no *dashboard* desenvolvido para ambiente *web*. Os dados levantados a partir da análise das imagens e convertidos também são enviados a infraestrutura de *big data* de forma a representar o evento capturado, com objetivo de viabilizar posteriores análises avançadas e o treinamento de novos modelos de inteligência artificial. Estes dados possibilitam o uso de ferramentas de análise de dados e recursos como gráficos, relatórios, planilhas eletrônicas etc. Entretanto, o armazenamento dos dados na estrutura de *big data* também viabiliza a criação de novas medidas de desempenho.

#### **4.5.4 Diagrama de comunicação**

Semelhante ao diagrama de sequência, quanto ao objetivo de demonstrar a ordem de execução das interações entre os elementos envolvidos nos processos do sistema, o diagrama de comunicação também auxiliou na representação da estrutura de distribuição de recursos. Contudo, ele enfatiza o contexto das medidas de desempenho com disponibilidade contínua, como apresentado na Figura 26.

Figura 26 - Diagrama de comunicação



Fonte: elaborado pelo autor

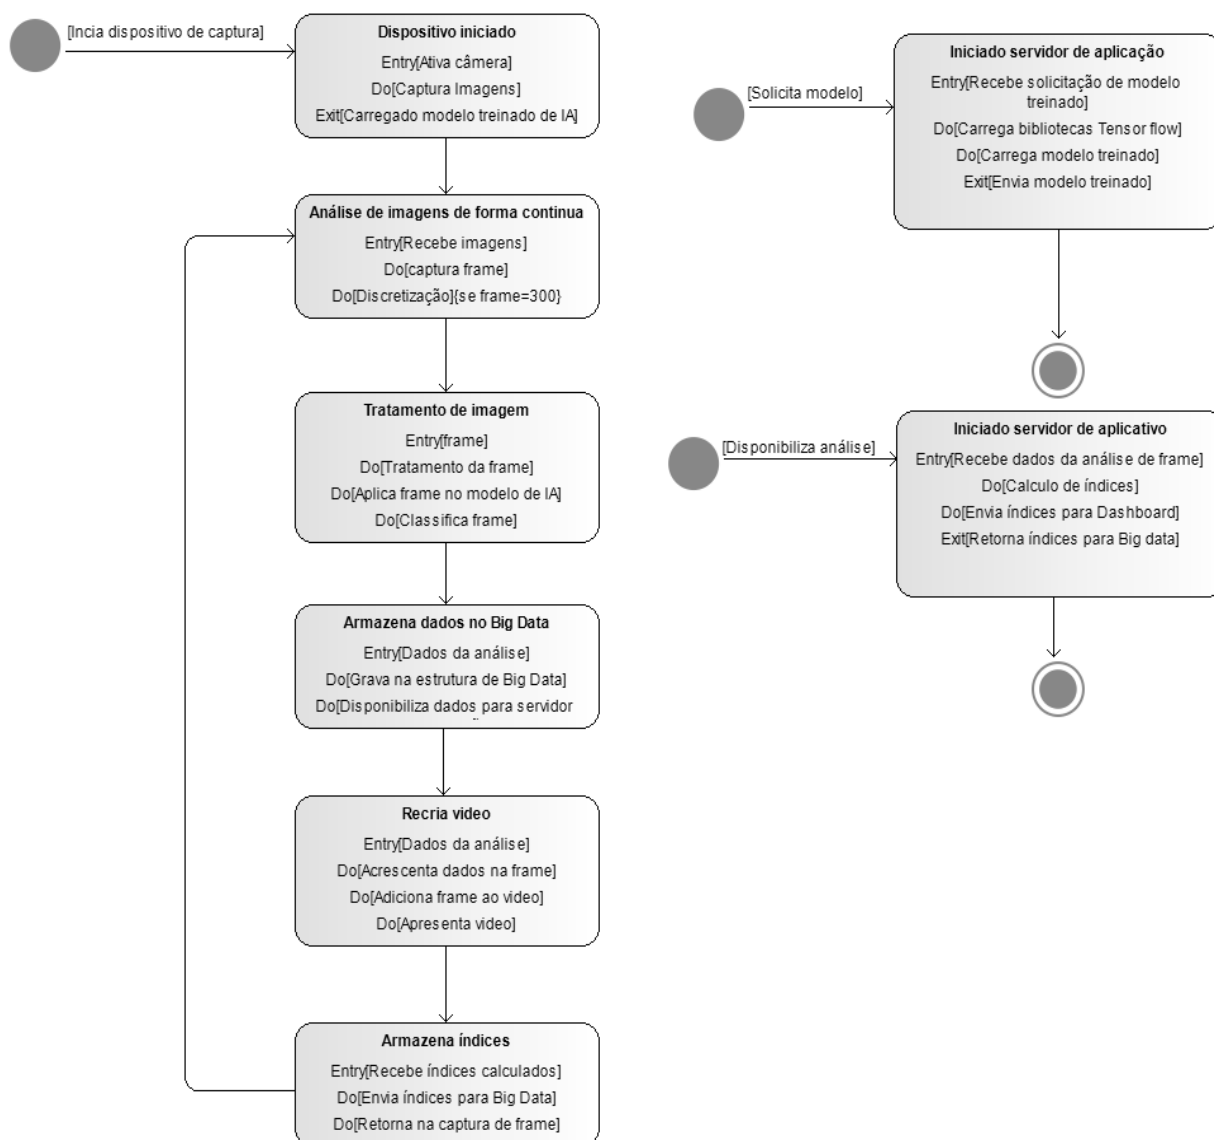
#### 4.5.5 Comportamento interno das aplicações

Durante a execução de um *software* seus elementos podem passar por diversos estados, como a espera de um evento, reação a estímulos, execução de atividades ou mesmo a satisfação de uma condição. Um estado representa a situação que elementos/objetos se encontram em determinado momento do processo (BOOCH; RUMBAUGH; JACOBSON, 2006; PRESSMAN, 2005). Desta forma, o diagrama de estados, por vezes conhecido como diagrama de máquina de estados, detalha o comportamento interno dos objetos que formam a aplicação.

No protótipo de sistema de medição de desempenho desenvolvido, as principais mudanças de estado ocorrem basicamente nos programas dos dispositivos de captura de imagens e servidor de aplicação, uma vez que o projeto prevê uma infraestrutura de *big data* e treinamento de modelos já disponíveis localmente ou na forma de SAAS. A Figura 27

apresenta os estados dos dois dispositivos mencionados e as transições ocorridas durante a execução do protótipo. O diagrama de máquinas de estados, auxiliou no processo de desenvolvimento do código fonte destas aplicações, além da definição de componentes de *software* necessários para viabilizar o comportamento desejado dos objetos envolvidos.

Figura 27 - Diagrama de máquina de estado



Fonte: elaborado pelo autor

#### 4.5.6 Procedimentos de avaliação

A avaliação do artefato projetado e desenvolvido é parte fundamental da validação das pesquisas com abordagem *Design Science*, uma vez que ele é o objetivo principal do trabalho. Assim, para garantir que o artefato desenvolvido proporcione esta validação para pesquisa e seja avaliado quanto à solução satisfatória para o problema identificado, o *design science research* estabelece na fase de projeto a necessidade de serem definidos os procedimentos de avaliação e os resultados esperados para cada teste. (DRESCH; LACERDA; ANTUNES, 2015; LACERDA et al., 2013). Estas avaliações de desempenho e comportamento do artefato desenvolvido podem ser: observacionais, analíticas, funcionais e descritivas (DRESCH; LACERDA; ANTUNES, 2015).

Nos casos de desenvolvimento de aplicações que utilizam tecnologia de *big data*, uma vez que o processamento envolvido pode levar dias e o conjunto de dados utilizado ter que apresentar ocorrências relacionadas às análises, o uso de métodos de testagem menores, mas com capacidade de representar os possíveis cenários se tornam necessários para validação de suas funções e recursos (GUPTA; SHARMA, 2021; STAEGEMANN, VOLK; NAHHAS, 2019; GULZAR, MARDANI, MUSUVATHI, 2019). Neste contexto, para a presente pesquisa foi planejado usar na fase de avaliação do protótipo, as técnicas de teste funcional, também conhecido como teste de caixa-preta e teste de sistemas. A escolha desses testes se deu porque os testes funcionais e testes de sistemas são usados na avaliação de artefatos finalizados e verificam os comportamentos exigidos do sistema (NIDHRA; DONDETI, 2012).

A técnica de teste funcional consiste no fornecimento de dados de entrada, que após a execução da aplicação tem os resultados comparados a um valor esperado e previamente conhecido (GUPTA; SHARMA, 2021, DRESCH; LACERDA; ANTUNES, 2015; NIDHRA; DONDETI, 2012; MYERS; SANDLER; BADGETT, 2011; PRESSMAN, 2005, COPELAND, 2004). Desta forma, haverá sucesso no teste funcional se o resultado da execução do sistema apresentar um valor igual ao levantado anteriormente (NIDHRA; DONDETI, 2012).

Com a seleção de cenários que representam um grupo de situações, os testes funcionais permitem um número menor de simulações (NIDHRA; DONDETI, 2012; MYERS; SANDLER; BADGETT, 2011). Este tipo de teste não considera o comportamento interno do *software*, mas pode ser aplicado para validação de métodos, funções internas, programas inteiros e até conjuntos de programas e/ou componentes, em todos os níveis

(NIDHRA; DONDETI, 2012; MYERS; SANDLER; BADGETT, 2011; PRESSMAN, 2005, COPELAND, 2004).

São dois os principais passos do teste funcional. Primeiro são identificados, a partir das especificações do *software*, os requisitos e funções que o programa deve atender. No segundo passo, são criados cenários capazes de verificar se essas funções estão sendo realizadas. Existem alguns critérios para realização deste tipo de teste como: particionamento em classes de equivalência, análise do valor limite, grafo de causa-efeito, entre outras formas (NIDHRA; DONDETI, 2012; MYERS; SANDLER; BADGETT, 2011).

Nesta tese, foi adotado o critério de particionamento em classes de equivalência, que a partir das condições de entrada de dados, divide-se o domínio em grupos válidos e inválidos. Em seguida, selecionou-se o menor número de casos de teste, tendo como base a hipótese que um elemento de uma classe é representativo para todo um grupo de situações (PRESSMAN, 2005; COPELAND, 2004).

O teste de sistema permite confirmar se os objetivos e requisitos do *software* foram atendidos (FREEMAN, 2002) e se o artefato tem capacidade de operar em um ambiente com as características do local onde irá trabalhar (NIDHRA; DONDETI, 2012). Assim, funciona como uma espécie de processo de verificação, por meio de uma visão externa do sistema, sem a preocupação com a forma de execução. Este tipo de teste usa como base os requisitos do sistema, documentos de modelagem ou arquitetura e especificações de operações (NIDHRA; DONDETI, 2012, FREEMAN, 2002).

Para este trabalho de pesquisa, testes funcionais e testes de sistema foram planejados para avaliar a pontualidade, validade e confiabilidade das medidas de desempenho e análises de dados definidas na proposta. O Quadro 9 apresenta as avaliações planejadas e respectivos testes para cada característica das medidas de desempenho, além das formas de execução e os resultados esperados para os requisitos. As avaliações consequentemente avaliam a infraestrutura e consideram a mesma como adequada quando atendido o requisito da medida de desempenho avaliada, uma vez que não foram planejadas análises técnicas da área da computação.

Quadro 9 - Avaliações planejadas para o protótipo

Avaliação	Procedimento de execução	Característica	Tipo de teste	Resultados esperados	Referência
Disponibilidade dos resultados	Por meio de <i>browsers</i> de internet, em diferentes tipos de <i>hardware</i> , acessar o <i>dashboard</i> desenvolvido e acompanhar a simulação de operações de fabricação	Validade	Funcional	Valores das medidas de desempenho corretos;	Nidhra; Dondeti (2012) Al-Sarmi; Al-Hemyari (2014) Al-Turki; Duffuaa (2003) Hwang et al. (2017) Tambare et al. (2022) ISO 22400
		Pontualidade	Sistema	Não apresentar interrupção nos serviços	Nidhra; Dondeti, (2012) Al-Sarmi; Al-Hemyari (2014) Al-Turki; Duffuaa (2003) Camm et Al. (2020) Franceschini; Galetto (2019)
Coleta e manipulação de dados	Realizar 3 simulações de operações, cada uma correspondendo a um cenário de fabricação e comparar com a interpretação apresentada pelo modelo de IA.	Validade	Funcional	Capacidade na interpretação das ações presentes nas imagens	Nidhra; Dondeti (2012) Al-Sarmi; Al-Hemyari (2014) Al-Turki; Duffuaa (2003) Zhang A. et al. (2021) Voulodimos et al. (2018)
Armazenagem e manipulação de dados	Aplicar no protótipo 5 simulações de entrada de dados de processo de produção criadas a partir do <i>dataset</i> de vídeos, composta por 3 tipos diferentes de operações.	Confiabilidade	Funcional	Número de registros armazenados igual ao calculado a partir das informações dos vídeos	Gupta; Sharma (2021) Staegemann, Volk; Nahhas, (2019) Gulzar, Mardani, Musuvathi, (2019) Nidhra; Dondeti (2012) Al-Sarmi; Al-Hemyari (2014) Al-Turki; Duffuaa (2003)
				Representação gráfica do processo igual a registro armazenado na estrutura de <i>big data</i>	
				Apresentar os mesmos valores para as medidas de desempenho	
		Validade	Funcional	Os registros armazenados representam todos os	Gupta; Sharma (2021) Staegemann, Volk; Nahhas (2019)

				eventos presentes na captura.	Gulzar, Mardani, Musuvathi (2019) Nidhra; Dondeti (2012) Al-Sarmi; Al-Hemyari (2014) Al-Turki; Duffuaa (2003)
Análise preditiva	Submeter ao protótipo de SMD, vídeos com objetivo de simular a captura de imagens em um ambiente de produção. Acompanhar os processos para coletar os dados de previsão do processo, além do resultado final, por meio das opções do <i>dashboard</i> .	Validade	Funcional	Prever o resultado final do processo analisado	Gupta; Sharma (2021) Staegemann, Volk; Nahhas (2019) Gulzar, Mardani, Musuvathi (2019) Nidhra; Dondeti (2012) Lepenioti e al. (2020a) Soltanpoo; Sellis (2016)
Acompanhar as operações em tempo real	A partir de um processo de produção criar 5 simulações diferentes com anomalias a serem identificadas.	Validade	Funcional	<ol style="list-style-type: none"> <li>1. Indicar como não classificada a ação de limpeza de resíduos da usinagem.</li> <li>2. Indicar como operações conhecidas, porém não presentes no processo de produção padrão, como paradas não programadas.</li> </ol>	Gupta; Sharma (2021) Al-Sarmi; Al-Hemyari (2014) Al-Turki; Duffuaa (2003) Camm et al. (2020) Franceschini; Galetto (2019)
		Pontualidade	Sistema	Apresentar no histórico do processo e operações as anomalias provocadas no momento de sua ocorrência.	Al-Sarmi; Al-Hemyari (2014) Al-Turki; Duffuaa (2003) Camm et al. (2020) Franceschini; Galetto; Maisano (2018)

Fonte: elaborado pelo autor



Conforme o detalhamento do Quadro 9, um processo de execução pode avaliar mais de uma característica, bem como uma característica pode ser avaliada por vários testes. O Quadro 10 apresenta o planejamento de avaliação de cada medida de desempenho proposta para o protótipo em relação aos testes funcionais e testes de sistema e as características avaliadas. Também apresenta os testes executados para informações presentes no *dashboard* que não representam medidas de desempenho, como as principais operações do processo de produção e histórico de processo.

Quadro 10 - Avaliação para cada medida de desempenho

Medida de Desempenho	Testes	Característica
OEE	Disponibilidade dos resultados	Validade
		Pontualidade
	Coleta e manipulação de dados	Confiabilidade
	Armazenagem e manipulação de dados	Validade
Confiabilidade		
Tempo total disponível	Disponibilidade dos resultados	Validade
		Pontualidade
	Coleta e manipulação de dados	Confiabilidade
	Armazenagem e manipulação de dados	Validade
Confiabilidade		
Principais operações	Coleta e manipulação de dados	Validade
Produção atual	Armazenagem e manipulação de dados	Confiabilidade
Tempo de execução	Armazenagem e manipulação de dados	Confiabilidade
Capacidade de produção	Armazenagem e manipulação de dados	Confiabilidade
Índice de disponibilidade	Disponibilidade dos resultados	Validade
		Pontualidade
	Coleta e manipulação de dados	Confiabilidade
	Armazenagem e manipulação de dados	Validade
Confiabilidade		

Índice de desempenho	Disponibilidade dos resultados	Validade
		Pontualidade
	Coleta e manipulação de dados	Confiabilidade
	Armazenagem e manipulação de dados	Validade
Confiabilidade		
Tempo total disponível	Armazenagem e manipulação de dados	Confiabilidade
Previsões	Análise preditiva	Validade
	Disponibilidade dos resultados	Validade
		Pontualidade
	Armazenagem e manipulação de dados	Validade
Confiabilidade		
Histórico de operações	Disponibilidade dos resultados	Validade
	Acompanhar as operações em tempo real	Validade
		Pontualidade
Armazenagem e manipulação de dados	Validade	
Processo de produção	Disponibilidade dos resultados	Validade
	Acompanhar as operações em tempo real	Validade
		Pontualidade
Armazenagem e manipulação de dados	Validade	

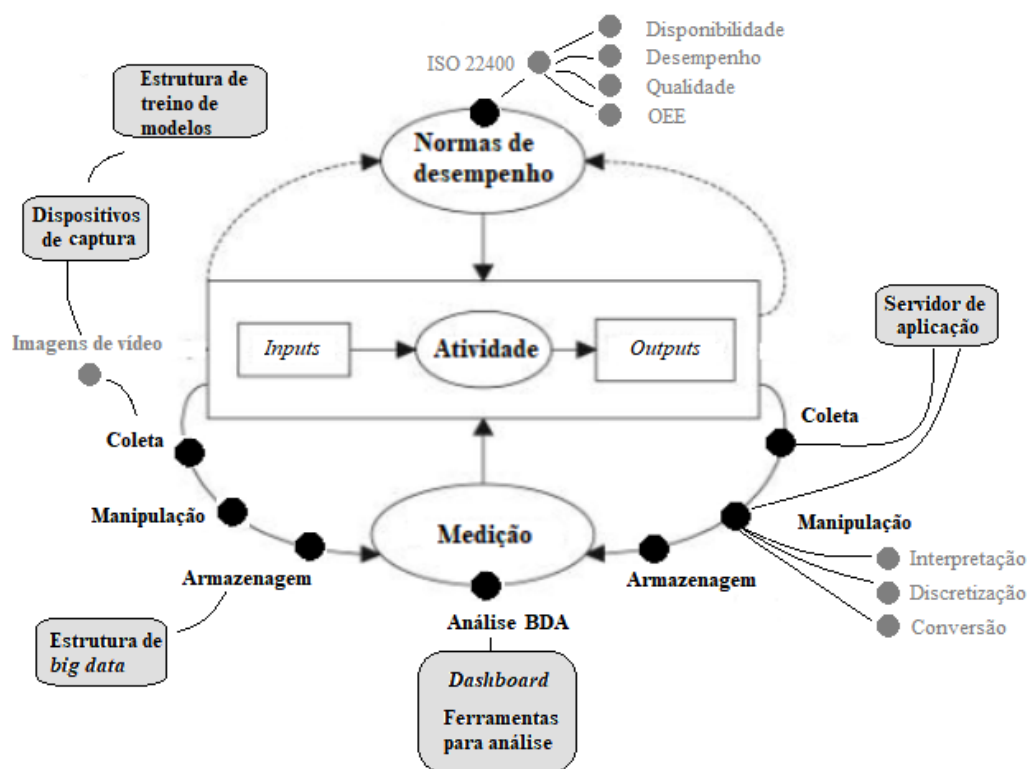
Fonte: elaborado pelo autor

Apesar dos SMD possuírem características importantes como influenciar comportamento dos usuários e comunicação de resultados, o foco desta tese em explorar o uso de dados não estruturados de imagem com a estrutura de *big data* acabou por direcionar as avaliações para elementos do SMD influenciados pelos temas: BDA, *deep learning* e visão computacional.

