

**ASSOCIAÇÃO EDUCACIONAL DOM BOSCO
FACULDADE DE ENGENHARIA DE RESENDE
CURSO DE ENGENHARIA DE PRODUÇÃO**

MATHEUS GONÇALVES DA SILVA

**ANÁLISE DOS DESAFIOS E LIMITAÇÕES DO GERENCIAMENTO DO *BIG*
DATA: um recorte das indústrias automotivas situadas no Sul Fluminense**

RESENDE
2025

**ASSOCIAÇÃO EDUCACIONAL DOM BOSCO
FACULDADE DE ENGENHARIA DE RESENDE
CURSO DE ENGENHARIA DE PRODUÇÃO**

MATHEUS GONÇALVES DA SILVA

ANÁLISE DOS DESAFIOS E LIMITAÇÕES DO GERENCIAMENTO DO *BIG*

DATA: um recorte das indústrias automotivas situadas no Sul Fluminense

Trabalho de conclusão de curso apresentado à Faculdade de Engenharia de Resende, Curso de Engenharia de Produção, como requisito parcial para obtenção do diploma de Bacharel em Engenharia de Produção.

Orientador: Prof. Me. Cássio Castilho Oliveira de Faria

RESENDE
2025

Catálogo na fonte
Biblioteca Central da Associação Educacional Dom Bosco – Resende-RJ

S586	<p>Silva, Matheus Gonçalves da Análise dos desafios e limitações do gerenciamento do <i>Big Data</i>: um recorte das indústrias automotivas situadas no Sul Fluminense / Matheus Gonçalves da Silva - 2025. 47f.</p> <p>Orientador: Cassio Castilho Oliveira de Faria Trabalho de conclusão de curso apresentado como requisito parcial à finalização do curso de Engenharia de Produção da Faculdade de Engenharia de Resende da Associação Educacional Dom Bosco.</p> <p>1. Engenharia de produção. 2. Indústria 4.0. 3. Tecnologia da informação. 4. Gerenciamento de dados. 5. Indústria automotiva. I. Faria, Cássio Castilho Oliveira de. II. Faculdade de Engenharia de Resende. III. Associação Educacional Dom Bosco. IV. Título.</p> <p>CDU 629.33:004.6(043)</p>
------	---

MATHEUS GONÇALVES DA SILVA

ANÁLISE DOS DESAFIOS E LIMITAÇÕES DO GERENCIAMENTO DO *BIG*

DATA: um recorte das indústrias automotivas situadas no Sul Fluminense

Trabalho de Graduação apresentado à Faculdade de Engenharia de Resende, Curso de Engenharia de Produção, como requisito parcial para obtenção do diploma de Bacharel em Engenharia de Produção.

BANCA EXAMINADORA:

Prof. Me. Cássio Castilho Oliveira de Faria
Orientador

Prof. Me. Douglas Rosa Grillo
Faculdade de Engenharia de Resende

Prof.^a Me. Ana Paula Pereira Maiato Nascimento
Membro Externo

Resende, 28 de outubro de 2025

dedico este trabalho de modo especial, à minha
família.

AGRADECIMENTOS

Em primeiro lugar agradeço a Deus, fonte da vida e da graça. Agradeço pela minha vida, minha inteligência, minha família e meus amigos; ao meu orientador, Prof. Me. Cássio Castilho Oliveira de Faria que jamais deixou de me incentivar. Sem as suas orientações, dedicação e auxílio, o estudo aqui apresentado seria praticamente impossível; aos meus pais *Marcelo e Marilucia*, que apesar das dificuldades enfrentadas, sempre incentivaram meus estudos; e aos funcionários das Faculdades Dom Bosco pela dedicação e alegria no atendimento.

“Sem educação não há esperança para um mundo mais justo e fraterno. Educar é apostar no futuro”

Papa Francisco.

RESUMO

Em um contexto de transformação digital impulsionado pela Indústria 4.0, o *Big Data* surge como um recurso estratégico para a competitividade do setor automotivo. No entanto, sua implementação efetiva enfrenta obstáculos significativos, especialmente em polos industriais específicos. Este estudo tem como objetivo geral identificar e analisar as barreiras e limitações para o progresso no gerenciamento do *Big Data* nas indústrias automotivas do Sul Fluminense, visando mapear os desafios tecnológicos, humanos e organizacionais envolvidos. A pesquisa, de natureza aplicada e abordagem mista, adotou a metodologia *Design Science Research*, que orientou a criação e avaliação de um artefato, um Diagrama de Afinidades, para sintetizar e estruturar os problemas identificados. O percurso metodológico incluiu uma revisão bibliográfica sistemática e a aplicação de uma *survey* com 62 profissionais da região. Os resultados principais revelam que, embora a totalidade das empresas utilize *Big Data* de forma estruturada ou limitada, persistem entraves. O mais significativo é a resistência cultural à mudança (61,7%), seguido por limitações de infraestrutura, como falta de *hardware* (48,3%), preocupações com segurança e privacidade dos dados (46,7%) e escassez de profissionais qualificados (43,3%). Apesar dessas barreiras, há uma percepção positiva do valor do *Big Data*, com 96,7% dos respondentes avaliando seu impacto como alto ou muito alto, principalmente para a melhoria na tomada de decisão estratégica (93,3%) e a redução de custos operacionais (78,3%). Nesse contexto, conclui-se que a adoção efetiva do *Big Data* é considerada essencial para a competitividade futura do setor no Sul Fluminense, porém, depende da superação coordenada dos desafios identificados por meio de investimentos em tecnologia, capacitação profissional e uma transformação cultural orientada por dados. Assim, a pesquisa contribui para os meios profissional e acadêmico ao mapear e sistematizar os principais desafios do gerenciamento de *Big Data* no polo automotivo do Sul Fluminense, oferecendo um diagnóstico regionalizado para gestores e validando os desafios teóricos em um contexto industrial específico.

Palavras-chaves: *Big Data*; Indústria 4.0; Indústria Automotiva; Tecnologia da Informação; Gerenciamento de Dados

ABSTRACT

In a context of digital transformation driven by Industry 4.0, Big Data has emerged as a strategic resource for the competitiveness of the automotive sector. However, its effective implementation faces significant obstacles, especially in specific industrial hubs. This study aims to identify and analyze the barriers and limitations to the progress of Big Data management in the automotive industries of South Fluminense, seeking to map the technological, human, and organizational challenges involved. The research, of an applied nature and using a mixed-methods approach, adopted the Design Science Research (DSR) methodology, which guided the creation and evaluation of an artifact, an Affinity Diagram, to synthesize and structure the identified problems. The methodological path included a systematic literature review and a survey with 62 professionals from the region. The main results reveal that although all companies use Big Data in a structured or limited way, obstacles persist. The most significant is cultural resistance to change (61.7%), followed by infrastructure limitations, such as a lack of hardware (48.3%), concerns about data security and privacy (46.7%), and a shortage of qualified professionals (43.3%). Despite these barriers, there is a positive perception of the value of Big Data, with 96.7% of respondents rating its impact as high or very high, primarily for improving strategic decision-making (93.3%) and reducing operational costs (78.3%). In this context, it is concluded that the effective adoption of Big Data is considered essential for the future competitiveness of the sector in South Fluminense; however, it depends on the coordinated overcoming of the identified challenges through investments in technology, professional training, and a data-driven cultural transformation. Thus, the research contributes to professional and academic circles by mapping and systematizing the main challenges of Big Data management in the automotive hub of Southern Fluminense, offering a regionalized diagnosis for managers and validating the theoretical challenges in a specific industrial context.

Keywords: Big Data; Industry 4.0; Automotive Industry; Information Technology; Data Management

LISTA DE ILUSTRAÇÕES

Figura 1 - Percurso metodológico.....	22
Figura 2 – Como é utilizado o <i>Big Data</i> pelas empresas, de acordo com os participantes da <i>survey</i>	28
Figura 3 - Aplicações mais empregadas pelas empresas que utilizam <i>Big Data</i> , segundo os participantes da <i>survey</i>	28
Figura 4 - Software mais utilizado pelas empresas para gerenciamento de <i>Big Data</i> , segundo os participantes da <i>survey</i>	28
Figura 5 - Principais desafios no gerenciamento do <i>Big Data</i> , de acordo com os participantes da <i>survey</i>	30
Figura 6 – Equipe de especialistas no gerenciamento do <i>Big Data</i> , de acordo com os participantes da <i>survey</i>	30
Figura 7 - Resultado referente a pergunta: Em uma escala de 1 a 5, como você avaliaria o impacto do gerenciamento do <i>Big Data</i> nos resultados de sua empresa?.....	31
Figura 8 - As principais vantagens que as empresa tem e/ou espera ter ao implementar <i>Big Data</i> , de acordo com os participantes da <i>survey</i>	31
Figura 9 - <i>Big Data</i> como um fator para a competitividade no setor automotivo nos próximos 5 anos, de acordo com os participantes da <i>survey</i>	32
Figura 10 - <i>Insights</i> mapeados	33
Figura 11 - Diagrama de Afinidades	34

LISTA DE QUADROS

Quadro 1 - Classificação da Pesquisa	20
--	----

SUMÁRIO

1. INTRODUÇÃO	12
1.1 SITUAÇÃO PROBLEMA.....	12
1.2 JUSTIFICATIVA E RELEVÂNCIA DO TEMA.....	13
1.3 OBJETIVOS	13
1.3.1 Objetivo geral	13
1.3.2 Objetivos específicos	14
1.4 DELIMITAÇÃO DO TRABALHO.....	14
1.5 ORGANIZAÇÃO DO TRABALHO.....	14
2. REVISÃO DA LITERATURA	15
2.1 HISTÓRIA DAS REVOLUÇÕES INDUSTRIAIS.....	15
2.2 CONCEITOS E DESAFIOS PARA O GERENCIAMENTO DO <i>BIG DATA</i>	16
2.3 PANORAMA DE OUTRAS FERRAMENTAS NO CONTEXTO DE ANÁLISE DE DADOS	17
2.4 USO DE FERRAMENTA PARA DESENVOLVIMENTO DE INDICADORES E OS PRINCIPAIS DESAFIOS DESSE USO.....	18
3. METODOLOGIA	19
3.1 METODOLOGIA CIENTÍFICA	20
3.2 METODOLOGIA DO DESENVOLVIMENTO DO ARTEFATO	21
3.2.1 Identificação do problema e motivação	22
3.2.2 Definição dos objetivos	23
3.2.3 Desenvolvimento do artefato	25
3.2.4 Demonstração, avaliação e comunicação	26
4. RESULTADOS E DISCUSSÕES	26
4.1 IDENTIFICAÇÃO DO PROBLEMA E MOTIVAÇÃO.....	26
4.2 DEFINIÇÃO DOS OBJETIVOS DA SOLUÇÃO	27
4.3 <i>DESIGN</i> E DESENVOLVIMENTO	32
4.3.1 Mapeamento dos <i>insights</i>	32
4.3.2 Sistematização: por meio do diagrama de afinidades	33
4.4 DEMONSTRAÇÃO, AVALIAÇÃO E COMUNICAÇÃO	35
4.5 DISCUSSÕES: COMPARAÇÃO ENTRE <i>SURVEY</i> E LITERATURA	36
5. CONCLUSÃO	38
REFERÊNCIAS	40
APÊNDICE A – RESULTADO DA PESQUISA BIBLIOGRÁFICA	44
APÊNDICE B – QUESTIONÁRIO	47

1. INTRODUÇÃO

As indústrias automotivas no Brasil empregam aproximadamente 1,3 milhão de pessoas e representam cerca de 20% de todo o Produto Interno Bruto (PIB) do país (ANFAVEA, 2025). Adicionalmente, o mercado de especialistas em análises de *Big Data* tem projeção de movimentação de USD 54.75 bilhões de dólares, anualmente, até 2033 (*Business Research Insights*, 2025).

Nesse sentido, considerando as transformações industriais advindas da Quarta Revolução Industrial (Indústria 4.0), com integração de tecnologias como *Internet of Things* (IoT), *Artificial Intelligence* (AI), *Big Data* e *Cyber-Physical System* (CPS) para criar fábricas inteligentes e autônoma, observa-se que no setor automotivo essas tecnologias proporcionam ganhos de eficiência, personalização em massa e otimização em toda a cadeia produtiva. Contudo, sua implementação enfrenta desafios significativos, como a complexidade de integração tecnológica, resistência cultural à mudança, custos elevados de investimento e lacunas na qualificação da mão de obra, conforme destacam (Hermann; Pentek; Otto, 2015; Kagermann; Wahlster; Helbig, 2013).

Nesse contexto, destaca-se estudos de outros autores como Francisco e Costa (2024) que apontam para o fenômeno de aumento de massa de dados a serem analisados diante o avanço da Indústria 4.0. Assim sendo, é importante que se tenha estudos que tragam *softwares* que consigam tratar de toda essa massa de dados e mostrá-los de maneira clara e objetiva.

1.1 SITUAÇÃO PROBLEMA

Considerando a transformação das empresas manufatureiras com a chegada da Indústria 4.0 e o incremento do *Big Data* no cotidiano dessas indústrias torna-se necessário analisar as atuais ferramentas disponíveis para gerenciamento dessa massa de dados e escolher as mais adequadas para cada empresa. Com isso, pode-se realizar o tratamento de dados, utilizando essas ferramentas como suporte à tomada de decisão.

Esse cenário de transformação revela desafios que ainda não são devidamente esclarecidos, tais como: as dificuldades e limitações que os *softwares* apresentam, a necessidade de mais cursos de graduação voltados para área ou se há resistência cultural à mudança, por exemplo. Nesse contexto, surge a seguinte questão norteadora: quais são as principais dificuldades encontradas no gerenciamento do *Big Data* em empresas automotivas?

1.2 JUSTIFICATIVA E RELEVÂNCIA DO TEMA

A gestão eficiente de *Big Data* vem tornando-se estratégica para as organizações. A capacidade de coletar, armazenar, processar e analisar volumes massivos de dados em tempo real é crucial para extrair *insights*, otimizar operações e antecipar tendências. Nesse sentido, esse estudo se justifica ao identificar os desafios no gerenciamento dessa massa de dados, permitindo as organizações análises estratégicas visando a competitividade diante à Indústria 4.0, a partir da gestão eficiente de *Big Data*.

Além disso, este estudo encontra amparo e motivação na experiência do autor na indústria automotiva, dado sua observação quanto ao crescimento das discussões sobre a gestão de *Big Data*. Assim sendo, a partir da observação do autor é percebido uma carência de especialistas capazes de lidar com o gerenciamento da massa de dados.

Ressalta-se que a relevância do tema deste estudo pode ser destacada na vertente acadêmica e profissional. Academicamente por evidenciar a necessidade de adaptar currículos acadêmicos e programas de formação profissional, tanto técnicos quanto de nível superior, para desenvolver essas habilidades multidisciplinares e profissionalmente desse estudo, visto que a competitividade industrial depende cada vez mais da adoção estratégica de tecnologias digitais, com o *Big Data* ocupando papel importante. Nesse sentido, a nível nacional, dominar seu gerenciamento é vital para que a indústria brasileira aumente sua produtividade, personalize a produção, otimize cadeias de suprimentos complexas e desenvolva novos modelos de negócio, reduzindo o *gap* tecnológico frente as nações mais avançadas.

Ademais, regionalmente, este tema adquire contornos ainda mais urgentes no polo automotivo do Sul Fluminense na aplicação do *Big Data* na previsão de demanda, manutenção preditiva de máquinas, controle de qualidade em tempo real, logística integrada e desenvolvimento de indicadores *KPIs* para tomada de decisão.

1.3 OBJETIVOS

1.3.1 Objetivo geral

Este estudo tem como objetivo geral identificar e analisar as barreiras e limitações para o progresso no gerenciamento de *Big Data* no polo automotivo do Sul Fluminense.

1.3.2 Objetivos específicos

Além do objetivo geral, os objetivos específicos desse estudo são:

- a) Analisar estudos sobre gerenciamento e análise de dados na indústria;
- b) Identificar os riscos e oportunidades sobre o gerenciamento de *Big Data* na indústria automotiva;
- c) Mapear os desafios para a gestão de *Big Data* nas indústrias automotivas do Sul Fluminense;
- d) Sistematizar a representação das dificuldades para o avanço no gerenciamento de *Big Data* pela indústria automotiva do Sul Fluminense.

1.4 DELIMITAÇÃO DO TRABALHO

Essa pesquisa delimita-se ao estudo do gerenciamento do *Big Data* na indústria automotiva, com recorte geográfico exclusivo para empresas situadas no Sul Fluminense. A abordagem metodológica integra uma análise bibliográfica de publicações científicas e uma *survey* com funcionários da área de empresas locais. O escopo restringe-se aos processos de captura, armazenamento e análise de volumes de dados sobre a dificuldade do gerenciamento do *Big Data*.