Após a diagramação do artefato proposto, a definição dos resultados esperados e as formas de realizar sua avaliação, foi possível integrar os 5 principais componentes identificados: *dashboard*, servidor de aplicação, programa de dispositivos de captura, estrutura de *big data* e estrutura para treinamento de modelos de *deep learning*, ao modelo de

transformação geral e modelo de referência *Integral Framework for Performance Measurement*, conforme apresentado na Figura 28.

Figura 28 - Integração de componentes do projeto



Fonte: elaborado pelo autor

#### 4.6 Desenvolvimento do Artefato

Assim que a fase de projeto do artefato proposto for concluída, seu desenvolvimento pode ser iniciado (GOECKS et al., 2021; VAN AKEN et al. 2018; DRESCH; LACERDA; ANTUNES, 2015). O método preconizado por Dresch; Lacerda e Antunes (2013), apresenta em sua fase 6 o desenvolvimento do artefato, por meio de diferentes abordagens. Para esta tese, a fase correspondeu a programação do protótipo, bem como a configuração do ambiente de execução e avaliação. Conforme apresentado na Figura 13, esta fase de desenvolvimento do artefato, corresponde a fase de *implantação* no processo de construção de um SMD e a pós-implantação, quando comparada com as fases de um projeto de *big data* apresentadas por Mousannif (2016).

Deve ser destacado que esta fase não é restrita ao desenvolvimento do produto, uma vez que tem os objetivos mais amplos de gerar conhecimento a ser aplicado e útil para

resolução de problemas, melhorar sistemas existentes e criação de novas soluções e/ou artefatos. Assim, ao final da fase de desenvolvimento do artefato, o pesquisador tem duas saídas principais como produtos do trabalho. A primeira saída é o artefato em seu estado funcional. A segunda saída consiste nas heurísticas de construção que podem ser formalizadas a partir do artefato desenvolvido e que contribuem para o avanço do conhecimento (GOECKS et al., 2021; DRESCH; LACERDA; ANTUNES, 2015) e são contempladas a seguir nesta seção.

#### 4.6.1 Recursos computacionais usados no desenvolvimento do artefato

Enquanto as perguntas “o que devemos medir?” (BOURNE et al., 2000) e “quais medidas de desempenho são usadas? Para que são usadas? Que benefício elas oferecem?” (NEELY; GREGORY; PLATTS, 1995) foram respondidas pela definição do OEE, o modelo de referência *Integral Framework for Performance Measurement*, técnicas de BDA e o padrão ISO 22400, nas fases de proposição e projeto, a questão “quanto elas custam?” (NEELY; GREGORY; PLATTS, 1995), esteve presente durante o desenvolvimento do artefato, não apenas delimitando a infraestrutura computacional, mas também os procedimentos necessários para operacionalização, uma vez que o baixo custo foi definido como um dos requisitos de algumas características do artefato proposto.

Como definido na fase de projeto do artefato, o sistemas de medição de desempenho, com uso de técnicas de BDA e *deep learning* para coleta, armazenagem e análise de dados não estruturados de imagens de vídeos, foi desenvolvido com o uso de linguagens, bibliotecas, interfaces, *software* e plataformas *open source*. A Tabela 5 apresenta os principais recursos computacionais de *software* aplicados nos 5 componentes identificados nos diagramas usados no projeto do protótipo. Além destes recursos, também foram utilizadas as bibliotecas para linguagem *Python*: *Matplotlib*, *Python Imaging Library (PIL)*, *Webbrowser*, *Ploty* e *Subprocess*.

Tabela 5 - Recursos computacionais de *software*

Recurso	Características	Referência
<i>Python</i>	Linguagem de programação <i>open source</i> orientada a objetos, sendo muito usada em aplicações de <i>Big Data</i> , mineração de dados, aprendizado de máquina, <i>deep learning</i> e ciência de dados.	Suraya; Sholeh (2022) Raschka; Mirjalili (2019) Lutz (2001)

<i>Tensorflow</i>	Interface <i>open source</i> de programação escalonável e multiplataforma para implementar e executar algoritmos de aprendizado de máquina.	Raschka; Mirjalili (2019)
<i>OpenCv</i>	Biblioteca com blocos de construção para experimentos e aplicativos com uso de visão computacional. Fornece interfaces de alto nível para captura, manipulação, processamento e apresentação de imagens.	Howse (2013)
<i>SQLite</i>	Banco de dados relacional de código aberto que dispensa o uso de um servidor e configurações. O SQLite disponibiliza acesso a bancos de dados a partir de aplicações desenvolvidas em diferentes linguagens, entre elas <i>Python</i> .	Suraya; Sholeh (2022) Bhosale; Patil (2015)
<i>Numpy</i>	Biblioteca com suporte ao processamento de grandes multi-dimensionais arranjos e matrizes, junto com uma coleção de funções matemáticas de alto nível.	Howse (2013)
<i>Pandas</i>	Construído em cima do <i>NumPy</i> fornece manipulação de dados de alto nível, ferramentas que tornam o trabalho com dados tabulares ainda mais conveniente.	Raschka; Mirjalili (2019)
<i>Flask</i>	<i>Microframework Python</i> para aplicações <i>web</i>	Suraya; Sholeh (2022)
<i>Hadoop</i>	Plataforma de <i>software</i> para computação distribuída com uso de <i>clusters</i> e processamento de grandes volumes de dados, com atenção a tolerância a falhas.	Barba-González, et al. (2019)
<i>Spark</i>	Mecanismo multilíngue para estrutura de <i>big data</i> usado pela ciência de dados e aprendizado de máquina com processamento em tempo real, por meio de linguagens como <i>Python, SQL, Scala, Java</i> ou <i>R</i> .	Belov; Tatarintsev; Nikulchev, (2021) Gulzar, Mardani, Musuvathi (2019) Drabas; Lee (2017)
<i>PySpark</i>	<i>PySpark</i> é uma interface para <i>Apache Spark</i> que permite a criação de aplicativos <i>Spark</i> com APIs <i>Python</i> . A interface também fornece recursos para analisar dados interativamente em um ambiente distribuído.	Drabas; Lee (2017)

---

Fonte: elaborado pelo autor

Para atender a necessidade de armazenagem e manipulação dos dados coletados com baixo custo, bem como proporcionar uma interface para análises avançadas e criação de novas medidas de desempenho, foi adotado para o ambiente de desenvolvimento do protótipo o ecossistema de *Big Data Hadoop*. Esta plataforma de *software* é projetada para computação distribuída voltada para *clusters* e processamento de grandes volumes de dados, com atenção a tolerância a falhas, sendo a estrutura de *big data* mais usada atualmente

(BARBA-GONZÁLEZ, et al., 2019). Todavia, como a plataforma *Hadoop* exige considerável conhecimento técnico dos usuários (BARBA-GONZÁLEZ, et al., 2019) também foi levantada e testada a hipótese do armazenamento e análise dos dados coletados e manipulados usarem ferramentas já existentes, como serviços comerciais frequentemente prestados por meio de SAAS de computação em nuvem com suporte a *Tensor Processing Units* (TPU). Uma vez que, esses serviços podem ser utilizados por meio de composições de fluxo de trabalho, por pessoas com menor qualificação na área da computação, sem a necessidade de infraestrutura de *hardware*.

Tanto o conjunto de processos de análises avançadas de dados do BDA, como a disseminação dos resultados em tempo real, também tiveram a alternativa do uso dos recursos de SAAS em suas versões do SMD durante esta fase, porém não exploradas totalmente.

Apesar da fase de projeto do artefato detalhar o *dashboard*, servidor de aplicação, programa de dispositivos de captura, estrutura de treinamento de modelos de *deep learning* e estrutura de *big data*, como partes do protótipo, o desenvolvimento destes 5 componentes ocorreu algumas vezes paralelamente, frente à necessidade de integração dos recursos. Da mesma forma, ocorreram paralelamente algumas avaliações do protótipo, pois apesar do método *design science research* prever uma fase específica para este fim, os testes de alguns requisitos definidos na proposição do artefato são inerentes ao desenvolvimento, como a infraestrutura de *software* usada nos componentes.

#### 4.6.2 Etapas do desenvolvimento do artefato

A primeira etapa de desenvolvimento do protótipo teve como objetivo produzir a estrutura de treinamento para inteligência artificial por meio de modelos de *deep learning*. Sendo um sistema de aprendizado de máquina que opera em grande escala em ambientes heterogêneos, a biblioteca *open source Tensorflow* (RASCHKA; MIRJALILI, 2019; ABADI et al., 2016) foi utilizada como base de uma aplicação SAAS. Para isso, foram programadas, no ambiente SAAS, rotinas com a linguagem *Python* para integrar as bibliotecas *Tensorflow* e *OpenCV*. A escolha por serviços na internet na forma de SAAS em detrimento a uma estrutura de *hardware* local se justifica frente a grande necessidade de processamento, identificada durante a programação e configurações específicas de equipamentos.

A segunda etapa da fase de desenvolvimento contemplou a programação das aplicações para serem usadas em dispositivos de captura, executados em diferentes tipos de *hardware* e sistemas operacionais. Além de realizar a discretização e interpretação das

imagens, esta parte do protótipo também disponibiliza as janelas de acompanhamento das entradas em tempo real com os resultados obtidos, conforme apresentado nas Figuras 29 e 30. Nesta parte, do protótipo a integração entre as bibliotecas *OpenCV* e *Tensorflow*, por meio da linguagem *Python*, se mostrou indicada pela fácil integração e disponibilidade de recursos de manipulação de imagens.

Figura 29 – Acompanhamento em tempo real



Fonte: elaborado pelo autor

Figura 30 – Acompanhamento em tempo real



Fonte: elaborado pelo autor

Contemplado pelos processos de coleta e manipulação de dados no artefato proposto, o recurso de aquisição de dados se apresentou na fase de proposta como uma inovação para os SMD, uma vez que sua viabilidade considera o uso de *deep learning* e visão computacional, tendo como objetivo a análise e conversão de imagens de vídeo em dados estruturados ou semiestruturados. A análise e processamento de imagens de vídeo pode ser realizada por meio de duas abordagens, em termos de arquitetura de sistema, ou seja, baseada em serviços em redes ou na “borda” do sistema em *hardware* locais (CHOI, et al., 2020). Frente a rápida evolução das tecnologias de *deep learning* na análise de imagens, que viabiliza o processamento local (LI; OTA; DONG, 2018) e a primícia de uso de *hardware* de baixo custo e de fácil aquisição, o protótipo proposto teve a análise e processamento de imagens programado para execução na “borda” da aplicação, juntamente com a captação das imagens. Alguns testes foram realizados durante o desenvolvimento de forma a analisar a discretização das imagens em um ambiente SAAS, porém a performance obtida não apresentou vantagens em relação a execução em “borda”.

Com o objetivo de servir várias instâncias para captura de imagem com modelos de classificação de imagens baseados em *deep learning* e rotinas de cálculos de medidas de desempenho pré-definidas, o servidor de aplicação teve o início de seu desenvolvimento simultaneamente com o programa para dispositivos de captura de imagens, porém sem comunicação com a estrutura de *big data*. Mesmo com a armazenagem dos dados projetada para estrutura de *big data*, esta aplicação utilizou o banco de dados *SQLite* para registros relacionados a execução e acessados em curtos intervalos de tempo, como status de equipamento, horário de início das operações, OEE calculado no momento e processos de produção planejados, sendo a base de dados hospedada localmente.

O uso de um banco de dados relacional para registros com acesso frequentes, durante a execução da aplicação, se deu em decorrência da alta latência identificada no uso destes dados quando armazenados na estrutura de *big data*.

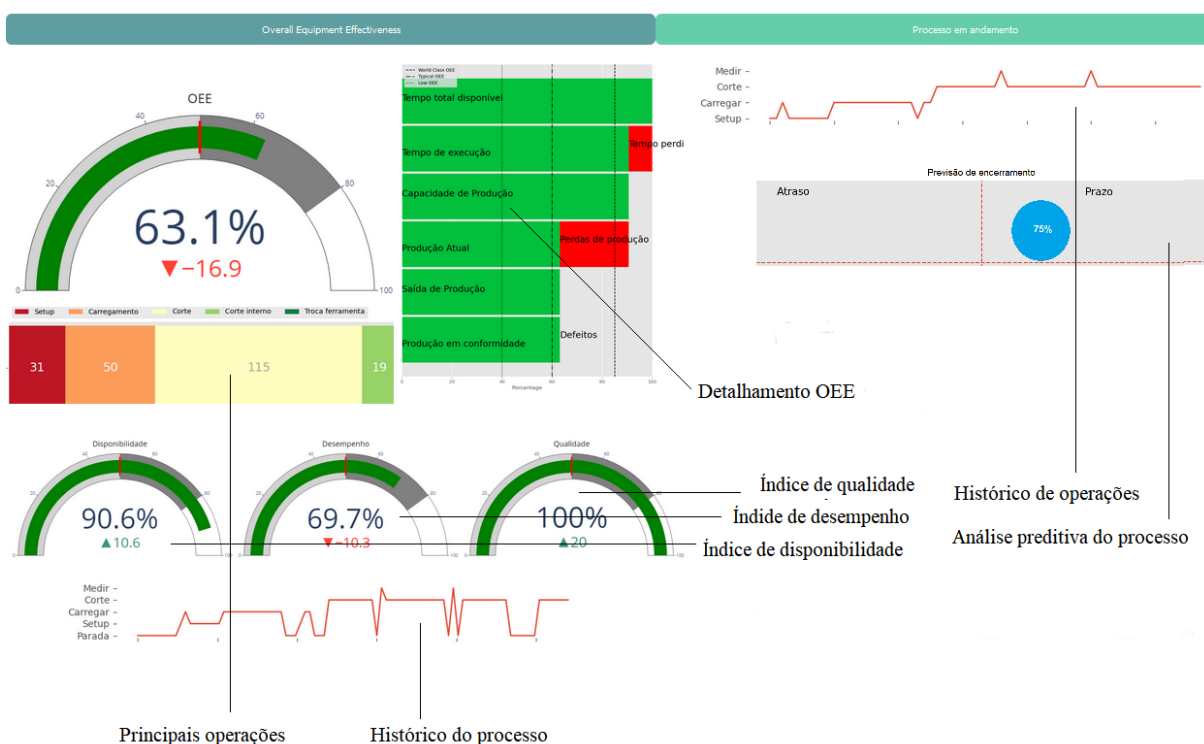
Armazenar os dados recebidos é uma das funções mais importantes de qualquer plataforma de processamento de *big data* (BELOV; TATARINTSEV; NIKULCHEV, 2021). Assim, a terceira etapa de desenvolvimento trabalhou na comunicação entre a estrutura de *big data* com o servidor de aplicações e o programa de dispositivos de captura, com objetivo de viabilizar a armazenagem de dados. Nos primeiros testes, a estrutura de *big data* foi usada localmente com a instalação da plataforma *Hadoop* e sistema de arquivos *Hadoop Distributed File System (HDFS)*, porém transferida posteriormente para uma solução SAAS. Em ambas as



configurações foi utilizada a linguagem *Python* e suas bibliotecas para acesso aos dados armazenados.

A proposta de desenvolvimento de um *dashboard* como parte do protótipo, conforme apresentado na Figura 31, teve como foco atender ao propósito de disponibilizar os resultados das análises de dados interna e externamente, além de concretizar o processo de gestão da informação e atender o objetivo específico da tese de propor um painel de indicadores de desempenho considerando as características de dados coletados, armazenados, manipulados e analisados a partir de imagens e vídeos.