1.5 ORGANIZAÇÃO DO TRABALHO

No Capítulo 1, são apresentadas as considerações iniciais sobre o tema do estudo a ser descrito pelo trabalho. No Capítulo 2, expõe-se a Revisão de Literatura, onde são abordados tópicos como o conceito da Indústria 4.0, o conceito do *Big Data* e o uso de *softwares* para gerenciamento da massa de dados. Já no Capítulo 3, são descritos os materiais e métodos utilizados para a realização da pesquisa, detalhando a abordagem metodológica adotada. O Capítulo 4 é dedicado à apresentação e discussão dos resultados, onde se analisam os resultados da pesquisa das dificuldades encontradas no gerenciamento do *Big Data*, nas empresas automotivas do Sul Fluminense e comparativos sob a ótica de estudo dos artigos selecionados. O Capítulo 5 reúne as conclusões do estudo, sintetizando os principais achados e apresentando sugestões para trabalhos futuros. Por fim, lista-se as referências bibliográficas ao final do trabalho.

2. REVISÃO DA LITERATURA

2.1 HISTÓRIA DAS REVOLUÇÕES INDUSTRIAIS

A trajetória das revoluções industriais reflete a evolução tecnológica e organizacional que transformou a sociedade e os sistemas produtivos. A Primeira Revolução Industrial (século XVIII ao século XIX) marcou a transição da produção artesanal para a mecanização, impulsionada pela invenção da máquina a vapor por James Watt e pela expansão das fábricas têxteis. Além disso, essa fase consolidou o capitalismo industrial, alterando relações de trabalho e urbanização (Hobsbawm, 2012; Landes, 2010).

A Segunda Revolução Industrial (final do século XIX ao início do século XX) trouxe avanços como a eletricidade, a linha de montagem de Henry Ford e a produção em massa, essa padronização e a energia elétrica, associadas ao desenvolvimento de ferrovias e telecomunicações, permitiram escalabilidade global; foi nesse período, também, que foi introduzido os princípios de gestão científica, otimizando processos produtivos (Rifkin, 2000; Taylor, 1997).

A Terceira Revolução Industrial, ou Revolução Digital (1970 até 2000), emergiu com a ascensão da eletrônica, da computação e da automação, essa fase pode ser descrita como descreve essa fase como a integração de tecnologias de informação (TI) e robótica, possibilitando a flexibilização da produção (Schwab, 2018). Existem, também, autores que discutem o impacto da internet e da digitalização na reconfiguração de cadeias de valor (Brynjolfsson e McAfee, 2016).

Atualmente, a Quarta Revolução Industrial, ou Indústria 4.0, surge da convergência de tecnologias digitais, físicas e biológicas. Concebida na Alemanha em 2011, baseia-se em CPS, IoT, AI e *Big Data* (Hermann, Pentek e Otto, 2015). A Indústria 4.0 transcende a automatização, promovendo fábricas inteligentes e personalização em massa, destacando a importância da manufatura aditiva e da integração em tempo real entre máquinas e humanos (Lee, Bagheri e Kao, 2015; Schwab, 2018).

Essa evolução, contudo, não é isenta de desafios que alertam para a necessidade de adaptação da força de trabalho e políticas de segurança digital. A Indústria 4.0 redefine não apenas processos produtivos, mas também modelos de negócios e interações sociais, consolidando-se como um marco na era da hiperconectividade (Kangermann, Helbing e Wahlster, 2013).

2.2 CONCEITOS E DESAFIOS PARA O GERENCIAMENTO DO *BIG DATA*

O termo *Big Data* refere-se a um conjunto massivo de dados que cresce em volume, variedade e velocidade, ultrapassando a capacidade de processamento das ferramentas tradicionais de gerenciamento de dados (Rossi e Hirama, 2022). A origem da expressão está associada ao crescimento exponencial na geração de dados digitais provenientes de dispositivos móveis, redes sociais, sensores IoT, sistemas corporativos e plataformas digitais em geral; o *Big Data* é caracterizado pelos "3Vs": Volume da quantidade de dados, Velocidade com que os dados são gerados e processados e Variedade, ou seja, a diversidade de formatos e fontes de dados, aos quais posteriormente foram acrescentados outros atributos, como Veracidade e Valor (Sha e Carotti-Sha, 2023).

O *Big Data* não se restringe apenas à quantidade de dados armazenados, mas também à sua complexidade e ao potencial de extração de informações relevantes. Por isso, seu valor estratégico reside na capacidade de transformar grandes volumes de dados brutos em *insights* úteis para a tomada de decisões. Segundo Rossi e Hirama (2022), as empresas que utilizam adequadamente soluções de *Big Data* conseguem obter vantagens competitivas ao identificar padrões de comportamento, prever demandas de mercado, otimizar processos internos e oferecer produtos e serviços personalizados, contudo essa transformação exige ferramentas adequadas de processamento, análise e visualização, bem como profissionais qualificados para interpretar os resultados.

No entanto, gerenciar dados apresenta desafios significativos, sendo a primeira dificuldade relacionada ao armazenamento, visto que nem todos os dados gerados podem ou devem ser armazenados de forma integral. É necessário estabelecer critérios para filtragem e organização, além de adotar sistemas escaláveis, como bancos de dados e plataformas distribuídas em nuvem. Além disso, a governança dos dados, incluindo políticas de segurança, privacidade e conformidade com legislações como a Lei Geral de Proteção de Dados (LGPD), torna-se um fator crítico no ambiente corporativo (Ekbia *et al.*, 2015; Scaglione *et al.*, 2021).

Nesse sentido, outro desafio é o processamento eficiente de informações, visto que dados em tempo real exigem sistemas capazes de executar análises instantâneas, como ocorre com o uso de ferramentas como Apache Kafka e Apache Spark. Ademais, observa-se a dificuldade crescente na integração de diferentes fontes de dados em um único ambiente de análise. De acordo com Ekbia *et al.* (2015) e Wu, Buyya e Ramamohanarao (2016), a falta de padronização e a necessidade de limpar e preparar os dados antes do uso representam etapas críticas que demandam tempo e recursos especializados.

Por fim, destaca-se o desafio da interpretação dos dados. Mesmo com o suporte de softwares avançados, é necessário que os profissionais tenham competência técnica e visão estratégica para identificar os dados relevantes, interpretar os resultados das análises e transformá-los em ações práticas. A escassez de talentos especializados em ciência de dados, análise estatística e BI ainda é uma limitação real em muitas organizações. Assim, a gestão eficaz do *Big Data* não depende apenas da tecnologia disponível, mas também da capacidade humana de transformar dados em conhecimento aplicável (Scaglione *et al.*, 2021; Wu, Buyya e Ramamohanarao, 2016).

2.3 PANORAMA DE OUTRAS FERRAMENTAS NO CONTEXTO DE ANÁLISE DE DADOS

O avanço da era digital e a crescente disponibilidade de dados em larga escala exigiram o surgimento de ferramentas mais sofisticadas para coleta, análise e visualização de informações, sobretudo no contexto do *Big Data*. Nesse cenário, as ferramentas de *Business Intelligence* (BI) destacam-se por permitir que grandes volumes de dados sejam transformados em *insights* estratégicos por meio de *dashboards*, relatórios interativos e análises em tempo real. Diferentemente das planilhas tradicionais, essas ferramentas são projetadas para lidar com múltiplas fontes de dados e apresentar informações de forma dinâmica e escalável (Chen e Chiang, 2014).

A integração entre *Big Data* e BI representa um dos pilares da transformação digital nas organizações contemporâneas. Enquanto o *Big Data* refere-se à gestão de grandes volumes de dados estruturados e não estruturados, caracterizados pelos "3Vs" (Volume, Velocidade e Variedade), o BI foca na análise desses dados para subsidiar decisões estratégicas (Gartner, 2021; Machado, 2018).

A convergência entre essas duas áreas amplia a capacidade das empresas de transformar dados brutos em *insights* acionáveis, otimizando processos e antecipando tendências de mercado (Mcafee e Brynjolfsson, 2012).

Os aplicativos de BI tradicionais, inicialmente limitados a análises descritivas de dados históricos, foram revolucionados pela ascensão do *Big Data*. A complexidade dos dados gerados em tempo real exigiu a adaptação das ferramentas de BI para incorporar técnicas de processamento distribuído e *machine learning* (Mahmoud Elhoushy, Mahmoud Elhennawy e Khamis Zaytoun, 2023).

Apesar de seu uso difundido em ambientes corporativos, o Microsoft Excel, especialmente por meio do *Visual Basic for Applications* (VBA), apresenta sérias limitações quando se trata de lidar com dados em grande volume, variedade e velocidade, ou seja, os chamados “3Vs” do *Big Data*. Setiyanto e Setiawan (2022) destacam que o Excel está limitado em sua capacidade de armazenamento, com máximo de 1 048 576 linhas e 16 384 colunas, o que reduz drasticamente sua aplicabilidade em contextos de *Big Data*, onde os volumes de dados frequentemente excedem tais limites .