Figura 31 – *Dashboard* com medidas de desempenho

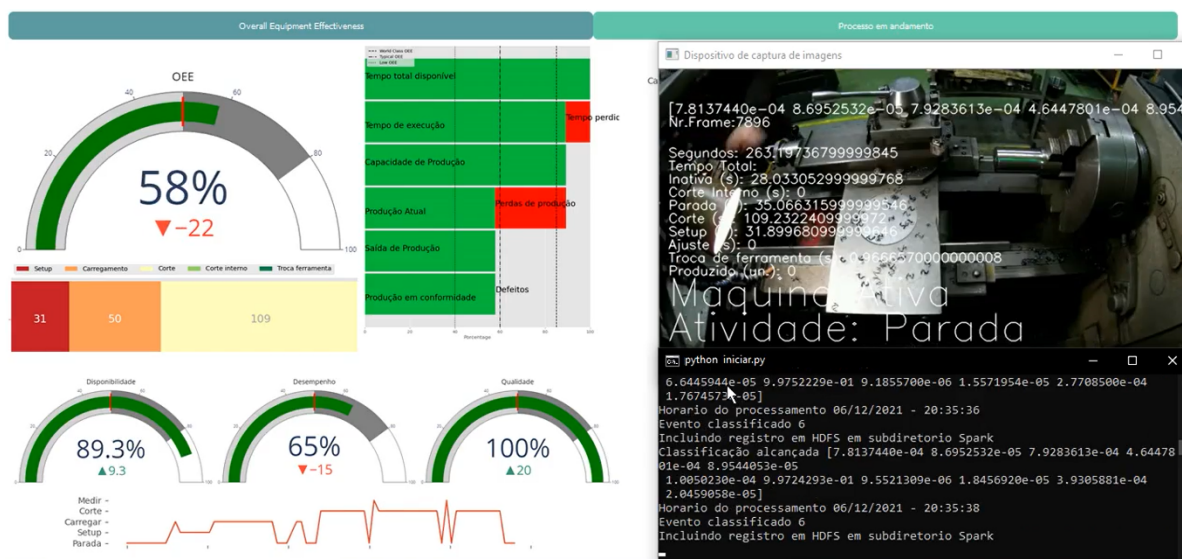


Fonte: elaborado pelo autor

Assim, uma aplicação *web* para disponibilizar informações de forma contínua em tempo quase real em diferentes tipos de plataformas foi desenvolvida na quarta etapa da fase para atender estes objetivos. O *dashboard* foi desenvolvido com uso da linguagem *Python*, combinada com a microframeworks *Flask* e a linguagem de marcação *HyperText Markup Language* (HTML).

A Figura 32 apresenta o *dashboard* desenvolvido, as janelas de acompanhamento das entradas em tempo quase real e o processamento no servidor de aplicação, como componentes de saída de informação. As medidas de desempenho e análises planejadas para o protótipo de SMD, e que formam o *dashboard*, são apresentadas na Figura 33 com as referências para o diagrama de estudo de caso do padrão UML.

Figura 32 – Componentes de saída

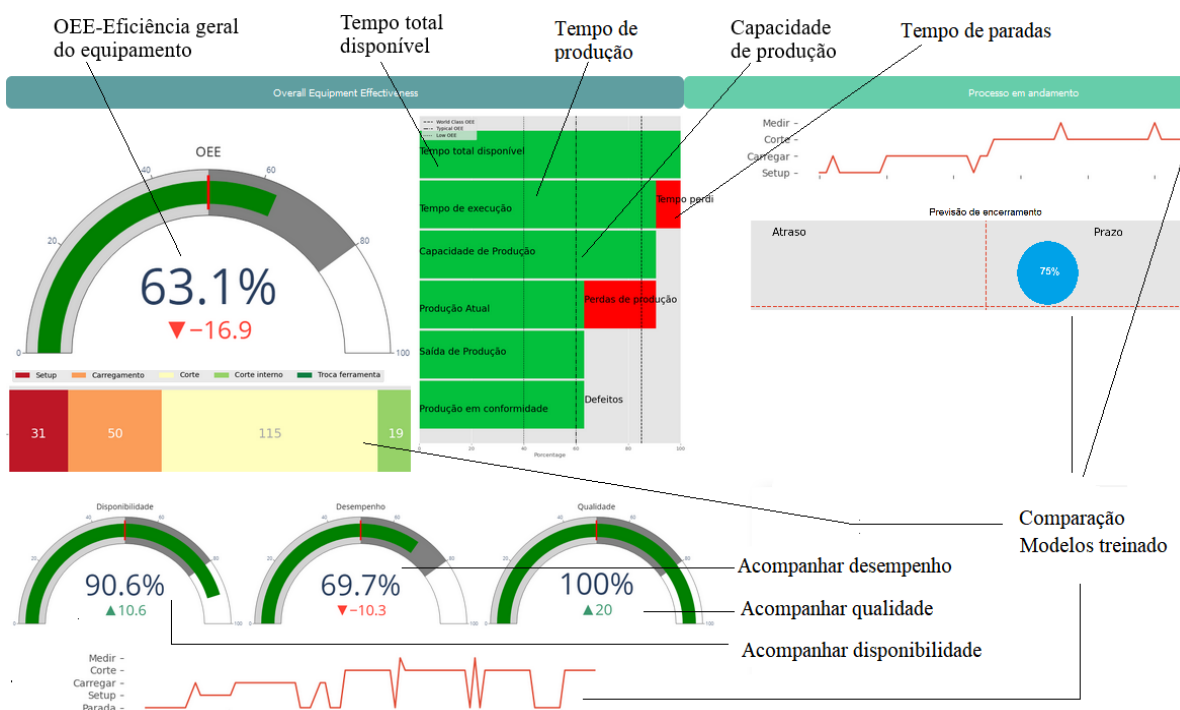


Fonte: elaborado pelo autor

Para viabilizar o acesso aos dados armazenados na estrutura de *big data* de forma a proporcionar a criação de novas medidas de desempenho, principalmente de diagnóstico, e operacionalizar o uso do BDA, por meio de análises descritivas e preditivas, a última etapa do desenvolvimento produziu a integração da *framework Spark* com os outros elementos do protótipo.

A integração foi viabilizada com o uso da biblioteca *PySpark*, porém antes de selecionar esta opção de configuração, foi testado o processamento com uso apenas da tecnologia *MapReduce*. Esta configuração apresentou resultados satisfatórios para o processamento em lote, porém com desempenho menor na criação de análises em tempo real. A criação de análises de BDA em um ambiente SAAS apresentou os melhores resultados, quando não considerados os custos do serviço.

Figura 33 – Medidas de desempenho e BDA

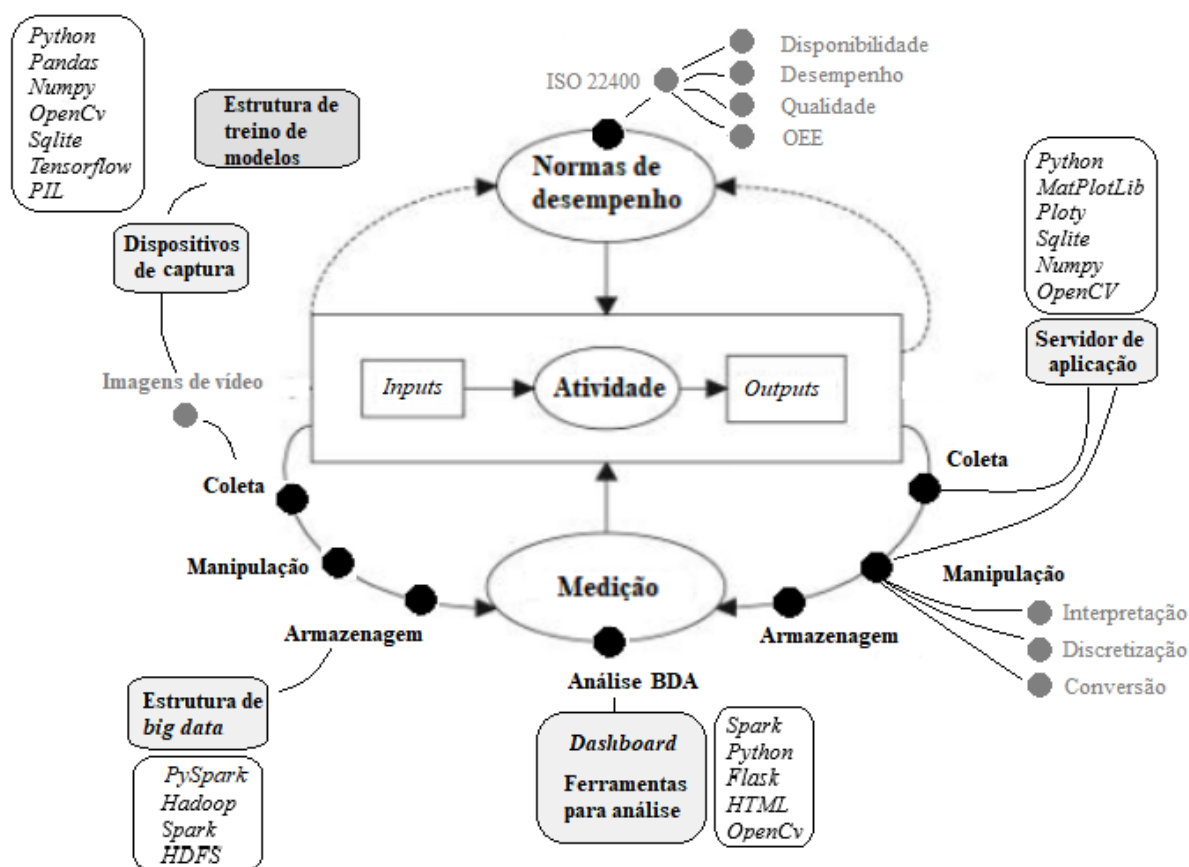


Fonte: elaborado pelo autor

O *Apache Spark* é um mecanismo multilíngue para estrutura de *big data* usado pela ciência de dados e aprendizado de máquina em um único nó ou *clusters* de equipamento que permite unificar o processamento em *batches* e *streaming* em tempo real, por meio de linguagens como *Python*, *SQL*, *Scala*, *Java* ou *R* (BELOV; TATARINTSEV; NIKULCHEV, 2021). Uma grande quantidade de bibliotecas como *SQL*, *MLlib*, *GraphX* e *Spark Streaming* são disponibilizadas na arquitetura do *Apache Spark*, sendo possível combina-las perfeitamente em um mesmo aplicativo.

A aplicação dos recursos computacionais nos componentes do protótipo e elementos do SMD, necessários para operacionalizar a coleta, manipulação, armazenagem e análise dos dados, são apresentados na Figura 34. Desta forma, complementando o modelo de transformação geral e modelo de referência *Integral Framework for Performance Measurement*.

Figura 34 - Componentes do protótipo e elementos do SMD



Fonte: elaborado pelo autor

#### 4.7 Avaliação do Artefato

A partir do planejamento das avaliações, definidas na fase de projeto do artefato, foram realizados testes funcionais e testes de sistemas para a análise preditiva de previsão de encerramento do processo e medidas de desempenho com suas características. O objetivo dos testes foi verificar se os requisitos do SMD proposto foram atendidos. Esta fase de avaliação do artefato na *design science research* corresponde a fase de uso e revisão no processo de construção de um SMD e a pós-implantação de projetos de do *big data*.

Como apresentado na Seção 4.5.5 deste Capítulo, algumas avaliações foram realizadas simultaneamente, uma vez que um mesmo teste permitiu verificar mais de um requisito de desempenho. Também são mencionados testes realizados durante a fase de desenvolvimento que ajudaram a complementar os testes funcionais e testes de sistemas.

A necessidade de representar possíveis cenários em teste de aplicações de *big data* (GUPTA; SHARMA, 2021), combinada com a dificuldade de obter equipamentos para

captura de imagens, curto intervalo de tempo para coleta e formação de uma base de dados significativa e a falta de empresas dispostas a terem sua área de produção filmada, inviabilizaram a avaliação do artefato em um ambiente real. Neste contexto, foi criado um *dataset* de operações em tornos universais horizontais com vídeos curtos de usinagem de peças, com objetivo de simular processos de produção e proporcionar a elaboração de análises descritivas como o OEE da máquina e análises preditivas como previsão de atraso em peças produzidas. A escolha por este equipamento tem como justificativa a dificuldade para medir o desempenho deste tipo de máquina e o viés do usuário ao realizar os registros, conforme Sadasivam et al. (2018), Perkins et al. (2012) e Willoughby et al. (2010).

Como obter conjuntos de dados para treinamento de modelos de *deep learning* é um desafio no desenvolvimento de aplicações, a criação de *dataset* específicos se apresenta como uma alternativa viável (ROH; HEO; WHANG, 2019). Assim, uma parte do conjunto de vídeos de operações foi usada para extração de imagens para treinamento de modelos de *deep learning*, por meio da estrutura desenvolvida e executada na forma de SAAS, com objetivo de identificação de ações durante o processo de produção. Outra parte do conjunto de pequenos vídeos de operações permitiu criar uma base de filmes de forma a simular vários dias de produção de peças usinadas, que corresponderam a um total de aproximadamente 160 horas de gravação e 631 vídeos.

Após o treinamento de modelos de *deep learning* para classificar as ações, eles foram disponibilizados para o protótipo por meio do servidor de aplicação, conforme previsto no diagrama de caso de uso, elaborado na fase de projeto. Os modelos de *deep learning* treinado também foram usados na plataforma SAAS, porém em uma cópia do programa dos dispositivos de captura, simulando a coleta das 160 horas de gravação.

Esta operação foi realizada frente à capacidade de processamento da plataforma SAAS. Desta forma, a necessidade de *hardware* local com capacidade para processar grandes quantidades de dados foi evitada. Como resultado do processamento foram obtidas as interpretações de todas as simulações, sendo armazenadas no sistema de arquivos HDFS e usadas em testes funcionais e testes de sistema.

Entre os vídeos criados por meio do *dataset* de operações, foram selecionados conjuntos específicos de simulações de produção conforme os requisitos a serem avaliados. A entrada dos vídeos para as simulações do processo de produção teve praticamente o mesmo procedimento se fosse realizada por meio de um dispositivo de captura, sendo necessária apenas a mudança do programa para dispositivos de captura, uma vez que a linguagem *Python* trata estes dois tipos de entrada da mesma forma.

#### 4.7.1 Avaliação da Disponibilidade dos Resultados

Por meio de *browsers* de internet, em diferentes tipos de hardware, o *dashboard* foi acessado com objetivo de testar a disponibilidade contínua dos indicadores de desempenho pré definidos: índice de qualidade, índice de disponibilidade, índice de eficiência, tempo de execução, principais operações, OEE, e processo de produção, além do histórico de operações. Também foi analisada a possibilidade de interrupções no serviço da aplicação, frente ao processamento ocorrido em outros elementos do sistema para geração das informações, a capacidade de acompanhamento dos eventos em tempo real ou quase real e a precisão dos valores calculados para as medidas de desempenho definidas. Os resultados da análise preditiva para previsão de encerramento do processo produtivo foram verificados em um teste específico.

Para realização dos testes, o funcionamento do *dashboard* foi acompanhado em três simulações de operações, sendo cada uma delas executada em equipamentos diferentes. Como os dados relacionados à qualidade das peças produzidas na simulação não possuem origem nas imagens de vídeos, durante a validação dos valores das medidas de desempenho a quantidade de produção em conformidade foi considerada igual ao número de produtos finalizados. Desta forma, ocasionando um índice de qualidade sempre igual a 100%, porém sem comprometer a simulação, uma vez que durante o processo de programação foram realizados testes com diferentes quantidade de não conformidades.

A Tabela 6 apresenta o resultado final das três simulações analisadas e os valores das medidas de desempenho calculados antecipadamente que corresponderam às partições de equivalência válidas. Os resultados obtidos nas simulações dos processos de produção, durante o teste funcional para avaliar a validade das medidas de desempenho apresentaram valores próximos da classe de equivalência válida e permitiram considerar o resultado esperado desta característica como alcançado.

Tabela 6 - Resultado final das 3 simulações analisadas

Medida de desempenho	Simulação 1		Simulação 2		Simulação 3	
	Protótipo	Esperado	Protótipo	Esperado	Protótipo	Esperado
Índice de disponibilidade (%)	90,44	90	72,14	74	90,58	90
Índice de qualidade (%)	100	100	100	100	100	100
Índice de desempenho (%)	77,43	88	71,09	72	88,34	88

OEE (%)	82,76	79,20	51,28	53,28	80,02	79,20
---------	-------	-------	-------	-------	-------	-------

Fonte: elaborado pelo autor

Para avaliar a pontualidade das medidas de desempenho apresentadas, por meio do *dashboard*, foi realizado um teste de sistema, sendo esperado como resultado válido a não interrupção do serviço do *dashboard*. Esta característica foi avaliada simultaneamente com a validação dos valores das medidas de desempenho. O acompanhamento da aplicação, por aproximadamente uma hora em três momentos distintos, durante a verificação dos cálculos que analisaram a viabilidade de modificação das medidas de desempenho usando dados não estruturados de imagens, permitiu identificar apenas alguns raros problemas na geração de gráficos. Mesmo com as ocorrências não houve comprometimento dos cálculos das medidas de desempenho e sua utilização. Este problema ocorreu tanto em acessos por meio de computador como em dispositivos móveis.

A hipótese do problema identificado ter sua causa na necessidade de processamento e capacidade do *hardware* utilizado como servidor de aplicação, uma vez que todos os dispositivos de acesso apresentaram problema, justificou a repetição dos testes em outro equipamento. Os testes funcionais realizados em um *hardware* com maior capacidade de processamento para o servidor de aplicação, confirmaram a hipótese. Desta forma, o resultado alcançado para os requisito de desempenhos foi considerado satisfatório, uma vez que a solução para o problema inicialmente identificado foi encontrada e a *dashboard* pode ser usada como ferramenta de comunicação, disseminação de resultados e influenciar os usuários com a oferta de informações.

#### 4.7.2 Avaliação dos processos de coleta e manipulação de dados

A coleta de dados em um SMD pode ser analisada na perspectiva da execução de suas funções, bem como da infraestrutura necessária para os processos (FRANCO-SANTOS et al., 2007) e deve ser automatizada ao máximo, com objetivo de economizar tempo e esforços (CHOI, et al., 2020; BOURNE et al., 2000). Para confirmar a possibilidade da infraestrutura de suporte do SMD viabilizar o uso automatizado de imagens de vídeo interpretadas por modelos de *deep learning* como fonte de dados, um teste funcional foi realizado para analisar a confiabilidade do processo de coleta de dados e manipulação.

O teste analisou cinco simulações de operações de produção capturadas. Cada uma correspondendo a um cenário de fabricação, com objetivo de comparar as ações apresentadas

no vídeo e a interpretação realizadas do modelo *deep learning*. Inicialmente, parte das interpretações feitas pelo modelo não corresponderam ao processo. Neste contexto, foi realizado um novo treinamento do modelo com um número maior de imagens de cada ação, selecionadas a partir de um estudo detalhado do processo de produção. Este novo processo de treinamento apresentou melhores resultados de interpretação do modelo de *deep learning*.

A indicação de uma maior capacidade na interpretação das atividades realizadas pelos operadores dos tornos nos vídeos, após o novo treinamento e apresentadas na Tabela 7, foram suficientes para considerar o resultado do requisito como satisfatório, uma vez que parte dos novos erros de interpretação ocorreram em curtos intervalos de tempo, dentro de períodos com interpretações corretas e não interferiram significativamente na representação do ocorrido no processo de produção.

Tabela 7 - Capacidade na interpretação das ações

<b>Simulação</b>	<b>Principais operações</b>	<b>Precisão</b>
1	Setup/Corte Interno/Corte	74,5%
2	Carregamento/Setup/Corte	69,7%
3	Corte/Medida/Corte	78,8%
4	Parada/Setup/Corte	71,2%
5	Corte/Troca de Ferramenta/Corte	79,1%

Fonte: elaborado pelo autor

Também foram testadas duas estruturas de organização dos modelos de *deep learning*. Inicialmente foi treinado um modelo com todas as possíveis ações a serem interpretadas durante a fase de coleta e manipulação de dados em uma máquina.

Depois foram treinados modelos com apenas as ações referentes aos processos produtivos analisados. Os testes não apresentaram diferenças significativas de desempenho e precisão. Contudo, foi mantida a segunda configuração uma vez que os modelos de inteligência artificial menores poderiam ser treinados com maior facilidade.

#### **4.7.3 Avaliação dos processos de manipulação e armazenagem de dados**

A infraestrutura de suporte para manipular e armazenar os dados coletados é necessária para viabilizar as medidas de desempenho de um SMD (FRANCO-SANTOS et al.,



2007). Desta forma, para avaliar a confiabilidade das medidas de desempenho e consequentemente a viabilidade da infraestrutura envolvida com estes processos foi realizado um teste funcional que abrangeu o servidor de aplicação, programa para dispositivos de captura e estrutura de *big data*. O teste avaliou a manipulação dos dados coletados quanto a discretização das entradas, preparação para interpretação e intervalo entre análises. Para isso, considerou os requisitos de desempenho do protótipo referentes a discretização e interpretação das imagens coletadas. Também foi avaliada a capacidade dos dados armazenados representarem o processo de produção registrado frente a futuras demandas de dados para uso de BDA e criação de novas medidas de desempenho.

Para realização do teste foram usadas três simulações de processo de produção criadas a partir do *dataset* de operações, sendo cada uma composta por três tipos diferentes de operações e analisadas individualmente. A primeira etapa submeteu os vídeos das operações de produção ao programa para dispositivos de captura, simulando a entrada de imagens capturadas em tempo real. As entradas geraram interações entre os elementos do protótipo, conforme já detalhado no diagrama de sequência que resultou em registros de dados semi estruturados no sistema de arquivos HDFS da estrutura de *big data*.

Com uso da plataforma *Jupyter Notebook* e da biblioteca *PySpark*, os dados referentes aos processos de produção usados como cenários para o teste e interpretados pelo modelo de *deep learning* foram acessados na estrutura de *big data* e seus registros listados. A combinação da plataforma *Jupyter Notebook* e a biblioteca *PySpark* também foi usada para contar o número de registros correspondentes a cada processo de produção armazenado no sistema de arquivos da estrutura de *big data*, com objetivo de confirmar se todas as entradas foram analisadas e armazenadas, bem como validar toda a interação entre os elementos do protótipo.

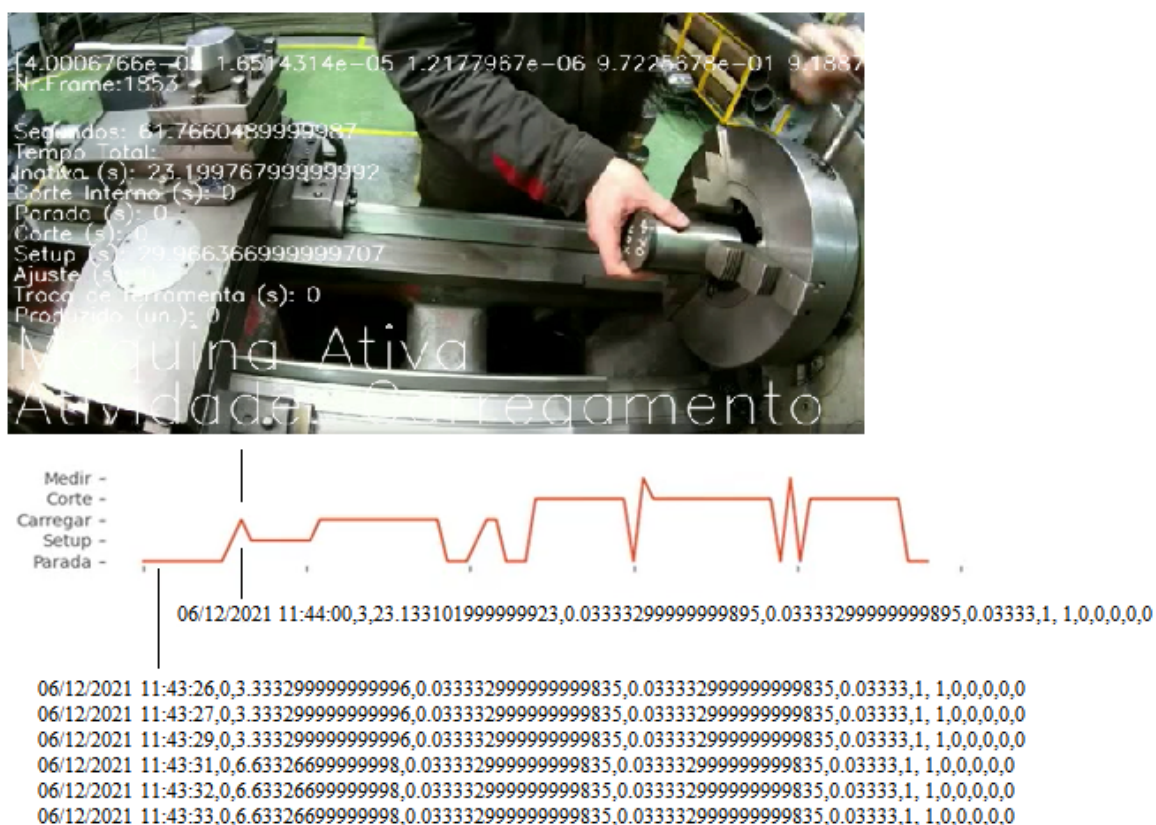
Após os levantamentos dos dados, a duração do vídeo juntamente com informações de *frames* por segundo e o intervalo entre cada análise forneceram o número de registros que deveriam estar armazenados no sistema de arquivos HDFS. Este dado foi comparado com o resultado obtido na consulta realizada com a combinação das ferramentas *Jupyter Notebook* e *PySpark*.

A partir da listagem dos registros correspondentes ao processo de produção e consequentemente das análises realizadas dos eventos pelo modelo de inteligência artificial, foi avaliado se o processo de discretização das imagens, o intervalo entre classificações de ações e o formato dos registros armazenados possuíam a capacidade de representar o cenário em futuras consultas. Para isso, representações gráficas do processo de produção como as

apresentadas em tempo real pela *dashboard*, foram geradas a partir dos registros, bem como os valores das medidas de desempenho. As representações gráficas do processo de produção foram comparadas com uma nova simulação de entrada do vídeo. O valor esperado nesta análise era uma igualdade entre a ação indicada na representação gráfica e registros listados frente a operação apresentada no vídeo, conforme apresentado na Figura 35.

O teste funcional descrito apresentou resultados satisfatórios para todos os requisitos de desempenho. O número de registros armazenados foi igual ao calculado a partir das informações dos vídeos usados nas simulações. A comparação entre a representação gráfica do processo de produção e os registros listados na consulta dos arquivos HDFS na estrutura de *big data*, com a nova entrada de imagens apresentaram resultados iguais em 96% das verificações. Quanto à comparação dos valores das medidas de desempenho calculados e apresentados durante o processo de captura das imagens, não foram notadas diferenças significativas, de forma a comprometer qualquer resultado.

Figura 35 – Representação de registros armazenados na estrutura de *big data*



Fonte: elaborado pelo autor

#### 4.7.4 Avaliação de análise preditiva do processo de fabricação

Como a análise preditiva compreende técnicas para prever resultados futuros (LEPENIOTI et al., 2020a; CAMM et al., 2020; SIOW; TIROPANIS; HALL, 2018; SOLTANPOOR; SELLIS, 2016; GANDOMI; HAIDER, 2015; DAVENPORT, 2013b), o teste funcional para previsão do processo de produção utilizou 10 simulações entre os vídeos criados, de forma a verificar qual a capacidade do protótipo neste requisito. Para realização do teste, cada vídeo foi submetido ao protótipo de SMD, com objetivo de simular a captura de imagens em um ambiente de produção. Os vídeos foram acompanhados e os dados de previsão do processo coletados, por meio das opções do *dashboard*, além do resultado final de cada simulação.

Para cada momento de execução da análise preditiva, foi necessário um modelo de *deep learning* treinado com as representações gráficas e os resultados finais do processo de produção. Os dados foram obtidos a partir do processamento realizado na plataforma SAAS e permitiram criar as representações gráficas necessárias. A Tabela 8 apresenta os valores das análises de cada simulação em quatro momentos distintos, bem como partição válida para cada simulação com o resultado final do processo de produção considerando a variável de prazo de conclusão como previsto e atrasado.


Tabela 8 - Resultado da análise preditiva para previsão de encerramento

Sim	Par. válida	Processo concluído				Término	
		10%	25%	50%	75%	Resultado	Tempo
1	Prv	Prv	Prv	Prv	Prv	Prv	14m32s
2	Prv	Prv	Prv	Prv	Prv	Prv	13m15s
3	Prv	Atr	Atr	Prv	Prv	Prv	14m57s
4	Atr	Prv	Prv	Prv	Atr	Atr	17m15
5	Atr	Prv	Atr	Prv	Atr	Atr	16m59
6	Atr	Prv	Atr	Prv	Prv	Prv	17m08
7	Atr	Prv	Atr	Atr	Prv	Prv	18m50
8	Atr	Prv	Atr	Atr	Atr	Atr	18m28
9	Atr	Prv	Prv	Atr	Atr	Atr	17m22
10	Prv	Atr	Atr	Prv	Prv	Prv	13m47s

Fonte: elaborado pelo autor

A Figura 36 apresenta a representação gráfica da análise de previsão de encerramento do processo de produção. Nesta representação, o tempo decorrido comparado com o previsto para execução do processo define o tamanho da esfera e o percentual indicado. O resultado da análise preditiva posiciona a esfera na linha para representação da previsão de atraso ou encerramento no prazo.

Figura 36 – Representação gráfica da análise preditiva



Fonte: elaborado pelo autor

Frente aos valores obtidos com a realização do teste, o resultado do requisito foi considerado satisfatório, quando considerada a previsão a partir da metade do tempo estimado para execução total do processo de produção. Conforme apresentado na Tabela 8, um total de oito simulações de processo de produção, conseguiram ter o resultado previsto igual ao real, com aproximadamente 75% do tempo total. A análise preditiva realizada com aproximadamente 50% do tempo também apresentou um resultado do requisito próximo do satisfatório, uma vez que sete simulações tiveram a previsão concretizada ao final. Contudo, nas previsões realizadas com 10% e 25% do tempo planejado a capacidade de previsão se mostrou menor, com 80% e 40% de erro respectivamente.

Com objetivo de auxiliar o acompanhamento do processo de produção, também foi criada uma análise descritiva com os registros dos eventos ocorridos. Este recurso proporcionou entender e apresentar o que aconteceu durante o processo.

#### 4.7.5 Avaliação do acompanhamento das operações em tempo real

A comparação em tempo quase real entre o processo de produção em andamento e padrões pré-estabelecidos do modelo de referência de SMD *Integral Framework for Performance Measurement*, definida como um requisito do protótipo, também foi avaliada por meio de um teste funcional. Desta forma, foram avaliadas as características referente à pontualidade e validade da medida de desempenho. O teste realizado teve como resultado

esperado identificar desvios no processo de produção monitorado e indicar anomalias no momento de sua ocorrência. Diferente da análise preditiva do processo de produção que utilizou informações armazenadas na estrutura de *big data*, esta medida de desempenho compara o andamento com padrões planejados e disponíveis ao sistema, por meio do banco de dados local *SQLite*.

A Tabela 9 apresenta as partições de equivalência válidas usadas para 10 simulações de processo de produção e as análises obtidas no teste funcional, enquanto a Figura 37 mostra como os desvios são representados na opção do *dashboard*. Para realização do teste foi utilizado o mesmo processo de produção, porém com desvios provocados em momentos, intensidade e formas diferentes. As partições válidas corresponderam às ações que o modelo de *deep learning* deveria indicar como não classificadas, neste teste representada pela limpeza de resíduos da usinagem, e operações conhecidas, porém não presentes no processo de produção padrão, como paradas não programadas.

Tabela 9 - Resultados acompanhamento das operações em tempo real

Sim.	Desvios não classificados		Operação não previstas	
	Partição válida	Resultado	Partição válida	Resultado
1	2min32s - 2min51s	Não identificado	5min15s - 7min	5min19s - 7min6s
	8min15s - 9min5s	8min16s - 9min7s	14min - 15min	14min4s - 15min6s
2	5min13s - 6min1s	5min15s - 6min01s	5min15s - 7min	5min18 - 7min6s
	8min16s - 9min5s	8min16s - 9min7s	14min - 15min	14min4s - 15min6s
3	10min15s - 10min55s	10min15s - 10min57s	5min15s - 7min	5min18s - 7min5s
	11 min - 12min15s	11min - 12min16s	14min - 15min	14min4s - 15min6s
4	10min15s - 10min55s	10min15s - 10min57s	5min15s - 7min	5min20s - 7min6s
	11min15 - 12min15s	11min14s - 12min16s	14min - 15min	14min4s - 15min6s
5	7min10s - 9min30s	Não identificado	5min15s - 7min	5min19s - 7min4s
			14min - 15min	14min4s - 15min6s
6	10min15s - 10min57s	10min15s - 10min59s	5min15s - 7min	5min21s - 7min7s
	11min15 - 12min18s	11min15s - 12min18s	14min - 15min	14min6s - 15min6s
7	2min32s - 2min51s	2min33s - 2min52s	5min15s - 7min	5min20s - 7min3s
	8min15s - 9min5s	8min16s - 9min7s	14min - 15min	14min6s - 15min6s
8	3min30s - 3min50s	3min33s - 3min52s	5min55s - 6min	Não identificado

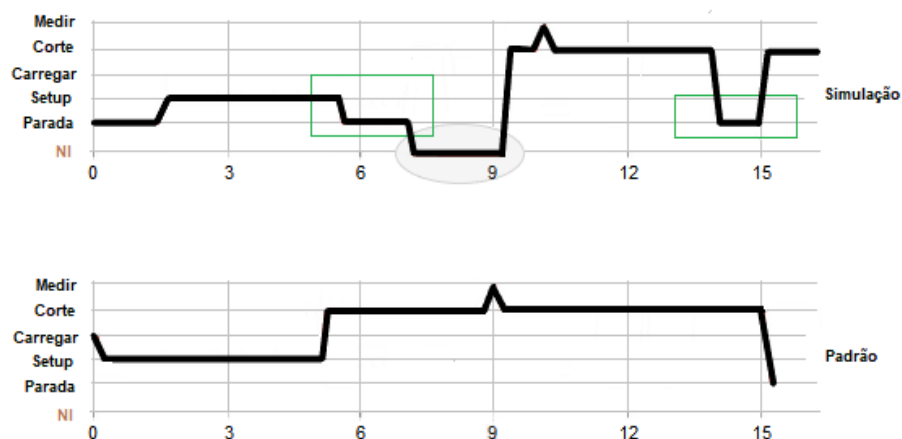
	6min15s - 7min5s	6min16s - 7min10s	15min - 17min	15min5s - 17min4s
9	5min13s - 6min8s	5min15s - 6min11s	5min15s - 7min	5min18 - 7min6s
	8min16s - 9min5s	8min16s - 9min7s	14min - 15min	14min1s - 15min2s
10	6min13s - 6min50s	6min15s - 6min51s	6min25s - 7min	6min20s - 7min26s
	8min16s - 9min5s	8min18s - 9min12s	10min - 11min	10min4s - 11min6s

Fonte: elaborado pelo autor

O teste funcional apresentou um resultado parcialmente satisfatório para o requisito, uma vez que na identificação de operações não conhecidas pelo modelo de *deep learning*, apenas três desvios não foram identificados, sendo que a duração destes eventos foram as menores dos simulados, com intervalos inferiores a 20 segundos e outras ocorrências apresentaram pequenas diferenças, conforme detalhado na Figura 37. Entretanto, a comparação entre o processo de produção monitorado e o planejado apresentou os problemas a serem trabalhados em novas versões do protótipo ou pesquisas:

- Dificuldade de diferenciar uma máquina desligada antes de iniciar o processo de produção de paradas ocorridas durante o funcionamento;
- Necessidade de indicar operações como carregamento da máquina no planejamento do processo de produção, de forma a estas não serem apresentadas como desvios;
- Mudanças viáveis na sequência de produção são indicadas como atraso pela representação.

Figura 37 – Acompanhamento das operações em tempo real



Fonte: elaborado pelo autor



desenvolvimento e avaliação do artefato, conforme os objetivos específicos da tese, uma vez que estes estão diretamente relacionados aos requisitos do protótipo.