Segundo Setiyanto e Setiawan (2022), o desempenho do Excel pode degradar-se significativamente, com risco de travamentos e lentidão, mesmo em cenários com até um milhão de linhas, o uso de funções como detecção de erro, remoção de duplicatas, detecção de outliers e validação de dados exige elevada carga operacional. Embora o *Excel* ofereça algumas possibilidades para limpeza e preparação de dados, tais como: detecção de erros, remoção de valores duplicados e tratamento de dados ausentes; esses processos requerem múltiplas etapas manuais e são relativamente rudimentares frente às funcionalidades automáticas e robustas encontradas em linguagens como Python, assim sendo o Excel pode ser usado em etapas iniciais de preparação de dados, desde que contidos dentro de seu limite nativo, mas sua utilização para o *Big Data* é inviável (Setiyanto e Setiawan, 2022).

2.4 USO DE FERRAMENTA PARA DESENVOLVIMENTO DE INDICADORES E OS PRINCIPAIS DESAFIOS DESSE USO

O uso de aplicativos de BI para a automação da sistemática de geração de indicadores-chave de desempenho (*KPIs*) tem se tornado uma prática essencial nas organizações que buscam eficiência na gestão de dados e na tomada de decisão. O BI compreende um conjunto de ferramentas, metodologias e processos que permitem a coleta, integração, análise e visualização de dados organizacionais para subsidiar decisões estratégicas (Chen e Chiang, 2014).

Segundo Wood *et al.* (2018), a automação da análise de *KPIs* através de sistemas de BI permite que gestores tenham acesso a informações relevantes em tempo real, possibilitando a identificação rápida de padrões e tendências. Dessa forma, os tomadores de decisão podem agir com maior assertividade, minimizando riscos e otimizando recursos.

A integração de tecnologias emergentes, como a Inteligência Artificial (IA) e a Aprendizagem de Máquina, aos sistemas de BI tem ampliado significativamente a capacidade de automação na geração de *KPIs*. A incorporação de *IA* nos sistemas de BI não apenas

automatiza a coleta e análise de dados, mas também melhora a previsibilidade dos indicadores, permitindo simulações baseadas em cenários reais e projetados (Davenport e Harris, 2017).

Outro aspecto relevante é a visualização de dados. Conforme argumentam Few (2012) e McKinney (2012), a eficácia dos sistemas de BI está diretamente relacionada à capacidade de apresentar informações complexas de maneira clara e intuitiva. Ferramentas como *Power BI*®, *Tableau*® e *QlikView*® são amplamente utilizadas para esse fim, permitindo a criação de dashboards dinâmicos que facilitam a interpretação dos *KPIs* por diferentes níveis hierárquicos dentro das organizações (Kimball e Ross, 2013)

A automação da sistemática de *KPIs* por meio de aplicativos de BI também contribui para a redução de erros humanos na coleta e processamento dos dados. Segundo Eckerson (2010), a implementação de soluções automatizadas minimiza inconsistências, melhora a confiabilidade das informações e proporciona maior agilidade na distribuição de relatórios gerenciais.

Dessa forma, os aplicativos de BI representam uma solução estratégica para organizações que buscam aprimorar seus processos de tomada de decisão baseados em *KPIs*. A evolução dessas ferramentas continuará a desempenhar um papel fundamental na gestão empresarial, impulsionada por inovações tecnológicas e pela crescente demanda por análises de dados mais precisas e ágeis.

Apesar dos avanços, a interface entre *Big Data* e BI enfrenta obstáculos, autores como Chen e Chiang (2014) alertam para a necessidade de governança de dados, garantindo qualidade e segurança. Além disso, a carência de profissionais qualificados limita o potencial dessa integração

Assim sendo, observa-se que a relação entre *Big Data* e BI redefine a gestão empresarial, tornando-a mais ágil e baseada em evidências. No entanto, seu êxito depende da superação de desafios técnicos e organizacionais, além do fato de que segundo Sharda, Delen e Turban (2017), o futuro dessa interface está na democratização do acesso a dados, combinando ferramentas intuitivas de BI com infraestruturas robustas de *Big Data*.

3. METODOLOGIA

A presente pesquisa foi estruturada de acordo com as práticas metodológicas definidas pela literatura acadêmica, sendo essas informações apresentadas no subcapítulo 3.1. Além disso, os desdobramentos do desenvolvimento do artefato serão descritos no subcapítulo 3.2, seguindo a metodologia do *Design Science Research* (DSR).

3.1 METODOLOGIA CIENTÍFICA

A metodologia científica desempenha um papel central na condução de pesquisas rigorosas, conferindo credibilidade, transparência e possibilidade de replicação aos estudos. Conforme Bloise (2020, p.1), “a metodologia é o instrumento de que a pesquisa se utiliza para construir o conhecimento”. Esse caráter é reforçado por Prodanov e Freitas (2013), ao mencionarem que toda pesquisa deve ser baseada em uma teoria que serve como ponto de partida para a investigação. Além disso, a adoção de uma metodologia clara e bem definida permite que outros pesquisadores entendam, avaliem e reproduzam seu estudo, fortalecendo a confiabilidade científica do trabalho. Assim, nesse trabalho os métodos utilizados foram classificados quanto à natureza, objetivo, abordagem e procedimento de pesquisa, conforme o Quadro 1.

Quadro 1 - Classificação da Pesquisa

Natureza	Objetivo	Abordagem	Procedimento de Pesquisa
Básica Aplicada	Exploratório Descritivo Explicativo Normativo	Quantitativa Qualitativa Mista	Experimento Prisma Pesquisa bibliográfica Modelagem matriz Pesquisa de campo <i>Design Science Research (DSR)</i>

Fonte: Adaptado de (Kothari e Garg, 2019; Lakatos e Marconi, 2017; Peffers *et al.*, 2007; Prodanov e Freitas, 2013)

A pesquisa conduzida é caracterizada como aplicada em sua natureza. Conforme destacam Prodanov e Freitas (2013), diferentemente da pesquisa básica, que visa ao avanço do conhecimento científico sem uma aplicação imediata, a pesquisa aplicada tem como finalidade gerar conhecimentos para aplicação prática, dirigidos à solução de problemas específicos, tais como o objetivo dessa pesquisa em analisar as barreiras e limitações para o progresso no gerenciamento de *Big Data* no polo automotivo do Sul Fluminense.

No que diz respeito aos objetivos, a pesquisa é definida como exploratória, pois busca proporcionar uma maior familiarização com o problema, visando torná-lo mais claro. De acordo com Kothari e Garg (2019), a pesquisa exploratória é empregada em temas que ainda não foram amplamente investigados ou que requerem uma análise mais detalhada. Este trabalho explora dificuldades do gerenciamento do *Big Data* no setor automotivo, baseando-se em uma revisão bibliográfica.

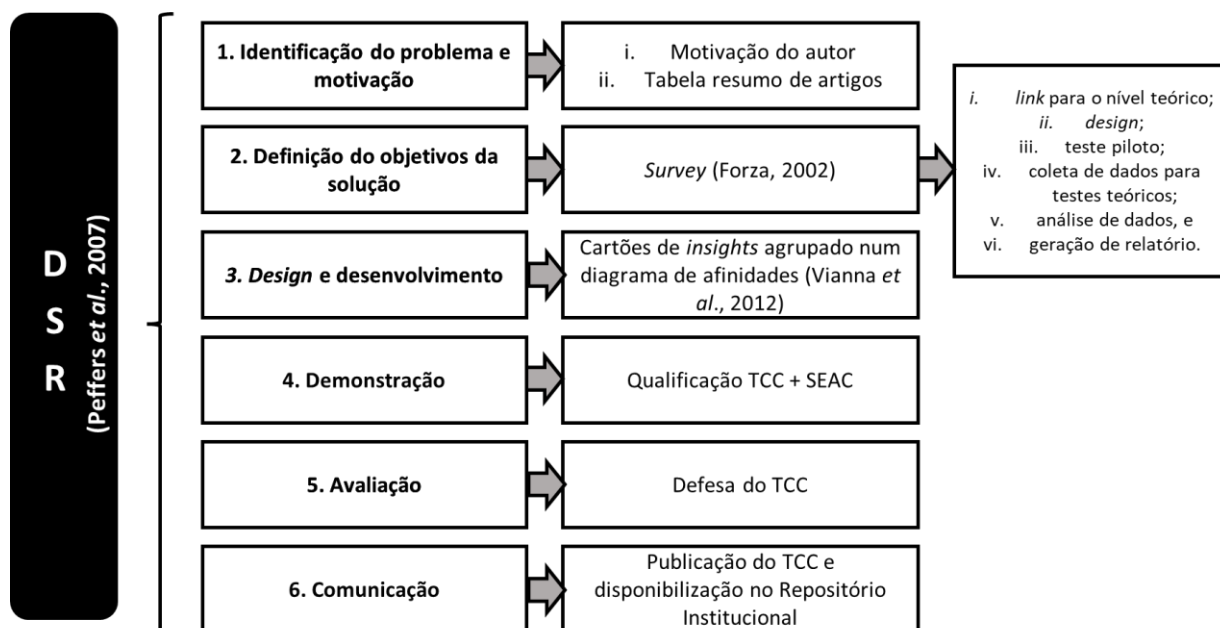
Em relação à abordagem, com base em Lakatos e Marconi (2017), essa pesquisa é de abordagem mista, ou seja, qualitativa e quantitativa. Qualitativa devido ao fato de alinhar-se à proposta de uma análise interpretativa e exploratória dos artigos encontrados na literatura e das informações coletados no Sul Fluminense; e quantitativa devido ao fato de realizar-se uma análise estatística dos dados coletados com a *survey* realizada no sul do estado do Rio de Janeiro.