#### **4.8.1 Infraestrutura para coleta, análise e armazenagem de dados**

Durante as fases de projeto e desenvolvimento do protótipo foi definida uma infraestrutura de SMD para coleta, análise e armazenagem de dados a partir de imagens de vídeo com uso de *deep learning*. A infraestrutura do SMD também representa um dos objetivos específicos desta tese. Com os resultados satisfatórios apresentados nos teste funcionais para avaliar a confiabilidade das medidas de desempenho e a infraestrutura para coleta automática e manipulação de dados, além manipulação e armazenagem, foi possível comprovar a viabilidade da infraestrutura planejada e que a mesma pode ser usada como parte dos recursos necessários para um SMD. A própria execução do experimento para o teste de avaliação da infraestrutura de manipulação e armazenagem, o qual também realizou análises de dados na arquitetura de *big data*, corrobora com a constatação.

Os resultados dos testes funcionais consequentemente indicaram o sucesso em atender o objetivo específico da tese. Contudo, também destacaram alguns pontos importantes para alcançar estes resultados e que devem ser observados para o uso prático do protótipo e a realização de novas pesquisas sobre o tema.

O primeiro ponto a ser destacado está na relação entre o treinamento do modelo de inteligência artificial com técnicas de *deep learning* e a confiabilidade das medidas de desempenho com uso de imagens. Assim, além de recursos como câmeras, rede para transferência de dados, *hardware* para servidores de aplicação, também deve ser planejada uma estrutura eficiente para treinamento de modelos de inteligência artificial. No desenvolvimento do protótipo, este recurso foi testado com o uso de *hardware* local, o que se mostrou inviável sem equipamentos com grande capacidade de processamento e configurações específicas para a tarefa. Também foi testado o uso de processamento para treinamento de modelos de *deep learning* na forma de SAAS, como alternativa para empresas sem estrutura avançada em computação, a qual se mostrou mais eficiente e eficaz quanto a implantação do ambiente computacional. Esta alternativa também se mostrou viável de ser estendida para todos outros componentes do protótipo de SMD, como a arquitetura de armazenagem para *big data*, ferramentas para BDA, servidores de aplicações etc. Contudo, a transferência de dados e o custo dos serviços foram os dificultadores identificados no uso desta configuração.



Apesar da visão computacional ter avançado muito nos últimos anos e apresentar resultados promissores em ambientes de operação, proporcionados principalmente pelas técnicas de *deep learning* (ORHEI et al., 2021; ZHANG A. et al., 2021; LIU et al., 2020; PATEL; THAKKAR, 2020; SHANAHAN; DAI, 2020; VOULODIMOS et al., 2018; DAVENPORT, 2018; POUYANFAR; CHEN, 2017), ela representa um aspecto a ser analisado no uso do protótipo. Como o nível de precisão do modelo de *deep learning* e discretização de imagens não foram objetos de análises técnicas avançadas da área de computação, os vídeos usados na simulação para avaliar a identificação das operações corretamente, durante os testes funcionais, tiveram a posições para captura de imagens, intensidade de luz, resolução etc., quase que padronizados e estes fatores podem ter influenciado positivamente o processo de captura de imagens e interpretação.

Neste cenário, é importante considerar estas variáveis do ambiente de produção durante o projeto da infraestrutura, bem como durante sua operacionalização, de forma a proporcionar melhores resultados no processo de treinamento e interpretação das imagens, e conseqüentemente na confiabilidade e validade da medida de desempenho, além de evitar maiores trabalhos com temas da área da computação como algoritmos de tratamento de imagens e tecnologias para processamento.

Como forma de aumentar a confiabilidade e validade das medidas de desempenho e minimizar o efeito destas variáveis, também deve ser considerada no planejamento da coleta de dados o uso de vários *hardware* para captura de imagem, posicionados de forma o sofrerem ações diferentes do ambiente de produção e obter imagens a partir de outros ângulos. Neste contexto, o segundo ponto relevante identificado durante o desenvolvimento do protótipo, porém não avaliado nos testes funcionais, é o planejamento na captura de imagens por diferentes *hardware*, permitindo uma conferência das medições e minimizar possíveis efeitos das condições do local de operação do equipamento como iluminação, reflexos, vibrações etc.

A divisão de modelos de inteligência artificial, em versões menores, durante a fase de desenvolvimento, não apresentou vantagens quanto à eficiência e confiabilidade, porém esta configuração se mostrou mais interessante quando analisada a partir da facilidade de treinamento. Assim, com o uso desta configuração em um ambiente de operação do SMD, mudanças em medidas de desempenho exigirão treinamento apenas dos modelos relacionados à alteração. Esta mesma facilidade se aplica na implantação de novas medidas de desempenho, e trabalhar neste ponto pode auxiliar na evolução do próprio SMD. Durante o desenvolvimento e avaliação dos resultados, também foi percebida a vantagem de organização

destes modelos no servidor de aplicação, evitando o uso de versões ultrapassadas, uma vez que ele centraliza e permite a atualização.

Quanto aos recursos computacionais utilizados na infraestrutura do SMD, a combinação das plataformas *Hadoop*, linguagem *Python*, biblioteca de inteligência artificial *Tensorflow*, biblioteca de visão computacional *OpenCV* e ferramenta de processamento paralelo *PySpark*, se mostraram totalmente compatíveis. Estes componentes foram definidos conforme as necessidades apresentadas durante o processo de projeto e desenvolvimento do protótipo e atenderam as demandas de BDA e medidas de desempenho. Neste contexto, o uso do padrão UML mostrou ser um facilitador importante para o processo de especificação, construção e a documentação da estrutura de *software* de um SMD com as características propostas para o artefato desta pesquisa, além de auxiliar em sua avaliação e consequentemente na validação da pesquisa. Apesar do objetivo específico não ter a preocupação com temas da computação, a seleção dos recursos computacionais se mostrou de extrema importância e exigiu esforços consideráveis para sua conclusão.

#### **4.8.2 Medidas de desempenho com dados não estruturados a partir de imagens**

A avaliação das características de pontualidade, confiabilidade e validade das medidas de desempenho modificadas de forma a usar dados não estruturados de imagens, conforme estabelecido no objetivo específico da tese, mostra que as interpretações realizadas pelo modelo de *deep learning* são responsáveis pelo sucesso alcançado, bem como pelos problemas identificados. Assim, alguns pontos identificados durante as fases de projeto e desenvolvimento do protótipo devem ser analisados na aplicação prática do conhecimento alcançado com objetivo de aumentar a capacidade de interpretação.

O primeiro ponto a ser considerado é o treinamento dos modelos de inteligência artificial para interpretação das imagens. A falta de conjuntos de dados para treinamento de modelos de inteligência artificial em novas aplicações é comum (ROH; HEO; WHANG, 2019) e influencia diretamente a precisão das interpretações (NEUPANE; SEOK, 2020; ROH; HEO; WHANG, 2019). Esta dificuldade foi identificada na implantação das medidas de desempenho planejadas para o protótipo, uma vez que não existia uma base de dados formada, principalmente para interpretação de eventos que ocorriam com grandes intervalos de tempo nas operações de produção analisadas.

Neste cenário, a geração de *dataset* se apresentou como uma solução viável (ROH; HEO; WHANG, 2019) e foi adotada durante o desenvolvimento do protótipo. Como

resultados foram alcançadas uma maior capacidade de interpretação das imagens pelos modelos de *deep learning* e conseqüentemente um aumento da confiabilidade das medidas de desempenho. Contudo, esta ação exigiu uma parcela significativa de tempo para obtenção, seleção, tratamento e organização das imagens e deve ser analisada durante o planejamento para uso destas tecnologias na medição de desempenho. Também deve ser contemplado no planejamento das medidas de desempenho a realimentação dos *dataset* de treinamento dos modelos. Desta forma, a partir do uso da aplicação, as imagens obtidas passam a ser incorporadas ao conjunto.

Outra ação realizada para aumentar a confiabilidade e validade das medidas de desempenho e que precisa ser considerada no planejamento das medidas de desempenho é o estudo das operações presentes nos processos de produção ou executadas pelo equipamento a ser acompanhado. Nas fases de desenvolvimento e testes, esta ação teve como objetivo identificar possíveis situações que poderiam resultar em interpretações erradas do modelo de *deep learning*, durante o processo de coleta, como a dificuldade de diferenciar um equipamento desligado de paradas não programadas na produção. A partir da identificação destas possíveis situações, bem como de outras encontradas, os *dataset* de treinamento foram aperfeiçoados, sendo criadas mais classificações e aumentado o número de imagens em cada uma destas divisões.

A melhora no desempenho das interpretações pelos modelos de *deep learning*, frente a este aperfeiçoamento com estudo das possíveis situações que podem resultar em interpretações erradas, combinado com realimentação de *datasets*, a partir do uso da aplicação, indica que a definição de prazos para atualização dos conjuntos de dados e novos treinamentos também devem fazer parte do projeto das medidas de desempenho. O estudo das operações realizadas durante o processo de produção, também auxiliou na fase de avaliação do protótipo, uma vez que contribuiu para o planejamento dos testes, com informações para composição de novos possíveis cenários.

Rotinas para treinamento de modelos de *deep learning* que não utilizam *datasets*, mas a base de dados armazenada na estrutura de *big data*, como na análise preditiva do processo, também devem ser analisados durante o projeto e revisão das medidas de desempenho. Mesmo sendo realizados em uma estrutura de *big data* na forma de SAAS, a qual proporciona maior capacidade de processamento, ou em *cluster* de equipamentos para execução em paralelo, as rotinas para seleção dos dados e a grande quantidade de modelos de *deep learning* a serem treinados, se mostraram como pontos a serem considerados para um uso prático do recurso, uma vez que demandam mão de obra capacitada.

Como mencionado na análise da infraestrutura do artefato, o planejamento da captura de imagens pode influenciar a confiabilidade e validade da medida de desempenho. Algumas variáveis como vibração, posição etc. podem se tornarem dificultadores, uma vez que a qualidade de uma imagem pode ser útil para uma medida de desempenho e não suficiente para outra. Durante os testes na fase de programação foi necessário selecionar formas de tratamento de imagens com objetivo de minimizar estes efeitos. Assim, esses dificultadores e limitações de medição devem ser considerados no planejamento e uso das medidas de desempenho.

O intervalo entre as interpretações de *frames*, obtidas a partir da discretização das imagens, é outro ponto importante a ser analisado durante o planejamento de medidas de desempenho, uma vez que impacta em sua validade e confiabilidade. Esta preocupação é justificada, uma vez que cada interpretação pode representar no mínimo um novo registro do evento na arquitetura de *big data*.

Neste contexto, algumas medidas de desempenho podem necessitar do armazenamento de dados a cada fração de segundos, exigindo assim maior capacidade de processamento para as análises do modelo de *deep learning*. Geralmente esta necessidade é combinada com o uso da estrutura de *big data*. Contudo, em algumas situações a medição pode exigir apenas registro de interpretações em intervalos de minutos e não utilizar a arquitetura de armazenagem e processamento paralelo.

#### **4.8.3 Análises descritivas e preditivas com uso de BDA e visão computacional**

Armazenar grandes quantidades de dados é uma das funções mais importantes das plataformas de *big data* (BELOV; TATARINTSEV; NIKULCHEV, 2021) e a possibilidade de coletar automaticamente os dados a partir de vídeos sem a necessidade de ações humanas, além de análises em intervalos menores para interpretação das imagens, viabilizaram a criação de uma grande quantidade de registros. Isso contribuiu para alcançar o objetivo específico de criar análises descritivas e preditivas a partir de dados não estruturados de imagem com uso de técnicas de BDA.

Contudo, além desta capacidade de armazenar uma grande quantidade de dados interpretados, foi necessário analisar outros pontos importantes no desenvolvimento e uso das análises descritivas e preditivas. O uso de redundâncias de dados, sem a necessidade de relacionamento entre registros, foi um dos principais pontos facilitadores identificados, pois permitiu armazenamentos específicos para cada análise com repetição de campos e dados.

Conseqüentemente este estilo de armazenagem de dados, diferente das estruturas usadas em bancos de dados relacionais, facilitou o desenvolvimento das análises descritivas e preditivas quanto à programação, não exigindo, por exemplo, a junção de registros. O armazenamento específico para cada análise também evitou o tratamento de dados após a interpretação, uma vez que estes foram estruturados conforme a necessidade de uso, sem a preocupação com o reaproveitamento em aplicações futuras.

A combinação das técnicas de *deep learning*, visão computacional e BDA podem permitir que operações nas quais sensores não são viáveis, como tarefas com intensa ação humana, sejam registradas com um alto nível de detalhamento e eventos que antes não seriam registrados em apontamentos manuais passam a ser identificados. Desta forma, o grande número de registros armazenados na arquitetura de *big data* também proporciona análises descritivas de diagnóstico mais completas.

A capacidade para processar grandes quantidades de registros armazenados na arquitetura de *big data* se mostrou um fator importante para o sucesso do BDA. Tanto o processamento, paralelo com uso de *cluster* de equipamentos na plataforma *Hadoop Spark*, quanto a execução em infraestruturas de terceiros na forma de SAAS, apresentaram resultados satisfatórios e influenciaram diretamente na pontualidade para tomada de decisão com análises descritivas, e na confiabilidade e validade quando utilizada para treinamentos de modelos de *deep learning* aplicados em análises preditivas. Contudo, as características das duas alternativas são pontos relevantes a serem analisados durante o planejamento.

Outro ponto importante na criação das análises descritivas e preditivas foi a definição de uma estrutura para acesso, análise e apresentação de resultados, pois além de viabilizar o atendimento de demandas específicas de informações para tomada de decisão, também permitiu testes para criação de novas medidas de desempenho sem a necessidade de alteração do sistema. Entre os recursos computacionais utilizados na criação das análises de BDA, foi possível identificar a facilidade de uso do ambiente *Jupyter Notebook* com a linguagem *Python*, combinados a interface *PySpark*.

#### **4.8.4 Painel de indicadores de desempenho**

Considerada dentro da infraestrutura do SMD, a disseminação de informações, junto com o processo de gestão da informação (FRANCO-SANTOS et al., 2007; NEELY, 1998), fomentou o objetivo específico da tese de propor um painel de indicadores de desempenho considerando as características de dados coletados, armazenados, manipulados e analisados a

partir de imagens e vídeos, concretizado por meio do desenvolvimento de um *dashboard*. Os testes realizados na avaliação da disponibilidade dos resultados quanto à validade e pontualidade das medidas de desempenho mostraram que esse objetivo específico foi atingido, uma vez que todos os requisitos para o *dashboard* foram atendidos.

Como o desenvolvimento desta parte do protótipo não tinha o objetivo de criar novos conhecimentos, mas apenas ser uma forma de completar a infraestrutura do SMD e demonstrar o uso das técnicas de visão computacional, *deep learning* e BDA, para medição de desempenho, apenas dois pontos considerados relevantes são destacados. O primeiro é a possibilidade de usar a integração visão computacional e *deep learning* para viabilizar medidas de desempenho de usos interativos em tempo real. Assim, mesmo sem a implantação da arquitetura de *big data* nas etapas iniciais do desenvolvimento do protótipo, o *dashboard* conseguiu proporcionar às medidas de desempenho, relacionadas ao OEE, atualizações automáticas com curtos intervalos de tempo, fornecendo informações para controles em tempo quase real, o que representa um benefício para os SMDs.

O segundo ponto a ser destacado na avaliação deste objetivo específico da tese é o uso do OEE e as medidas de desempenho que fazem parte de sua composição. Por serem medidas de desempenho amplamente conhecidas e documentadas, como no padrão ISO 22400, não ocorreram problemas na apresentação de seus resultados. Contudo, apesar da infraestrutura do SMD proporcionar a adoção de elementos gráficos para representação das informações, a dificuldade de definir um formato de apresentação do resultado da análise preditiva, principais operações e histórico do processo, apresentadas no *dashboard*, demonstrou a necessidade de estudar qual a melhor alternativa de disponibilizar as informações para os usuários e tomadores de decisão, uma vez que este pode contribuir para o desenvolvimento dos SMDs.

#### **4.8.5 Fases de desenvolvimento do protótipo**

Como mencionado no Terceiro Capítulo da tese, o qual aborda o delineamento da pesquisa, foi possível constatar, durante a aplicação do método de pesquisa, uma convergência entre o processo de desenvolvimento de um SMD e as fases para operacionalização de um projeto de *big data*, além das fases do próprio *design science research*.

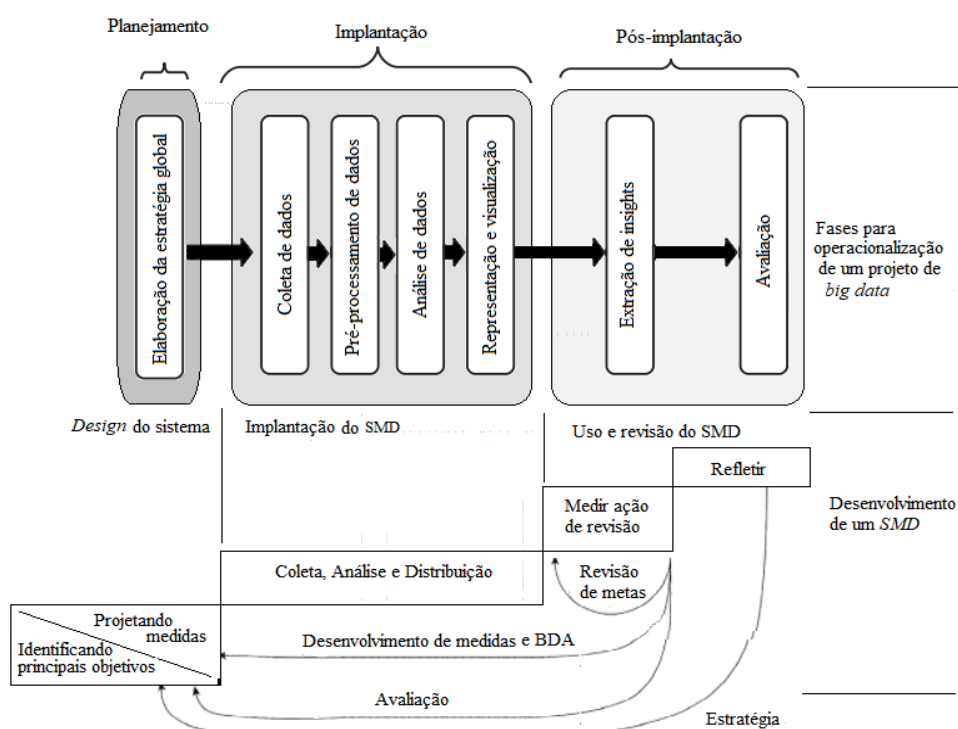
A convergência identificada é demonstrada na Figura 39, a partir do processo iterativo de desenvolvimento de um SMD, descrito por Bourne et al. (2000) e que apresenta as mesmas fases indicadas por Keathley e Van Aken (2013), e o conjunto de fases para um projeto de *big data* abordadas por Mousannif, et al. (2016). Esta convergência pode ser considerada uma

sequência de desenvolvimento do protótipo de SMD quando usadas técnicas de BDA, *deep learning* e visão computacional.

O primeiro ponto convergente da sequência é a necessidade de identificar, durante o processo de desenvolvimento do SMD, os objetivos do negócio e expectativa das partes interessadas, conforme apresentado por Gutierrez et al., 2015 e Martins et al., 2014, e o planejamento do projeto de *big data* que tem como função estabelecer os propósitos da implantação (MOUSANNIF, et al. 2016). Ainda na fase de planejamento a elaboração da estratégia global do projeto de *big data* (MOUSANNIF, et al. 2016), indica a necessidade de definir quais informações serão levantadas para tomada de decisão. Da mesma forma, Gutierrez et al. (2015), Lohman; Fortuin, Wouters, (2004) e Bourne et al. (2000) preveem o planejamento das medidas e indicadores de desempenho derivados da estratégia.

Apesar deste alinhamento do propósito do SMD com a estratégia e objetivos da organização não ter sido abrangido pelo protótipo desenvolvido, uma vez que se buscou uma maior generalização do artefato, as medidas de desempenho selecionadas a partir do padrão ISO 22400, cumpriram a exigência das duas abordagens e serviram de base para as outras ações do processo de desenvolvimento. Esta estratégia, de iniciar o projeto de SMD com técnicas de BDA a partir de medidas de desempenho já consolidadas, se mostra uma alternativa viável, quando o uso do *big data* não possui um objetivo específico.

Figura 39 – Convergência entre desenvolvimento de SMD e projeto de *big data*



Fonte: elaborada pelo autor

As duas abordagens também convergem em suas primeiras fases quanto a infraestrutura tecnológica necessária para medição de desempenho, processamento de dados, melhor estrutura para armazenamento, meios de acesso, além de formas para manter seguras as informações adquiridas. Desta forma, frente a necessidade de proporcionar, além da economia de tempo e esforços no processo de medição, a consistência das informações geradas e disponibilizadas (BOURNE et al., 2000), a pesquisa propôs uma infraestrutura para coleta, armazenagem e análise de dados não estruturados de imagens de vídeos, com as técnicas de *deep learning* e BDA.

A infraestrutura do SMD teve como ponto de partida as medidas de desempenho selecionadas e o modelo de referência *Integral Framework for Performance Measurement* apresentado por Rouse e Putterill (2003). Porém, como o foco da pesquisa não foi explorar recursos computacionais, mas seu uso em SMD, análises técnicas da área da computação não foram realizadas e os estudos para este elemento do protótipo ficaram restritos na seleção de alternativas que atendessem os requisitos de forma satisfatória.

As fases de implantação do SMD e do projeto de *big data* é o segundo ponto de convergência identificado na pesquisa. Como apresentado por Mousannif, et al. (2016) nesta fase do projeto de *big data* são definidos os processos e formas para coleta de dados, o pré-processamento e manipulação dos dados, e conversão de formatos, além de disponibilizar informações, por meio de um conjunto de análises avançadas de dados e visualização dos resultados alcançados. Da mesma forma, Nudurupati et al. (2011), Lohman, Fortuin, Wouters, (2004) e Bourne et al. (2000) indicam que nesta fase são estabelecidos os sistemas e procedimentos a serem utilizados nos processos de coleta, comparação, classificação e distribuição de dados para que a medição seja realizada regularmente. Estas fases foram contempladas na presente tese pelo projeto, desenvolvimento por meio da programação e avaliação do protótipo, conforme descrito no decorrer deste capítulo.

O processo de operacionalização de um projeto de *big data* prevê uma terceira fase definida como pós-implantação, dividida em duas etapas: extração de *insights* e avaliação da implantação. Estas etapas convergem para a fase de uso e revisão do processo de desenvolvimento do SMD e possuem objetivos semelhantes.

No uso do SMD são analisados os resultados da medição com objetivo de avaliar a eficiência e eficácia das operações e verificar se as estratégias foram implantadas com sucesso (GUTIERREZ et al., 2015; LOHMAN; FORTUIN; WOUTERS, 2004; BOURNE et al., 2000), por meio de medidas de desempenho ou ferramentas de BDA. Da mesma forma, a



extração de *insights* a partir do grande volume de dados coletados e manipulados (MOUSANNIF, et al. 2016; MARR, 2015a), por meio de diferentes tipos de análises, é compreendida na operacionalização de projetos de *big data*. O protótipo desenvolvido contemplou estas fases por meio do *dashboard*, com medidas de desempenho modificadas de forma a apresentar resultados em tempo quase real e uma análise preditiva, além da estrutura para análises avançadas de dados, funcionando como ferramenta de BDA.

O segundo objetivo da fase de pós-implantação do *big data* trata da avaliação do processo, de forma a garantir que o sistema se mantenha atualizado frente às mudanças do ambiente da organização (MOUSANNIF, et al. 2016). A revisão e atualização de SMD também prevê mudanças com base nos ambientes internos e externos da organização, e são consideradas tão importantes quanto o desenvolvimento e implantação (BRAZ; SCAVARDA; MARTINS, 2011). Desta forma, o SMD requer a revisão constante em diferentes níveis, incluindo um mecanismo eficaz de análise das metas e padrões, processos para desenvolver medições individuais conforme o desempenho e a mudança das circunstâncias, e verificar periodicamente o conjunto completo de medidas em uso (BOURNE et al., 2000). Neste processo interativo, as medidas de desempenho do SMD são ajustadas ou mesmo desenvolvidas, conforme mais informações sobre estratégia, clientes, processos, ambiente etc., se tornam disponíveis (LOHMAN; FORTUIN; WOUTERS, 2004; BOURNE et al., 2000). O protótipo apresenta um conjunto de ferramentas usadas durante o processo de desenvolvimento de análises de BDA e aperfeiçoamento das medidas de desempenho que podem ser usadas com este objetivo.

## 5 CONCLUSÕES

O objetivo principal desta tese foi desenvolver um protótipo de SMD para uso de dados não estruturados de imagens de vídeo. Assim, foi possível verificar como se pode aprimorar os SMDs com uso das técnicas de BDA e *deep learning* e auxiliar na tomada de decisão a partir deste tipo de dados não estruturados. Após alcançar o objetivo principal da tese, foi também possível identificar como as características dos SMDs sofrem impacto do uso dessas técnicas durante suas fases de *design*, implantação, uso e revisão.

Entre as características dos SMDs, a infraestrutura de suporte se mostra com o recurso que sofre maior impacto com o uso de técnicas de BDA e *deep learning*. Esta infraestrutura de suporte proposta modifica o processo de tomada de decisão ao viabilizar a criação ou alteração das medidas de desempenho e a disponibilidade de dados para BDA, anteriormente inviáveis pelas dificuldades na coleta automática de dados detalhados de eventos, processamento imediato das medições e capacidade de armazenar grandes quantidades de registros.

Desta forma, ao proporcionar um processo de coleta de dados automático, rápido e padronizado, juntamente com a capacidade de armazenar e processar grandes quantidades de registros, a infraestrutura de suporte proposta, influencia as medidas de desempenho e BDA, quanto as propriedade de validade, pontualidade e confiabilidade, além de impactar em questões para estabelecimento de procedimentos do sistema.

Como a validade de uma medida de desempenho consiste na precisão de representar o que está sendo avaliado (AL-SARMI; AL-HEMYARI, 2014; AL-TURKI; DUFFUAA, 2003), a capacidade da infraestrutura de suporte do protótipo em realizar uma grande quantidade de medições em intervalos menores de tempo e interpretar os dados coletados rapidamente de forma padronizada, influencia positivamente esta propriedade. Esta maior validade das medidas de desempenho é alcançada mesmo sem o uso de uma arquitetura de *big data*, usando apenas técnicas de *deep learning* e visão computacional.

Contudo, ao incorporar a capacidade de armazenar e processar uma grande quantidade de registros detalhados, por meio da arquitetura de *big data*, essa infraestrutura de suporte aumenta expressivamente a validade das medidas de desempenho, além de proporcionar o uso de BDA. Esta maior validade das medidas de desempenho e uso de BDA são alcançados com a possibilidade de recriar com precisão cenários e eventos ocorridos a partir de dados armazenados e disponibilizar estas informações para a serem usadas em futuras demandas da organização ou análises avançadas de dados. A estrutura de *big data* também influencia, de

forma positiva, a validade das medidas de desempenho e análises de BDA ao potencializar, por meio do processamento de dados em tempo real, várias medições de um evento em diferentes dispositivos.

Outra forma de influência da infraestrutura de suporte proposta para o SMD na validade das medidas de desempenho está no estabelecimento de procedimentos para agregação das medições de desempenho. Como o processo para medir o desempenho pode ser realizado em um nível individual ou de grupos, quanto menor a agregação das medições, maior a precisão e conseqüentemente maior a validade da medida de desempenho. Esta menor agregação das medições é viabilizada com a diminuição dos custos relacionados ao processo de coleta e interpretação de dados, proporcionada pelo uso das técnicas de BDA e *deep learning* na infraestrutura de suporte.

Segundo Al-Turki e Duffuaa (2003), a pontualidade de uma medida de desempenho consiste em disponibilizar os resultados da medição para os usuários interessados no menor tempo possível, antes que eles percam seu valor para tomada de decisões ou diminuam a possibilidade de aproveitamento de uma oportunidade. Assim, quando se utiliza de interfaces, como *dashboards* e alertas, a infraestrutura de suporte também influencia a pontualidade da medida de desempenho.

O processo de desenvolvimento e avaliação do protótipo mostrou que apenas o uso de técnicas de *deep learning* com visão computacional, sem uma estrutura de *big data*, também proporciona uma maior pontualidade das medidas de desempenho, uma vez que a coleta, interpretação e análise dos dados são realizadas em quase tempo real. Porém, a maior capacidade de processamento de dados no momento de sua coleta, proporcionado pela estrutura de *big data* juntamente com dados armazenados, influencia positivamente o uso de BDA quanto a pontualidade. Isso torna mais fácil e rápida a elaboração das análises e disseminação dos resultados.

Tendo em vista que a confiabilidade de uma medida de desempenho representa a capacidade de fornecer informações iguais quando aplicada ao mesmo período de tempo e objeto (AL-SARMI; AL-HEMYARI, 2014), ao padronizar o processo de coleta de dados dos SMD, de forma a mitigar problemas relacionados aos usuários, a infraestrutura de suporte proposta aumenta a confiabilidade das medidas de desempenho e processos de BDA. Entre os problemas identificados, durante o processo de desenvolvimento do protótipo e que podem ser mitigados ou mesmo eliminados, são destacados: o viés de julgamento da necessidade de registro do evento, imprecisão nos intervalos de medição, interrupção do processo de produção para apontamentos, registros realizados de forma errada. A infraestrutura de suporte

do protótipo também aumenta a confiabilidade das medidas de desempenho e BDA, por meio da arquitetura de *big data*, quando usa sua capacidade de armazenar e processar grandes quantidades de registros na elaboração de análises descritivas de diferentes períodos ou na elaboração de análises preditivas.

Assim quanto maior o detalhamento dos dados coletados pela técnica de *deep learning* com visão computacional e a quantidade de registros armazenados e processados pela plataforma de *big data*, maior a validade, pontualidade e confiabilidade das medidas de desempenho e análises avançadas. Ao proporcionar, além da armazenagem dos dados, recursos para coleta de dados como parte de um processo contínuo ou para atender a demandas específicas de análise, a infraestrutura de suporte proposta também atende às indicações de Bourne et al. (2000) para um SMD eficiente. Da mesma forma, a infraestrutura de suporte do protótipo também influencia positivamente as propriedades essenciais para um bom SMD, apresentadas por Kennerley e Neely (2002b), uma vez que viabiliza análises preditivas que podem ser aplicadas para prever ocorrências no negócio e mudanças nas medidas de desempenho com o processo de coleta automática de dados.

O processo de avaliação do protótipo, corroborou com as afirmações de Nudurupati e Bititci (2005) quanto à dependência que os SMD têm das áreas da tecnologia da informação e ciência da computação para uso efetivo de sua infraestrutura de suporte, principalmente para operacionalização de modelos de inteligência artificial de técnicas de *deep learning*.

A primeira indicação desta dependência da área da computação está na necessidade de conhecimento para operacionalizar o ambiente computacional de *big data* com seus *software* para integração e configurações dos recursos de armazenagem e processamento paralelo. Durante o desenvolvimento do SMD, foram testadas duas configurações de ambiente para o protótipo. A primeira configuração executou operações em uma infraestrutura local, enquanto a segunda usou uma infraestrutura na forma de SAAS. Apesar das vantagens e desvantagens apresentadas por cada configuração do SMD, ambas exigiram conhecimentos específicos da ciência da computação para seu funcionamento.

Outro indicativo de dependência de conhecimentos das áreas de tecnologia da informação e ciência da computação, identificado na pesquisa é relacionado à visão computacional, pois mesmo utilizando técnicas de *deep learning* para classificação, a necessidade de planejamento na obtenção das imagens e tratamento, exigem conhecimentos específicos. Da mesma forma, o treinamento de modelos de inteligência artificial com técnicas de *deep learning* apresenta dependência da área da ciência da computação, quanto a

exigências sobre formas e parâmetros de processamento e conjuntos de dados a serem usados no processo.

Os procedimentos de criação dos *datasets* de imagens para treinamento de modelos de *deep learning*, considerados como um dos processos ligados ao uso do SMD, configuram outra dependência das áreas da ciência da computação e tecnologia da informação, uma vez que são parte fundamental na interpretação dos dados coletados e exigem conhecimentos específicos dos usuários. Para execução destes procedimentos são necessários conhecimentos relacionados à visão computacional, captura e tratamento de imagens, além do treinamento de modelos de *deep learning*.

Os *hardware* de baixo custo, fácil aquisição e sem recursos avançados, especificados entre os atributos do protótipo, para serem usados no processamento, armazenagem, transferência e análise de dados, também indicam uma dependência de conhecimentos específicos da ciência da computação. Mesmo com o uso da arquitetura de *big data* na forma de SAAS, a integração e operação desses equipamentos para viabilizar a captura de imagens, processamento e transmissão dos dados, exigem conhecimentos específicos e que devem ser considerados no planejamento de um SMD com técnicas de BDA e *deep learning*.

Por fim, a necessidade de conhecimentos das áreas de tecnologia da informação e ciência da computação, também se mostrou imprescindível no uso de ferramentas para análises avançadas de dados. Apesar de possuírem vasta documentação e serem planejados para facilitar a análise de grandes volumes de dados, esses recursos exigem conhecimento de pelo menos uma linguagem de programação, bibliotecas de integração a arquitetura de *big data* e configuração de ambientes de teste e execução, bem como formas de apresentar os resultados alcançados.

Diante das modificações no SMD identificadas e apresentadas, e da descrição detalhada do aprendizado adquirido durante o processo de construção do protótipo, que permite a generalização do conhecimento para uma classe de problemas, o objetivo principal da tese foi atingido. Também foram alcançados os objetivos específicos, uma vez que o protótipo desenvolvido com técnicas de BDA e *deep learning* atendeu todos requisitos estabelecidos e seu processo de desenvolvimento foi construído a partir de um quadro teórico e validado conforme o rigor exigido pelo método de pesquisa. Assim, o protótipo desenvolvido constitui uma importante contribuição no sentido de utilizar dados não estruturados de imagem para medição de desempenho e aprimoramento dos SMDs.

## **Limitações da pesquisa**

Apesar da importante contribuição da tese para o uso de SMD, as dificuldades de validação do protótipo em um ambiente organizacional e obtenção de imagens de processos produtivos reais, impediram a verificação de alguns aspectos e estabeleceram limitações para pesquisa. Entre as limitações da pesquisa pode se destacar a impossibilidade de análise do SMD nos três níveis apresentados por Neely, Gregory e Platts (1995), uma vez que foram utilizadas medidas de desempenho individuais no protótipo com foco na eficiência, sem quantificar a eficácia. Esta limitação também impediu analisar a capacidade de resposta do SMD para mudanças nos ambientes interno e externo da organização.

A impossibilidade de validação do protótipo desenvolvido em um ambiente real de produção também impactou a análise do processo de tomada de decisão. Apesar do artefato disponibilizar novos recursos que podem auxiliar neste processo, o aspecto não foi analisado considerando alterações nos ambientes interno e externo das organizações, bem como a comunicação, mudança de estratégia, disseminação das informações e pró-atividade dos usuários.

As questões de privacidade e ética na coleta dos dados são desafios para uso de *big data* nas organizações (SIVARAJAH et al., 2017; MARR, 2015a; WU, et al., 2013) e representam outra limitação da pesquisa, uma vez que as análises destes fatores, inerentes ao ambiente de operação do SMD, não foram realizadas. A própria dificuldade na obtenção de imagens para realização da pesquisa já evidencia a existência deste desafio e a importância do tema.