Quanto aos procedimentos metodológicos, a presente pesquisa adota como base o método de DSR, que é um método voltado para a criação e avaliação de artefatos com o objetivo de solucionar problemas práticos e relevantes, promovendo ao mesmo tempo contribuições científicas (Peffer *et al.*, 2007). Essa abordagem busca o desenvolvimento de soluções inovadoras por meio de um processo estruturado, no qual a pesquisa é conduzida de forma iterativa e fundamentada em evidências. Assim, a aplicação de DSR neste trabalho visa propor, projetar e validar um artefato que atenda às necessidades identificadas, utilizando o conhecimento científico existente como suporte e base teórica.

3.2 METODOLOGIA DO DESENVOLVIMENTO DO ARTEFATO

Esse estudo adota a abordagem de DSR seguindo as etapas propostas por Peffer *et al.* (2007). Os seis passos propostos são: i) identificação do problema e motivação, onde se compreende a relevância e os desafios da situação a ser estudada; ii) definição dos objetivos da solução, com base nos requisitos identificados; iii) desenvolvimento do artefato, que envolve o projeto e a construção da solução proposta; iv) demonstração, em que o artefato é aplicado em um contexto real ou simulado para comprovar sua aplicabilidade; v) avaliação, busca analisar a eficácia do artefato e se os objetivos propostos foram alcançados; e vi) comunicação, onde os resultados obtidos são formalmente apresentados e disseminados para a comunidade acadêmica e profissional. O percurso metodológico adotado está demonstrado na Figura 1.

Figura 1 - Percurso metodológico



Fonte: o autor (2025)

Desse modo o trabalho seguirá os passos supracitados, da seguinte maneira: i) a identificação do problema e motivação foi com base observação e experiência do autor na indústria automotiva, além de uma pesquisa bibliográfica; ii) a definição dos objetivos foi o desenvolvimento e aplicação de uma pesquisa *survey* no Sul Fluminense; iii) no desenvolvimento do artefato foram criados cartões de *insights*, com base nos principais dados encontrados nas etapas anteriores, agrupando-os em um diagrama de afinidades; iv) para a demonstração foi realizada uma apresentação na Semana de Atividades Científicas (SEAC) de um centro universitário do Sul Fluminense, com banca e público presentes na sessão temática, além disso, esse estudo passou por uma qualificação de Trabalho de Conclusão de Curso (TCC) com professores especialistas, tanto na área profissional quanto na área acadêmica; v) foi avaliado, de fato, durante a defesa do TCC, que inclusive teve membros externos à faculdade; vi) a comunicação foi com publicação do TCC no repositório institucional da faculdade.

3.2.1 Identificação do problema e motivação

A identificação inicial do problema deu-se pela experiência do autor na indústria automotiva e pelo levantamento das hipóteses das dificuldades do gerenciamento do *Big Data* na região do Sul Fluminense.

Para a identificação do problema de uma forma mais detalhada, foi utilizado uma pesquisa bibliográfica na base *Scholar Google*, que tem inúmeros artigos e permite combinação de palavras no mecanismo de busca, além disso permitem o filtro por período de publicação.

A busca nas bases com os termos “*Industry 4.0*” AND “*Big Data analysis*” AND “*Automotive industry*” AND “*challenges*”, e com o filtro para restringir a pesquisa a artigos publicados entre 2020 e 2025, foram encontrados aproximadamente 352 documentos. A partir disso foram escolhidos 10 artigos para análise, considerando não apenas a qualidade e relevância da literatura, mas também o crescimento do número de publicações no período, o que evidencia o forte interesse da comunidade acadêmica pelo tema. Essa seleção assegura que o material represente contribuições significativas e alinhadas às inovações recentes do setor industrial.

A partir da seleção por afinidade ao tema deste presente estudo, iniciou-se uma análise detalhada dos mesmos em busca das informações necessárias para o desenvolvimento desse trabalho, tais como: local de publicação (revista), o que foi desenvolvido no trabalho, quais os resultados encontrados e quais as dificuldades levantadas no gerenciamento dos dados. Vale reforçar que o foco dessa pesquisa é a dificuldade do gerenciamento das massas de dados.

3.2.2 Definição dos objetivos

Já para a definição dos objetivos da solução, a partir da segunda fase do ciclo do DSR, elabora-se uma *survey* para compreensão dos problemas existentes como uma das soluções disponíveis sobre gerenciamento de *Big Data* no Sul Fluminense.

A pesquisa *survey* foi realizada de acordo com a recomendação de Forza (2002) para investigações em Engenharia de Produção e segue os seis passos que são: i) *link* para o nível teórico; ii) *design*; iii) teste piloto; iv) coleta de dados para testes teóricos; v) análise de dados e vi) geração de relatório.

O primeiro passo consiste em estabelecer um link com o nível teórico, o que envolve a revisão de literatura sobre *Big Data*. Nesse momento, são definidos os conceitos fundamentais e as variáveis que serão pesquisadas na *survey*. Além disso, levantam-se as hipóteses que poderão ser analisadas especificamente na região do Sul Fluminense, de modo a construir uma base sólida de conhecimento para orientar todas as etapas subsequentes da pesquisa.

Em seguida, inicia-se a etapa de *design*, que tem como objetivo identificar as empresas e os funcionários especialistas que atuam na área tecnológica no Sul do estado do Rio de Janeiro. Nessa fase, também é feita a definição da amostra que participará da pesquisa. Para

coletar informações consistentes, serão formuladas onze perguntas estratégicas, incluindo questões voltadas para os dados demográficos dos respondentes.

O pré-teste piloto é uma fase importante para garantir a qualidade do instrumento de pesquisa. Ele foi realizado com um especialista da área e dois professores universitários, permitindo identificar falhas e pontos de melhoria no questionário. A partir dessa etapa, foram realizados ajustes significativos nas perguntas cinco e seis do APÊNDICE B, bem como a criação de uma nova pergunta, neste caso a pergunta um. Essa validação inicial tem o propósito de garantir que os dados obtidos posteriormente sejam mais confiáveis e representativos.

A etapa de coleta de dados será conduzida utilizando meios digitais, como *e-mail* e aplicativos de mensagens, especialmente o *WhatsApp*®. Essa escolha busca ampliar o alcance da pesquisa e facilitar a resposta por parte dos participantes. Além disso, o uso de canais digitais permite uma comunicação mais rápida e eficiente, agilizando a obtenção das informações necessárias para as análises planejadas.

Após a coleta, realiza-se a análise e interpretação dos dados. Esse processo inclui o estudo das correlações entre variáveis e uma avaliação qualitativa das respostas fornecidas. A análise busca identificar padrões, tendências e *insights* relevantes, servindo de base para responder às hipóteses levantadas na fase teórica. Essa etapa é fundamental para que as conclusões do estudo tenham embasamento científico e prático.

Por fim, a última fase consiste na elaboração do relatório final. Nessa etapa, é desenvolvido o TCC, no qual são apresentados os resultados obtidos, juntamente com as análises realizadas e as considerações finais do estudo. Esse relatório é estruturado para transmitir de forma clara os achados da pesquisa e demonstrar a relevância do trabalho no contexto do *Big Data* na região do Sul Fluminense.

Após a conclusão dos seis passos supracitados tem-se o questionário final, disposto no APÊNDICE B, onde as perguntas que apresentam opções de respostas enumeradas com letras somente permitem uma resposta, ou seja, são de múltipla escolha; já as perguntas que apresentam opções de respostas que são iniciadas por parênteses permitem mais de uma opção de resposta, sendo assim caixas de seleção.

A pesquisa deu-se de maneira online devido à vários motivos, dentre eles o custo reduzido com a eliminação de gastos com impressão, deslocamento ou contratação de entrevistadores (Fowler, 2013).