## **Propostas para o desenvolvimento de trabalhos futuros**

A partir das limitações da pesquisa, alguns trabalhos podem ser desenvolvidos para preencher lacunas existentes. São eles:

- Validar o protótipo desenvolvido em um ambiente real de produção com objetivos de analisar outros aspectos do processo de tomada de decisão, como pró-atividade dos usuários a partir da maior pontualidade das medidas de desempenho e análises de BDA;
- Desenvolver novas medidas de desempenho com uso das técnicas de *deep learning* e BDA com foco na eficácia de ações específicas;

- Levantar alternativa para minimizar as barreiras para uso de imagens de vídeo na medição de desempenho de pessoas, frente às questões de privacidade e ética;
- Analisar a capacidade de adaptação do protótipo a demandas de um ambiente real de produção e mudanças de estratégia;
- Realizar pesquisas empíricas, por meio da implantação do protótipo desenvolvido em organizações diversas, de forma a avaliar como um SMD com técnicas de DBA e *deep learning* se adapta a diferentes sistemas de produção.

## REFERÊNCIAS

- ABADI, M. et al. Tensorflow: A system for large-scale machine learning. In: **12th Symposium on operating systems design and implementation ({OSDI} 16)**, p. 265-283, 2016.
- AGHABABAEYAN, Z.; ABDELLATIF, M.; BRIAND, L., Black-Box Testing of Deep Neural Networks through Test Case Diversity. **arXiv preprint arXiv:2112.12591**, 2021.
- AGOSTINO, D; SIDOROVA, Y. A performance measurement system to quantify the contribution of social media: new requirements for metrics and methods. **Measuring Business Excellence**, 2016.
- AKEN, J.E. Management research based on the paradigm of the design sciences: the quest for field-tested and grounded technological rules. **Journal of management studies**, v. 41, n. 2, p. 219-246, 2004.
- AKTER, S. et al. How to improve firm performance using big data analytics capability and business strategy alignment?. **International Journal of Production Economics**, v. 182, p. 113-131, 2016.
- AL-SARMI, Abdullah M.; AL-HEMYARI, Zuhair A. Some statistical characteristics of performance indicators for continued advancement of HEIs. **International Journal of Quality and Innovation**, v. 2, n. 3-4, p. 285-309, 2014.
- ALEXANDER, A.; KUMAR, M.; WALKER, H. A decision theory perspective on complexity in performance measurement and management. **International Journal of Operations & Production Management**, 2018.
- AL-TURKI, U.; DUFFUAA, S. Performance measures for academic departments. **International Journal of Educational Management**, 2003.
- ANTONIOU, C. et al. Towards a generic benchmarking platform for origin–destination flows estimation/updating algorithms: Design, demonstration and validation. **Transportation Research Part C: Emerging Technologies**, v. 66, p. 79-98, 2016.
- ANWAR, M.; KHAN, S. Z.; SHAH, S. Z. A. Big data capabilities and firm’s performance: a mediating role of competitive advantage. **Journal of Information & Knowledge Management**, v. 17, n. 04, p. 1850045, 2018.
- ASSANDRE, J. A.; MARTINS, R. A. Big data e medição de desempenho: uma análise bibliométrica descritiva.. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 2019, Santos, 2019.
- ASSANDRE, J. A.; MARTINS, R. A. Analysis of Scientific Production on the use of Big Data Analytics in Performance Measurement Systems. Working paper, 2020a.
- ASSANDRE, J. A.; MARTINS, R. A. O uso de big data analytics em sistemas de medição de desempenho: uma revisão de estudos empíricos. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 2020, Fox do Iguaçu, 2020b.
- BAG, S. et al. Role of institutional pressures and resources in the adoption of big data analytics powered artificial intelligence, sustainable manufacturing practices and circular economy capabilities. **Technological Forecasting and Social Change**, v. 163, p. 120420, 2021.
- BARBA-GONZÁLEZ, C. et al. BIGOWL: knowledge centered big data analytics. **Expert Systems with Applications**, v. 115, p. 543-556, 2019.
- BAX, M. P. **Design science: filosofia da pesquisa em ciência da informação e tecnologia**. 2017.
- BELOV, V.; TATARINTSEV, A.; NIKULCHEV, E. Choosing a Data Storage Format in the Apache Hadoop System Based on Experimental Evaluation Using Apache Spark. **Symmetry**, v. 13, n. 2, p. 195, 2021.
- BHADANI, K. et al. Development and implementation of key performance indicators for aggregate production using dynamic simulation. **Minerals Engineering**, v. 145, p. 106065, 2020.



BHOSALE, S. T.; PATIL, T.i; PATIL, P. Sqlite: Light database system. **Int. J. Comput. Sci. Mob. Comput**, v. 44, n. 4, p. 882-885, 2015.

BITITCI, U. S. et al. Value of maturity models in performance measurement. **International journal of production research**, v. 53, n. 10, p. 3062-3085, 2015.

BITITCI, U. S.; CARRIE, A. S.; MCDEVITT, L. Integrated performance measurement systems: a development guide. **International journal of operations & production management**, 1997.

BITITCI, U. S.; TURNER, U.; BEGEMANN, C. Dynamics of performance measurement systems. **International Journal of Operations & Production Management**, 2000.

BOOCH, G.; RUMBAUGH, J.; JACOBSON, I. **UML: guia do usuário**. Elsevier Brasil, 2006.

BOURNE, M.; MELNYK, S.; BITITCI, U. S. Performance measurement and management: theory and practice. **International Journal of Operations & Production Management**, v. 38, n. 11, p. 2010-2021, 2018.

BOURNE, M.; BOURNE, P. **Handbook of Corporate Performance Management**. Chichester, UK: Wiley, 2011.

BOURNE, M. et al. Designing, implementing and updating performance measurement systems. **International journal of operations & production management**, 2000.

BOURNE, M. et al. Implementing performance measurement systems: a literature review. **International Journal of Business Performance Management**, v. 5, n. 1, p. 1-24, 2003.

BRAZ, R. G. F.; SCAVARDA, L. F.; MARTINS, R. A. Reviewing and improving performance measurement systems: An action research. **International Journal of Production Economics**, v. 133, n. 2, p. 751-760, 2011.

CAMM, J. D. et al. **Business analytics**. Cengage Learning, 2020.

CHEN, H.; CHIANG, R.H.L; STOREY, V.C. Business intelligence and analytics: From big data to big impact. **MIS quarterly**, p. 1165-1188, 2012.

CHOI, T.; SEO, Y. A Real-Time Physical Progress Measurement Method for Schedule Performance Control Using Vision, an AR Marker and Machine Learning in a Ship Block Assembly Process. **Sensors**, v. 20, n. 18, p. 5386, 2020

CHOLLET, F. **Deep learning with Python**. Simon and Schuster, 2021.

COPELAND, L. **A practitioner's guide to software test design**. Artech House, 2004.

DAUGHERTY, P. R.; WILSON, H. J. **Human+ machine: Reimagining work in the age of AI**. Harvard Business Press, 2018.

DAVENPORT, T. H. Analytics 3.0. **Harvard business review**, v. 91, n. 12, p. 64-72, 2013a.

DAVENPORT, T. H. What do we talk about when we talk about analytics? **Enterprise analytics, optimize performance, process and decision through big data**, p. 9-18, 2013b.

DAVENPORT, T. H. The AI advantage: How to put the artificial intelligence revolution to work. **MIT Press**, 2018.

DAVENPORT, T. H.; HARRIS, J. G. **Competição analítica: vencendo através da nova ciência**. Alta Books, 2020.

DE CARVALHO VICTORINO, M. et al. Uma proposta de ecossistema de big data para a análise de dados abertos governamentais concetados. **Informação & sociedade**, v. 27, n. 1, 2017.

- DEDIĆ, N.; STANIER, C. Towards differentiating business intelligence, big data, data analytics and knowledge discovery. In: International Conference on Enterprise Resource Planning Systems. **Springer**, Cham, 2016. p. 114-122.
- DESHPANDE, A. M. et al. Computer vision toolkit for non-invasive monitoring of factory floor artifacts. **Procedia Manufacturing**, v. 48, p. 1020-1028, 2020.
- DESHPANDE, P.S.; SHARMA, S.C.; PEDDOJU, Sateesh K. Predictive and prescriptive analytics in Big-data Era. In: **Security and data storage aspect in cloud computing**. Springer, Singapore, 2019. p. 71-81.
- DIVYA, K. S.; BHARGAVI, P.; JYOTHI, S. Machine learning algorithms in big data analytics. **International Journal of Computer Sciences and Engineering**, v. 6, n. 1, p. 64-70, 2018.
- DRABAS, T.; LEE, D. **Learning PySpark**. Packt Publishing Ltd, 2017.
- DRESCH, A.; LACERDA, D. P.; ANTUNES, José Antônio Valle. Design science research. In: **Design science research**. Springer, Cham, 2015. p. 67-102.
- ECCLES, R. G. The performance measurement manifesto. **Harvard business review**, n. February, p. 131–137, 1991
- ELKMASH, M. R. M.; ABDEL-KADER, M. G.; EL DIN, B. B.. An experimental investigation of the impact of using big data analytics on customers' performance measurement. **Accounting Research Journal**, 2021.
- FATTAH, A. The emergence of the analytics architect. **IBM Data Magazine**, 2014. Disponível em: <<http://ibmdatamag.com/2014/06/the-emergence-of-the-analytics-architect/>>. Acesso em: 12 dez. 2020
- FRANCISCHINI, A. S. N. FRANCISCHINI, P. G. **Indicadores de Desempenho: Dos objetivos à ação—métodos para elaborar KPIs e obter resultados**. Alta Books Editora, 2018.
- FRANCESCHINI, Fiorenzo; GALETTO, Maurizio; MAISANO, Domenico. **Designing performance measurement systems: theory and practice of key performance indicators**. Springer, 2018.
- FRANCESCHINI, F.; GALETTO, M.; MAISANO, D. **Management by measurement: Designing key indicators and performance measurement systems**. Springer Science & Business Media, 2007.
- FERNANDEZ, N. S. et al. Diseño de sistemas de medición de desempeño de proveedores: experiencias de un caso de estudio. **Production**, v. 22, n. 1, p. 43-57, 2012.
- FLEURY, A. Planejamento do Projeto de Pesquisa e Definição do Modelo Teórico. In: MIGUEL, Paulo A.M (org.). **Metodologia de pesquisa em engenharia de produção e gestão de operações**. Rio de Janeiro: Elsevier, 2010, pp.5-29.
- FORZA, C.; SALVADOR, F. Assessing some distinctive dimensions of performance feedback information in high performing plants. **International Journal of Operations & Production Management**, 2000.
- FRANCO-SANTOS, M. et al. Towards a definition of a business performance measurement system. **International Journal of Operations & Production Management**, v. 27, n. 8, p. 784-801, 2007.
- FRANCO-SANTOS, M.; LUCIANETTI, L.; BOURNE, M. Contemporary performance measurement systems: A review of their consequences and a framework for research. **Management accounting research**, v. 23, n. 2, p. 79-119, 2012.
- FREDERICO, G. F. et al. Performance measurement for supply chains in the Industry 4.0 era: a balanced scorecard approach. **International Journal of Productivity and Performance Management**, 2020.
- FREEMAN, H. Software testing. **IEEE instrumentation & measurement magazine**, v. 5, n. 3, p. 48-50, 2002.
- FURLAN, P. K.; LAURINDO, F. J. B. Epistemological grouping of published articles on big data analytics. **Transinformação**, v. 29, n. 1, 2017., v. 24, n. 2, p. 100-91, 2017.

- GANDOMI, A.; HAIDER, M. Beyond the hype: Big data concepts, methods, and analytics. **International journal of information management**, v. 35, n. 2, p. 137-144, 2015.
- GHAVAMI, P. **Big Data Analytics Methods**. De Gruyter, 2019.
- GOECKS, L.S. et al. Design Science Research in practice: review of applications in Industrial Engineering. **Gestão & Produção**, v. 28, 2021.
- GLOBERSON, S. Issues in developing a performance criteria system for an organization. **International Journal of production research**, v. 23, n. 4, p. 639-646, 1985.
- GOODFELLOW, I. et al. **Deep learning**. Cambridge: MIT press, 2016.
- GOUVÊA DA COSTA, S. E.; PINHEIRO DE LIMA, E. Processos: Uma Abordagem da engenharia para a gestão de operações. MIGUEL, PAC et al. **Metodologia de Pesquisa em Engenharia de Produção e Gestão de Operações**. Rio de Janeiro: Campus, p. 63-72, 2011.
- GRAHAM, I. et al. Performance measurement and KPIs for remanufacturing. **Journal of Remanufacturing**, v. 5, n. 1, p. 10, 2015.
- GUEDES, G.T.A. **UML 2-Uma abordagem prática**. Novatec Editora, 2018.
- GUPTA, D.; SHARMA, L.. Improved Combinatorial Algorithms Test for Pairwise Testing Used for Testing Data Generation in Big Data Applications. In: **Artificial Intelligence**. Chapman and Hall/CRC, 2021. p. 81-90.
- GUTIERREZ, D.M.; SCAVARDA, L.F.; FIORENCIO, L.; MARTINS, R.A.. Evolution of the performance measurement system in the Logistics Department of a broadcasting company: An action research. **International Journal of Production Economics**, v. 160, p. 1-12, 2015.
- GUPTA, M.; GEORGE, J. F. Toward the development of a big data analytics capability. **Information & Management**, v. 53, n. 8, p. 1049-1064, 2016.
- GULZAR, M., MARDANI, S., MUSUVATHI, M. White-box testing of big data analytics with complex user-defined functions. In: **Proceedings of the 2019 27th ACM Joint Meeting on European Software Engineering Conference and Symposium on the Foundations of Software Engineering**. 2019. p. 290-301.
- HOWSE, J. **OpenCV computer vision with python**. Birmingham: Packt Publishing, 2013.
- HWANG, G. et al. Developing performance measurement system for Internet of Things and smart factory environment. **International journal of production research**, v. 55, n. 9, p. 2590-2602, 2017.
- JÄÄSKELÄINEN, A.; ROITTO, J.. Visualization techniques supporting performance measurement system development. **Measuring Business Excellence**, 2016.
- JUUSO, E. K. Smart Adaptive Big Data Analysis with Advanced Deep Learning. **Open Engineering**, v. 8, n. 1, p. 403-416, 2018.
- LACERDA, D. P. et al. Design Science Research: método de pesquisa para a engenharia de produção. **Gestão & produção**, v. 20, n. 4, p. 741-761, 2013.
- LAKATOS, E. M.; MARCONI, M. A. **Fundamentos em metodologia científica**. 5.ed. São Paulo, Atlas, 2003.
- LEPENIOTI, K. et al. Machine learning for predictive and prescriptive analytics of operational data in smart manufacturing. In: **International Conference on Advanced Information Systems Engineering**. Springer, Cham, 2020a. p. 5-16.
- LEPENIOTI, K. et al. Prescriptive analytics: Literature review and research challenges. **International Journal of Information Management**, v. 50, p. 57-70, 2020b.

LIU, P.; QI, B.; BANERJEE, S. E.: An edge service framework for real-time intelligent video analytics. In: **Proceedings of the 1st international workshop on edge systems, analytics and networking**, 2018. p. 1-6.

LONG, S.; HE, X.; YAO, C. Scene text detection and recognition: The deep learning era. **International Journal of Computer Vision**, v. 129, n. 1, p. 161-184, 2021.

KAMBLE, S. S. et al. A performance measurement system for industry 4.0 enabled smart manufacturing system in SMMEs-A review and empirical investigation. **International Journal of Production Economics**, v. 229, p. 107853, 2020.

KAMBLE, S. S.; GUNASEKARAN, A.. Big data-driven supply chain performance measurement system: a review and framework for implementation. **International Journal of Production Research**, v. 58, n. 1, p. 65-86, 2020.

KANG, N. et al. A Hierarchical structure of key performance indicators for operation management and continuous improvement in production systems. **International Journal of Production Research**, v. 54, n. 21, p. 6333-6350, 2016.

KAPLAN, R. S.; NORTON, D. P. The balanced scorecard - measures that drive performance. **Harvard Business Review**, v. 70, n. 1, p. 71-9, 1992.

KAPLAN, R. S.; NORTON, D. P. Using the balanced scorecard as a strategic management system. 1996.

KAPLAN, R. S.; NORTON, D. P. **The strategy-focused organization: how balanced scorecard companies thrive in the new business environment**. Boston, MA, USA: Harvard Business School Publishing, 2001.

KEATHLEY, H.; VAN AKEN, E. Systematic literature review on the factors that affect performance measurement system implementation. In: **IIE Annual Conference. Proceedings**. Institute of Industrial and Systems Engineers (IISE), 2013. p. 837.

KEATHLEY-HERRING, H. An approach to quantify the factors that affect performance measurement system implementation. **Engineering Management Journal**, v. 29, n. 2, p. 63-73, 2017.

KENNERLEY, M.; NEELY, A. A framework of the factors affecting the evolution of performance measurement systems. **International journal of operations & production management**, 2002a.

KENNERLEY, M.; NEELY, A. A. Performance measurement frameworks: a review. Business performance measurement: **Theory and practice**, p. 145-155, 2002b.

KENNERLEY, M.; NEELY, A. A.. Measuring performance in a changing business environment. **International journal of operations & production management**, 2003.

KERZNER, H. Project management metrics, KPIs, and dashboards: a guide to measuring and monitoring project performance. **John Wiley & Sons**, 2017.

KHANRA, S.; DHIR, A.; MÄNTYMÄKI, M.. Big data analytics and enterprises: a bibliometric synthesis of the literature. **Enterprise Information Systems**, p. 1-32, 2020.

KIM, M. et al. A vision-based system for monitoring block assembly in shipbuilding. **Computer-Aided Design**, v. 59, p. 98-108, 2015.

KITCHIN, R. Big Data, new epistemologies and paradigm shifts. **Big data & society**, v. 1, n. 1, p. 2053951714528481, 2014.

KLEIN TANK, K. **Continuous Auditing & Continuous Monitoring in a Broader Perspective**. Twente University, 2011.

KOTHARI, C.R. **Research methodology: Methods and techniques**. New Age International, 2004.

- KWON, O.; LEE, N.; SHIN, B. Data quality management, data usage experience and acquisition intention of big data analytics. **International journal of information management**, v. 34, n. 3, p. 387-394, 2014.
- LAMBA, H. S.; DUBEY, S. K. Analysis of requirements for big data adoption to maximize IT business value. In: 2015 4th **International Conference on Reliability, Infocom Technologies and Optimization**. IEEE, 2015. p. 1-6.
- LECUN, Y.; BENGIO, Y.; HINTON, G.. Deep learning. **Nature**, v. 521, n. 7553, p. 436-444, 2015.
- LEPENIOTI, K. et al. Prescriptive analytics: Literature review and research challenges. **International Journal of Information Management**, v. 50, p. 57-70, 2020.
- LIMA, R.H.P.; CARPINETTI, L.C.R. Desenvolvimento e aplicação de uma ferramenta informatizada para medição de desempenho e melhoria contínua. **Produto & Produção**, v. 11, n. 2, 2010.
- LI, H.; OTA, K.; DONG, M. Learning IoT in edge: Deep learning for the Internet of Things with edge computing. **IEEE network**, v. 32, n. 1, p. 96-101, 2018.
- LIU, L. et al. Deep learning for generic object detection: A survey. **International journal of computer vision**, v. 128, n. 2, p. 261-318, 2020.
- LOHMAN, C.; FORTUIN, L.; WOUTERS, M.. Designing a performance measurement system: A case study. **European journal of operational research**, v. 156, n. 2, p. 267-286, 2004.
- LUTZ, M. **Programming python**. " O'Reilly Media, Inc.", 2001.
- MAHAMI, H. et al. Automated progress controlling and monitoring using daily site images and building information modelling. **Buildings**, v. 9, n. 3, p. 70, 2019.
- MARCH, S. T.; SMITH, G. F. Design and natural science research on information technology. **Decision support systems**, v. 15, n. 4, p. 251-266, 1995.
- MARCHAND, M.; RAYMOND, L. Performance measurement and management systems as IT artefacts: Characterising, contextualising and valuing their effective use in SMEs. **International Journal of Productivity and Performance Management**, 2018.
- MARTINS, R. A. **Sistemas de medição de desempenho: um modelo para estruturação do uso**. 1998. 248 p. Tese (Doutorado em Engenharia de Produção) - Escola Politécnica, Universidade de São Paulo, São Paulo, 1998.
- MARTINS, R. A. Use of Performance Measurement Systems : Some Thoughts Towards a Comprehensive Approach. In: NEELY, A. (Ed.). . **Performance Measurement 2000 – Past, Present and Future**. Cranfield, Bedfordshire, UK: University of Cambridge, 2000. p. 363–370
- MARTINS, R. A. Princípios da Pesquisa Científica. In: MIGUEL, P. A. C. (Ed.). **Metodologia da Pesquisa em Engenharia de Produção e Gestão de Operações**. 2a. ed. Rio de Janeiro: Elsevier: ABEPRO, 2012. p. 7–31.
- MARTINS, R. A. et al. Designing a Performance Measurement System: a case study at the Oil and Gas Sector. In: IIE Annual Conference. Proceedings. **Institute of Industrial and Systems Engineers (IISE)**, 2014. p. 2573.
- MARR, B. Artificial intelligence in practice: how 50 successful companies used AI and machine learning to solve problems. **John Wiley & Sons**, 2019.
- MARR, B. Big Data: Using SMART big data, analytics and metrics to make better decisions and improve performance. **John Wiley & Sons**, 2015a.
- MARR, B. **Key performance indicators for dummies**. Jonh Wiley & Sons, ltd, 2015b
- MAWED, M.; AL-HAJJ, A. Using big data to improve the performance management: a case study from the UAE FM industry. **Facilities**, 2017.

- MELNYK, S. A. et al. Is performance measurement and management fit for the future? **Management Accounting Research**, v. 25, n. 2, p. 173-186, 2014.
- MERGULHÃO, R. C.; MARTINS, R. A. Relação entre sistemas de medição de desempenho e projetos Seis Sigma: estudo de caso múltiplo. **Production**, v. 18, n. 2, p. 342-358, 2008.
- MISHRA, Deepa et al. Big Data and supply chain management: a review and bibliometric analysis. **Annals of Operations Research**, v. 270, n. 1, p. 313-336, 2018.
- CAUCHICK MIGUEL, P.A. et al. Metodologia de pesquisa em engenharia de produção e gestão de operações. Rio de Janeiro: **Elzevir**, 2010.
- MIKUŠOVÁ, M.; JANEČKOVÁ, V. Developing and implementing successful key performance indicators. **World Academy of Science, Engineering and Technology**, v. 42, p. 969-981, 2010.
- MOEUF, A. et al. The industrial management of SMEs in the era of Industry 4.0. **International Journal of Production Research**, v. 56, n. 3, p. 1118-1136, 2018.
- MOUSANNIF, H. et al. Big data projects: just jump right in!. **International Journal of Pervasive Computing and Communications**, 2016.
- MYERS, G.J.; SANDLER, C.; BADGETT, T. The art of software testing. **John Wiley & Sons**, 2011.
- NAJAFABADI, M. M., VILLANUSTRE, F., KHOSHGOFTAAR, T.M., SELIYA, N., WALD, R., e MUHAREMAGIC, E. Deep learning applications and challenges in big data analytics. **Journal of Big Data**, vol. 2, n. 1, p. 1, 2015.
- NEELY, A.; GREGORY, M.; PLATTS, K. Performance measurement system design: a literature review and research agenda. **International journal of operations & production management**, v. 15, n. 4, p. 80-116, 1995.
- NEELY, A. et al. Performance measurement system design: should process based approaches be adopted?. **International journal of production economics**, v. 46, p. 423-431, 1996.
- NEELY, A. **Measuring business performance**. Profile books, 1998.
- NEUPANE, D.; SEOK, J. Bearing fault detection and diagnosis using case western reserve university dataset with deep learning approaches: A review. **IEEE Access**, v. 8, p. 93155-93178, 2020.
- NIDHRA, S.; DONDETI, J. Black box and white box testing techniques-a literature review. **International Journal of Embedded Systems and Applications (IJESA)**, v. 2, n. 2, p. 29-50, 2012.
- NUDURUPATI, S. S.; BITITCI, U. S. Implementation and impact of IT-supported performance measurement systems. **Production Planning & Control**, v. 16, n. 2, p. 152-162, 2005.
- NUDURUPATI, S. S. et al. State of the art literature review on performance measurement. **Computers & Industrial Engineering**, v. 60, n. 2, p. 279-290, 2011.
- NUDURUPATI, S. S.; GARNAGO, P.; BITITCI, U.S. Impact of the changing business environment on performance measurement and management practices. **International Journal of Production Economics**, p. 107942, 2021.
- NUDURUPATI, S. S.; TEBBOUNE, S.; HARDMAN, J. Contemporary performance measurement and management (PMM) in digital economies. **Production Planning & Control**, v. 27, n. 3, p. 226-235, 2016.
- PAPULOVÁ, Z. et al. **Performance Measurement System: Implementation Process in SMEs**. Sustainability, v. 13, n. 9, p. 4794, 2021.
- PARIDA, A.; KUMAR, U. Maintenance performance measurement (MPM): issues and challenges. **Journal of Quality in Maintenance Engineering**, 2006.

- PARMENTER, D. Key performance indicators: developing, implementing, and using winning KPIs. **John Wiley & Sons**, 2015.
- PATEL, P.; THAKKAR, A. The upsurge of deep learning for computer vision applications. **International Journal of Electrical and Computer Engineering**, v. 10, n. 1, p. 538, 2020.
- PACKOVÁ, V.; KARÁCSÓNY, P. Designing and implementing performance management systems. In: **Business Performance Measurement and Management**. Springer, Berlin, Heidelberg, 2010. p. 241-249.
- PERKINS, C. et al. Practical implementation of machine tool metrology and maintenance management systems. In: **Journal of Physics: Conference Series**. IOP Publishing, 2012. p. 012105.
- POUYANFAR, S.; CHEN, S. Automatic video event detection for imbalance data using enhanced ensemble deep learning. **International Journal of Semantic Computing**, v. 11, n. 01, p. 85-109, 2017.
- PRANCIC, E. Modelo para concepção de sistema de medição de desempenho do processo de desenvolvimento do produto. 2008.
- PRESSMAN, R.S. **Software engineering: a practitioner's approach**. Palgrave macmillan, 2005.
- O'MAHONY, N. et al. Deep learning vs. traditional computer vision. In: **Science and Information Conference**. Springer, Cham, 2019. p. 128-144.
- OJIAKO, U. et al. Ambiguity in performance management systems of complex multi-stakeholder organisations. **Production Planning & Control**, p. 1-21, 2022.
- ORHEI, C. et al. End-To-End Computer Vision Framework: An Open-Source Platform for Research and Education. **Sensors**, v. 21, n. 11, p. 3691, 2021.
- RAMIS FERRER, B. et al. Implementing and visualizing ISO 22400 key performance indicators for monitoring discrete manufacturing systems. **Machines**, v. 6, n. 3, p. 39, 2018.
- RASCHKA, S.; MIRJALILI, V. **Python machine learning: Machine learning and deep learning with Python, scikit-learn, and TensorFlow 2**. Packt Publishing Ltd, 2019.
- RASMUSSEN, N. H.; BANSAL, M.; CHEN, C. Y. **Business dashboards: a visual catalog for design and deployment**. John Wiley & Sons, 2009.
- RAVELOMANANTSOA, M.S.; DUCQ, Y; VALLESPIR, B. A state of the art and comparison of approaches for performance measurement systems definition and design. **International Journal of Production Research**, v. 57, n. 15-16, p. 5026-5046, 2019.
- RENO, M.D. **Integrative executive leadership: Towards a general theory of positive business leadership**. University of Toronto (Canada), 2011.
- ROCKART, J.F. Chief executives define their own data needs. **Harvard business review**, v. 57, n. 2, p. 81-93, 1979.
- ROH, Y.; HEO, G.; WHANG, S.E. A survey on data collection for machine learning: a big data-ai integration perspective. **IEEE Transactions on Knowledge and Data Engineering**, v. 33, n. 4, p. 1328-1347, 2019.
- ROUSE, P.; PUTTERILL, M. An integral framework for performance measurement. **Management decision**, 2003.
- RUSSOM, P. et al. Big data analytics. **TDWI best practices report, fourth quarter**, v. 19, n. 4, p. 1-34, 2011.
- SAHLIN, J; ANGELIS, J. Performance management systems: reviewing the rise of dynamics and digitalization. **Cogent Business & Management**, v. 6, n. 1, p. 1642293, 2019.

SADASIVAM, L.; ARCHENTI, A.; SANDBERG, U.. Machine tool ability representation: A review. **Journal of Machine Engineering**, v. 18, 2018.

SARDI, A. et al. Big data and performance measurement research: trends, evolution and future opportunities. **Measuring Business Excellence**, 2020.

SARKAR, D. **Text analytics with Python: a practitioner's guide to natural language processing**. Apress, 2019.

SHANAHAN, J. G.; DAI, L. Introduction to Computer Vision and Real Time Deep Learning-based Object Detection. In: **Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining**. 2020. p. 3523-3524.

SILVA, E. L.; MENEZES, E. M. **Metodologia da pesquisa e elaboração de dissertação**. 4. ed. Florianópolis: UFSC, 2005.

SIMON, H. A. **The Sciences of the Artificial**. 3rd ed. Cambridge: MIT Press, 1996

SINGH, V.K. et al. The journal coverage of Web of Science, Scopus and Dimensions: A comparative analysis. **Scientometrics**, v. 126, n. 6, p. 5113-5142, 2021.

SIOW, E.; TIROPANIS, T.; HALL, W.. Analytics for the internet of things: A survey. **ACM computing surveys (CSUR)**, v. 51, n. 4, p. 1-36, 2018.

SIVARAJAH, U., KAMAL, M. M., IRANI, Z., E WEERAKKODY, V. Critical analysis of Big Data challenges and analytical methods. **Journal of Business Research**, v. 70, p. 263-286, 2017.

SKANSI, S. **Introduction to Deep Learning: from logical calculus to artificial intelligence**. Springer, 2018.

SOLTANPOOR, R.; SELLIS, T. Prescriptive analytics for big data. In: **Australasian database conference**. Springer, Cham, 2016. p. 245-256.

STAEGEMANN, D., VOLK, M.; NAHHAS, A. Exploring the specificities and challenges of testing big data systems. In: **2019 15th International Conference on Signal-Image Technology & Internet-Based Systems (SITIS)**. IEEE, 2019. p. 289-295.

STÖRRLE, H. How are conceptual models used in industrial software development? A descriptive survey. In: **Proceedings of the 21st International Conference on Evaluation and Assessment in Software Engineering**. 2017. p. 160-169.

SURAYA, S.; SHOLEH, M. Designing and Implementing a Database for Thesis Data Management by Using the Python Flask Framework. **International Journal of Engineering, Science and Information Technology**, v. 2, n. 1, p. 9-14, 2022.

TALWAR, S.; KAUR, P.; WAMBA, F.S. Big Data in operations and supply chain management: a systematic literature review and future research agenda. **International Journal of Production Research**, v. 59, n. 11, p. 3509-3534, 2021.

TAMBARE, P. et al. Performance Measurement System and Quality Management in Data-Driven Industry 4.0: A Review. **Sensors**, v. 22, n. 1, p. 224, 2022.

TANWAR, S.; TYAGI, S.; KUMAR, N. (Ed.). **Multimedia big data computing for IoT applications: concepts, paradigms and solutions**. Springer, 2019.

TATICCHI, P.; TONELLI, F. CAGNAZZO, Luca. Performance measurement and management: a literature review and a research agenda. **Measuring business excellence**, 2010.

TUNG, A.; BAIRD, K.; SCHOCH, H.P. Factors influencing the effectiveness of performance measurement systems. *International Journal of Operations & Production Management*, 2011.



- U.S. General Accounting Office. (2012). Performance measurement and evaluation: Definitions and relationships (revised). Retrieved September 2018, from [http://www.gao.gov/special\\_pubs/gg98026.pdf](http://www.gao.gov/special_pubs/gg98026.pdf).
- VAN AKEN, J.E. Management research as a design science: Articulating the research products of mode 2 knowledge production in management. **British journal of management**, v. 16, n. 1, p. 19-36, 2005.
- VAN AKEN, J. E.; BERENDS, H. Problem solving in organizations. Cambridge university press, 2018.
- VAN FENEMA, P.C.; KEERS, B.M. Interorganizational Performance Management: A Co-evolutionary Model. **International Journal of Management Reviews**, v. 20, n. 3, p. 772-799, 2018.
- VENABLE, J. The role of theory and theorising in design science research. In: **Proceedings of the 1st International Conference on Design Science in Information Systems and Technology (DESRIST 2006)**. 2006. p. 1-18.
- VOULODIMOS, A. et al. A threefold dataset for activity and workflow recognition in complex industrial environments. **IEEE MultiMedia**, n. 3, p. 42-52, 2012.
- VOULODIMOS, A. et al. Deep learning for computer vision: A brief review. **Computational intelligence and neuroscience**, v. 2018, 2018.
- WAMBA, S. F. et al. How 'big data' can make big impact: Findings from a systematic review and a longitudinal case study. **International Journal of Production Economics**, v. 165, p. 234-246, 2015.
- WANG, L.; SNG, D. Deep learning algorithms with applications to video analytics for a smart city: A survey. **arXiv preprint arXiv:1512.03131**, 2015.
- WANG, G., et al., T. Big data analytics in logistics and supply chain management: Certain investigations for research and applications. **International Journal of Production Economics**, 176, 98- 110, 2016.
- WANG, Y; LUO, Z.; JODOIN, P. Interactive deep learning method for segmenting moving objects. **Pattern Recognition Letters**, v. 96, p. 66-75, 2017.
- WIECH, Michael et al. Implementation of big data analytics and Manufacturing Execution Systems: an empirical analysis in German-speaking countries. **Production Planning & Control**, v. 33, n. 2-3, p. 261-276, 2022.
- WILLOUGHBY, P. et al. A Holistic Approach to Quantifying and Controlling the Accuracy, Performance and Availability of Machine Tools. In: **Proceedings of the 36th International Conference**. Springer, London, 2010. p. 313-316.
- WU, X. et al. Data mining with big data. **IEEE transactions on knowledge and data engineering**, v. 26, n. 1, p. 97-107, 2013.
- WÜRSCHINGER, H. et al. Implementation and potentials of a machine vision system in a series production using deep learning and low-cost hardware. **Procedia CIRP**, v. 90, p. 611-616, 2020.
- XU, L. D.; DUAN, L. Big data for cyber physical systems in industry 4.0: a survey. **Enterprise Information Systems**, v. 13, n. 2, p. 148-169, 2019.
- YADAV, N.; SAGAR, M. Performance measurement and management frameworks. **Business Process Management Journal**, 2013.
- YOUSEFI-AZAR, M.; HAMEY, L. Text summarization using unsupervised deep learning. **Expert Systems with Applications**, v. 68, p. 93-105, 2017.
- YUAN, H. et al. Exploring the influence of multimodal social media data on stock performance: an empirical perspective and analysis. **Internet Research**, 2021.

ZHANG, J.Z. et al. Big Data Analytics and Machine Learning: A Retrospective Overview and Bibliometric Analysis. **Expert Systems with Applications**, p. 115561, 2021.

ZHANG, A. et al. Dive into deep learning. **arXiv preprint arXiv:2106.11342**, 2021..

ZHAO, Z. et al. Object detection with deep learning: A review. **IEEE transactions on neural networks and learning systems**, v. 30, n. 11, p. 3212-3232, 2019.

ZHU, L. et al. Key performance indicators for manufacturing operations management–gap analysis between process industrial needs and ISO 22400 standard. **Procedia Manufacturing**, v. 25, p. 82-88, 2018.

ZIKOPOULOS, P.; EATON, C. **Understanding big data: Analytics for enterprise class hadoop and streaming data**. McGraw-Hill Osborne Media, 2011.

ZUPIC, I.; ČATER, T. Bibliometric methods in management and organization. **Organizational Research Methods**, v. 18, n. 3, p. 429-472, 2015.