Para a realização da pesquisa foi selecionado a plataforma *Google Forms*, visto que é uma ferramenta gratuita e comumente utilizada no campo de pesquisas online, ou seja,

apresenta boa confiabilidade, além disso, permite a personalização de perguntas (múltipla escolha, escalas *Likert*, campos abertos), enriquecendo a experiência do participante (Mondal *et al.*, 2019).

Com o questionário já pronto, o próximo passo é o envio para coletar as respostas, a amostragem será definida por conveniência, que é um método não probabilístico de seleção de participantes no qual os indivíduos são escolhidos com base na acessibilidade e disponibilidade, sem aleatorização (Bryman e Bell, 2015). Essa técnica é frequentemente utilizada em pesquisas exploratórias ou estudos com restrições de tempo e recursos, pois permite a coleta rápida de dados a baixo custo (Etikan, Musa e Alkassim, 2016). Assim sendo, o questionário foi finalizado e enviado aos respondentes, que são colaboradores de empresas automotivas do Sul Fluminense, via *e-mail* e *WhatsApp*®.

3.2.3 Desenvolvimento do artefato

Seguindo os conceitos de Vianna *et al.* (2012), o diagrama de afinidades é uma ferramenta visual utilizada para organizar e estruturar ideias, opiniões e informações complexas, favorecendo a identificação de padrões e relações entre os dados. Essa metodologia é especialmente útil na fase de análise de pesquisas qualitativas, pois permite agrupar informações dispersas em categorias que emergem de forma natural, auxiliando na interpretação dos resultados. O processo se dá por meio da interação de uma equipe multidisciplinar, que analisa os dados e propõe agrupamentos baseados em similaridades e temas centrais, facilitando a compreensão do problema e estimulando a colaboração.

Os cartões de *insights* são um dos elementos fundamentais para a construção do diagrama de afinidades, pois representam informações, ideias ou percepções extraídas de dados coletados, como entrevistas, questionários ou observações. Cada cartão contém uma ideia central, escrita de forma objetiva, para facilitar sua visualização e posterior agrupamento. O uso desses cartões contribui para a síntese de grandes volumes de informações e para a geração de *insights* relevantes, tornando o processo mais interativo e participativo. Essa abordagem permite organizar os dados de forma hierárquica e visual, possibilitando a construção de um entendimento coletivo do tema estudado (Vianna *et al.*, 2012).

3.2.4 Demonstração, avaliação e comunicação

A fase de demonstração consiste na aplicação prática do artefato desenvolvido, com o objetivo de mostrar como ele pode resolver o problema proposto. Neste estudo, a demonstração foi realizada durante a SEAC, que é um evento institucional voltado à difusão de pesquisas acadêmicas, sendo este aberto ao público do Sul Fluminense. Esse ambiente proporcionou uma oportunidade adequada para apresentar o artefato desenvolvido, permitindo evidenciar sua funcionalidade, relevância e aderência ao contexto da pesquisa. A apresentação visa não apenas demonstrar o uso do artefato, mas também iniciar a coleta de *feedbacks* preliminares que poderão auxiliar na etapa seguinte.

A avaliação do artefato proposto foi conduzida durante a defesa oficial do TCC. Nesta fase, foi considerado o julgamento de uma banca avaliadora composta por especialistas, que observaram aspectos como coerência metodológica, aplicabilidade prática, consistência teórica e inovação. A defesa permitiu avaliar o artefato por meio de uma análise crítica, buscando identificar suas contribuições e limitações. A utilização de critérios objetivos e argumentação fundamentada serão essenciais para validar os resultados alcançados pela pesquisa.

Por fim, a fase de comunicação envolve a disseminação dos resultados obtidos, com a finalidade de compartilhar o conhecimento gerado com a comunidade acadêmica e profissional, esta etapa é crucial para garantir o impacto científico e prático da pesquisa. Neste trabalho, a comunicação foi concretizada por meio da publicação do TCC no repositório institucional da faculdade, permitindo o acesso ao conteúdo por outros pesquisadores, professores e alunos interessados na temática. A publicação do trabalho reforça o compromisso com a ciência aberta e com a evolução do conhecimento na área, contribuindo com futuras investigações e aplicações relacionadas ao tema estudado.

4. RESULTADOS E DISCUSSÕES

Neste capítulo serão trazidos e discutidos os resultados de cada etapa metodológica delineada pelo ciclo sistemática proposto por Peffers *et al.* (2007).

4.1 IDENTIFICAÇÃO DO PROBLEMA E MOTIVAÇÃO

Como resultados encontrados na literatura, temos o APÊNDICE A para examinar cada uma das pesquisas estudadas. Nesse sentido, foram levantadas informações sobre a publicação, incluindo: título, autor, ano, local de publicação, o que foi feito e resultados encontrados nas

pesquisas. Em seguida, foi designado um campo específico para coletar as dificuldades de gerenciamento de dados, trazidas por cada artigo.

Em resumo, as principais dificuldades trazidas pela literatura foram: a complexidade na integração tecnológica, a necessidade de infraestrutura adequada, as limitações tecnológicas, a necessidade de tratamento e integração dos dados, a resistência à mudanças, a falta de treinamentos e capacitação dos funcionários, e a má qualidade dos dados recebidos

4.2 DEFINIÇÃO DOS OBJETIVOS DA SOLUÇÃO

A pesquisa *survey* foi realizada entre os dias dezesseis de agosto e quatro de setembro de dois mil e vinte e cinco e obteve um total de 62 respostas. Os dados detalhados estão apresentados nas Figuras 2 a 9.


Contextualizando o perfil dos participantes do estudo, observa-se que 60 participantes indicaram trabalhar em indústrias localizadas na região Sul Fluminense, o que representa 96,8% dos participantes, ou seja, a maioria dos envolvidos no estudo. Esse dado reforça a capacidade da pesquisa em capturar a realidade desse polo industrial específico, objeto do trabalho. Além disso, a amostra é majoritariamente composta por grandes empresas (74,2%), o que é um fator significativo para a análise subsequente, pois empresas de maior porte geralmente possuem mais recursos e necessidade para investir em tecnologias complexas como *Big Data*, influenciando diretamente as taxas de adoção e os desafios relatados.

Já em relação ao perfil dos respondentes, destaca-se uma predominância de cargos de analista (43,5%), sugerindo que as respostas partem de profissionais com visão estratégica e operacional do negócio.

Na Figura 2, pode-se observar o fato de 100% das empresas já utilizarem a tecnologia, seja de forma estruturada ou limitada, indicando uma maturidade significativa na região, provavelmente impulsionada pela necessidade de se manter competitiva em um setor automotivo altamente complexo.


A Figura 3 revela como e em quais campos está sendo aplicado o *Big Data*. A aplicação mais citada é o "Desenvolvimento de Indicadores Chaves" (100%), seguida pelo "Controle de qualidade em tempo real" (76,7%). Já a Figura 4 indica que o Power BI (73,3%) é a plataforma de *analytics* mais utilizada, seguida pelo Excel (15%). A predominância do Power BI sugere um nível de maturidade analítica, com investimentos em ferramentas projetadas para lidar com grandes volumes de dados e gerar *insights* visuais.

Figura 2 – Como é utilizado o *Big Data* pelas empresas, de acordo com os participantes da *survey*




Fonte: o autor (2025)

Figura 3 - Aplicações mais empregadas pelas empresas que utilizam *Big Data*, segundo os participantes da *survey*



Fonte: o autor (2025)

Figura 4 - Software mais utilizado pelas empresas para gerenciamento de *Big Data*, segundo os participantes da *survey*



Fonte: o autor (2025)

A Figura 5 revela o panorama que as empresas do setor automotivo do Sul Fluminense enfrentam, observa-se que o desafio mais significativo não é técnico, mas cultural: a "Resistência cultural à mudanças" foi citada por 37 respondentes, representando 61,7% das respostas. Este dado revela que a maior barreira para a implementação do *Big Data* não está na tecnologia em si, mas na dificuldade de adaptação das pessoas e processos organizacionais a uma nova cultura orientada por dados, conforme, também, encontra na literatura por (Francisco e Costa, 2024; Zattar *et al.*, 2023; Ojha *et al.*, 2024; Leka *et al.*, 2025).


Vale ressaltar que nessa questão os participantes puderam indicar até três respostas, o que pode trazer os *insights* mais urgente e que mais podem impactar o gerenciamento do *Big Data* em suas respectivas empresas.

Em seguida, aparecem os desafios técnicos e de infraestrutura, tais como: "Falta de *hardware* para tratar e analisar os dados", que foi citada por 48,3% dos respondentes, indicando que a infraestrutura física necessária para processar grandes volumes de informação ainda é uma barreira significativa. Logo após, as "Preocupações com segurança e privacidade dos dados" (46,7%) e a "Falta de profissionais capacitados" (43,3%) aparecem como obstáculos, mostrando que as empresas, do Sul Fluminense, enfrentam simultaneamente desafios de proteção de dados e escassez de mão de obra especializada. Já na literatura somente foi encontrado a escassez de mão de obra especializada, conforme estudo de (Da Costa Neto e Campos, 2023; Zattar *et al.*, 2023; Leka *et al.*, 2025).

Este resultado contrasta com a Figura 6, que mostra que 95% das empresas possuem equipes internas especializadas ou terceirizam o serviço. A contradição aparente sugere que, mesmo possuindo especialistas, a demanda por profissionais qualificados ainda supera a oferta, ou que os desafios técnicos de infraestrutura (*hardware*) são tão grandes que pode sobrecarregar até mesmo equipes dedicadas.

O quarto grupo de desafios inclui a "Má qualidade dos dados disponíveis" (36,7%), que compromete a confiabilidade de qualquer iniciativa analítica, e problemas operacionais como a "Dificuldade na coleta e armazenamento de dados" e a "Falta de integração entre sistemas" (ambas com 21,7%), que indicam deficiências na arquitetura de dados das organizações. Por fim, a "Necessidade de investimentos financeiros" (20%) completa o panorama, ressalta-se que todos esses desafios têm implicações orçamentárias.

Figura 5 - Principais desafios no gerenciamento do *Big Data*, de acordo com os participantes da *survey*



Fonte: o autor (2025)

Figura 6 – Equipe de especialistas no gerenciamento do *Big Data*, de acordo com os participantes da *survey*



Fonte: o autor (2025)


Há uma percepção positiva sobre o impacto do *Big Data*, onde na Figura 7, 96,7% dos respondentes avaliam esse impacto como 4 ou 5, em uma escala de 1 (nenhum impacto) a 5 (impacto extremamente positivo), observa-se uma concentração expressiva de respostas nas classificações mais altas. Do total de 60 respondentes, a moda da distribuição é 4, representada por 51,7% (31 respostas), seguida de perto pela nota 5, com 45% (27 respostas). O cálculo da média aritmética, ponderada pelas frequências, resulta em aproximadamente 4,42, refletindo a tendência central elevada das avaliações. De forma similar, a mediana situa-se no valor 4, uma vez que mais de 50% das respostas se concentram a partir desta classificação. Em contrapartida, apenas 3,3% (2 respostas) concederam nota 3, e nenhum participante utilizou as notas 1 ou 2. Esses resultados indicam uma percepção majoritariamente positiva sobre a influência do *Big*

Data, com 96,7% das respostas situadas nas duas faixas superiores da escala, sugerindo que a gestão de dados é considerada um fator relevante e de alto impacto para os resultados empresariais na amostra pesquisada.

Essa visão é corroborada pelas vantagens esperadas ou obtidas na Figura 8, onde "Melhoria na tomada de decisão estratégica" (93,3%) e "Redução de custos operacionais" (78,3%) se destacam. Isso demonstra que, superados os desafios iniciais, as empresas enxergam no *Big Data* um retorno tangível e estratégico, validando os investimentos realizados.

A análise otimista culmina na visão de futuro expressa na Figura 9, onde 85% dos respondentes acreditam que o *Big Data* será "totalmente essencial" para a competitividade do setor automotivo nos próximos 5 anos. Essa convicção está alinhada com a alta avaliação de impacto atual (Figura 7) e as vantagens estratégicas percebidas (Figura 8), pintando um cenário em que a adoção e o refinamento do uso de dados não são uma opção, mas uma necessidade para a sobrevivência e sucesso no mercado.

Figura 7 - Resultado referente a pergunta: Em uma escala de 1 a 5, como você avaliaria o impacto do gerenciamento do *Big Data* nos resultados de sua empresa?



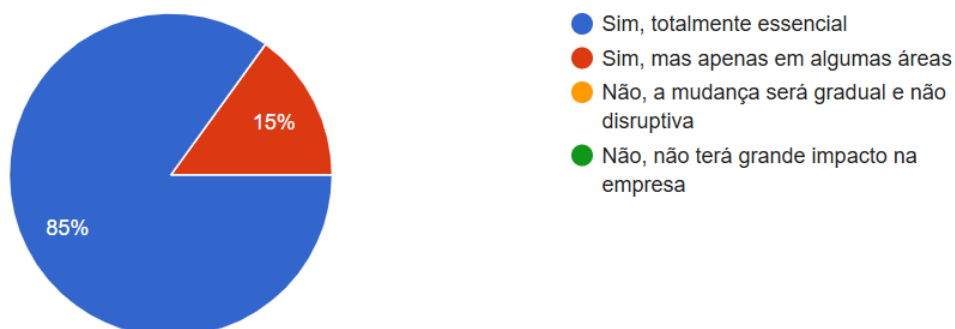
Fonte: o autor (2025)

Figura 8 - As principais vantagens que as empresa tem e/ou espera ter ao implementar *Big Data*, de acordo com os participantes da survey



Fonte: o autor (2025)

Figura 9 - *Big Data* como um fator para a competitividade no setor automotivo nos próximos 5 anos, de acordo com os participantes da *survey*



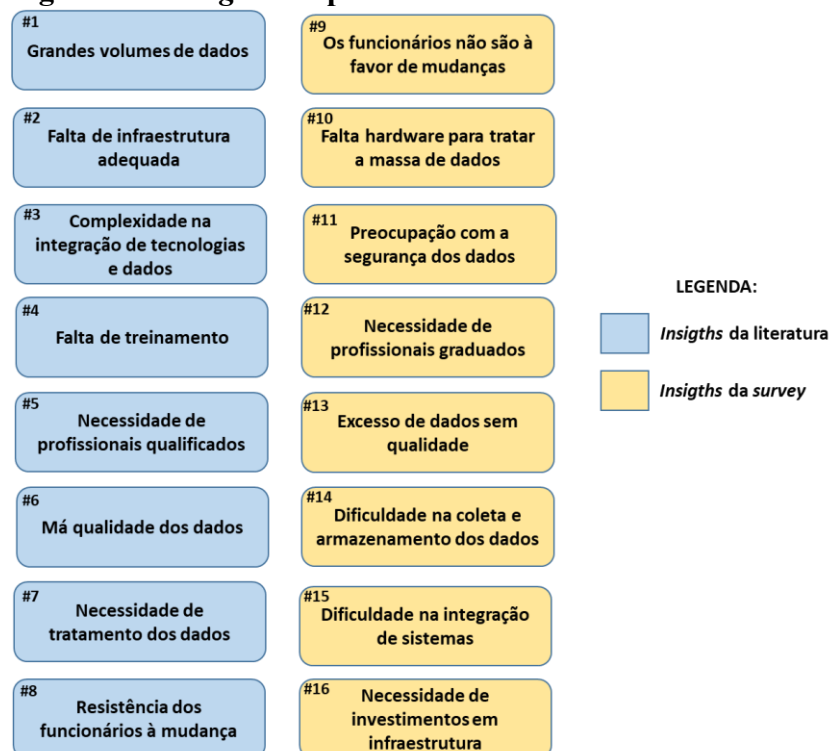
Fonte: o autor (2025)

4.3 DESIGN E DESENVOLVIMENTO

4.3.1 Mapeamento dos *insights*

Considerando os achados na literatura e os dados coletados com a *survey*, a essa seção apresenta tais resultados. Para isso, primeiro, as evidências foram organizadas em cartões de insight, segundo proposto por Vianna *et al.* (2012). Desse modo, elaborou-se 16 cartões de insight, os quais foram distribuídos da seguinte maneira: oito baseados na literatura e oito provenientes da *survey*. Com isso, essa etapa viabilizou a sistematização dos principais desafios relacionados ao gerenciamento de *Big Data* nas empresas automotivas, de forma a facilitar a organização e a análise dos dados, especialmente, visando uma compreensão clara dos problemas mapeados. A Figura 10 demonstra esses cartões de *insights*, eles são apresentados em ordem numérica conforme a posição que foram identificados ao longo do estudo.

Figura 10 - Insights mapeados

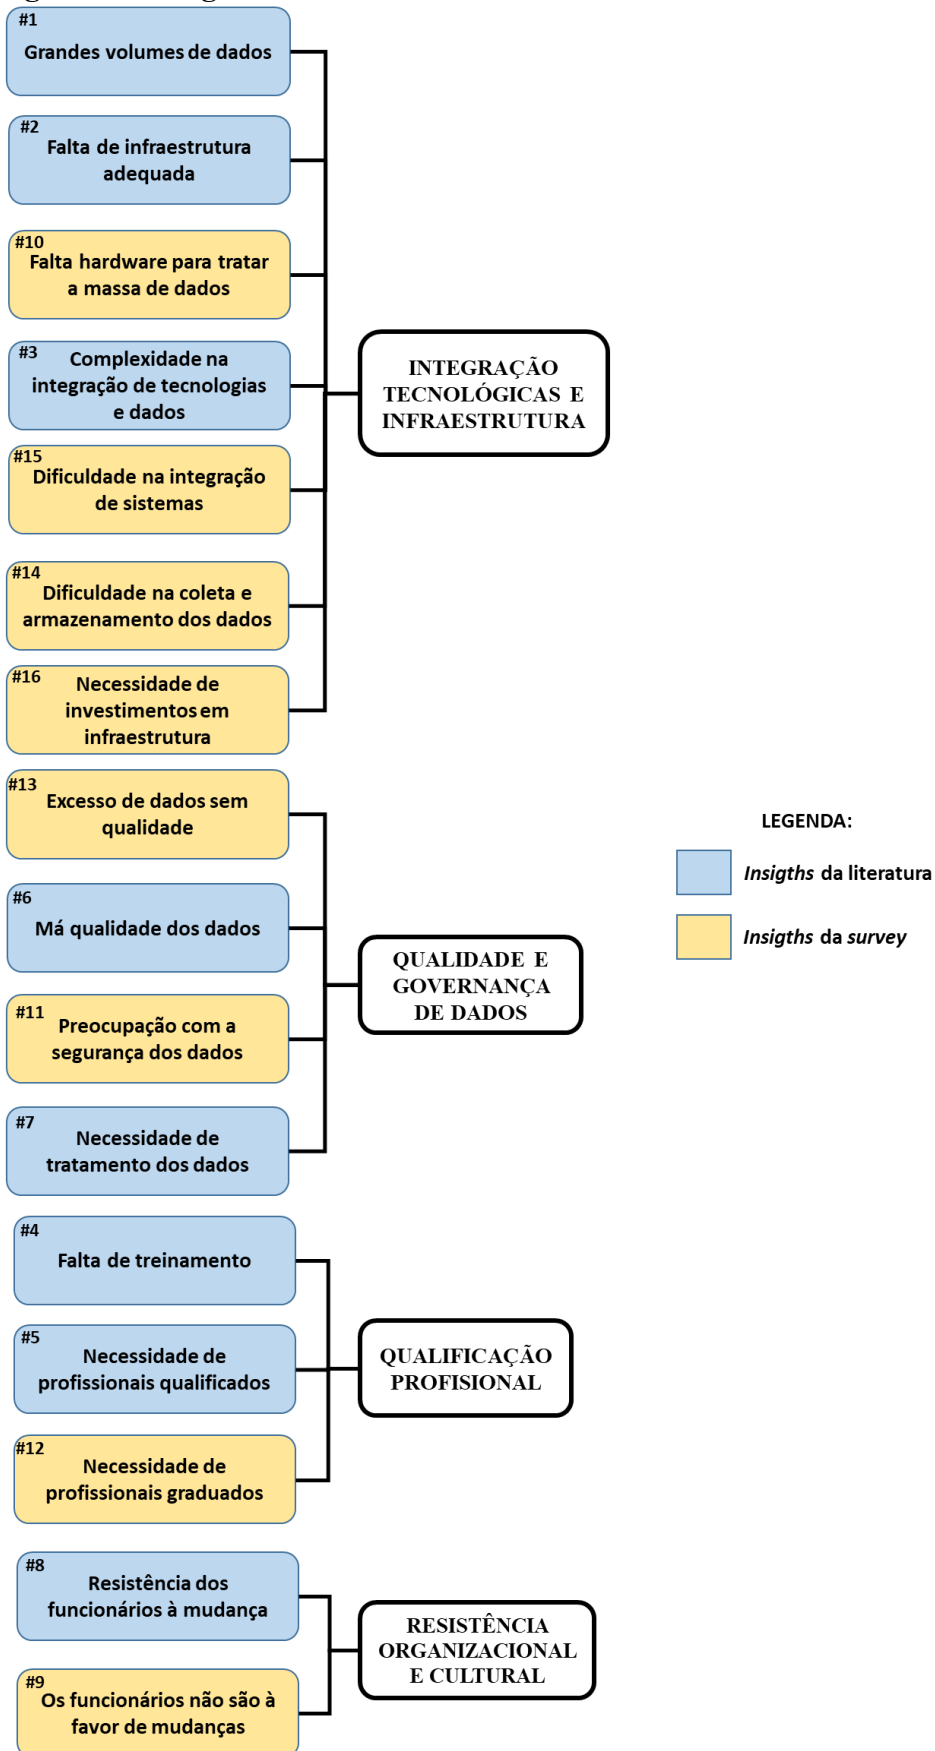


Fonte: o autor (2025)

4.3.2 Sistematização: por meio do diagrama de afinidades

Dessa forma, após a organização dos cartões de *insight* de acordo com suas semelhanças, elaborou-se um diagrama de afinidades, conforme definido por Viana *et al.* (2012). Destaca-se que os cartões de insight são organizados em dois grupos principais, sendo a fonte de tais *insights*: a literatura e a *survey*. Assim, esses *insights* refletem os desafios identificados para o gerenciamento de *Big Data*. Com isso, essa categorização proporciona uma análise sistemática dos desafios e a identificação de estratégias para o gerenciamento de *Big Data* nas empresas automotivas. A Figura 11 demonstra cartões de *insights* agrupados e interligados com as principais macro dificuldades encontradas formando um diagrama de afinidades, agrupando os pontos levantados na pesquisa bibliográfica e na *survey*.

Figura 11 - Diagrama de Afinidades



Fonte: o autor (2025)

A Figura 11 resume diferentes estudos sobre o gerenciamento do *Big Data* na indústria, especialmente no setor automotivo. Os obstáculos mais recorrentes estão ligados à integração tecnológica, à resistência organizacional, à necessidade de qualificação profissional e à qualidade e governança de dados. A complexidade na integração de diferentes sistemas e fontes de dados é um dos principais entraves, exigindo infraestrutura adequada e compatibilidade entre plataformas.

Outro desafio notável é a resistência à mudança por parte das organizações e seus colaboradores. Essa resistência aparece sob diversas formas, como a relutância em adotar novas tecnologias, dificuldades culturais na aceitação de processos orientados por dados e falta de engajamento com soluções tecnológicas. Além disso, a baixa qualidade dos dados disponíveis e a escolha inadequada de ferramentas também se mostraram barreiras críticas que comprometem o gerenciamento da massa de dados.

A capacitação técnica dos profissionais surge como um ponto crucial para o sucesso da implementação. Isso indica uma carência de profissionais qualificados para atuar com o *Big Data*, reforçando assim a necessidade de investimentos em treinamento e desenvolvimento de habilidades específicas para o uso estratégico dos dados, o que pode impactar diretamente na eficiência das decisões empresariais baseadas em dados.

4.4 DEMONSTRAÇÃO, AVALIAÇÃO E COMUNICAÇÃO

A fase de demonstração consiste na aplicação prática do artefato desenvolvido, com o objetivo de mostrar como ele pode resolver o problema proposto. Neste estudo, a demonstração foi realizada durante a Semana de Atividades Científicas (SEAC), evento institucional voltado à difusão de pesquisas acadêmicas, por meio de sessões temáticas. Esse ambiente proporcionou uma oportunidade para apresentar o artefato desenvolvido, permitindo evidenciar sua funcionalidade e relevância. A apresentação visou não apenas demonstrar o uso do artefato, mas também iniciar a coleta de *feedbacks* preliminares que auxiliarão na etapa seguinte.

A avaliação do artefato proposto aconteceu durante a defesa oficial do TCC. Nesta fase, foi considerado o julgamento de uma banca avaliadora composta por especialistas acadêmicos, que observaram aspectos como coerência metodológica, aplicabilidade prática e consistência teórica. A defesa permitiu avaliar a eficácia do artefato por meio de uma análise crítica, buscando identificar suas contribuições e limitações. A utilização de critérios objetivos e argumentação fundamentada foram essenciais para validar os resultados alcançados pela pesquisa.

Por fim, a fase de comunicação envolve a disseminação dos resultados obtidos, com a finalidade de compartilhar o conhecimento gerado com a comunidade acadêmica e profissional, esta etapa é crucial para garantir o impacto científico e prático da pesquisa. Neste trabalho, a comunicação foi concretizada por meio da publicação do TCC na base institucional da faculdade, permitindo o acesso ao conteúdo por outros pesquisadores, professores e alunos interessados na temática. A publicação do trabalho reforça o compromisso com a ciência aberta e com a evolução do conhecimento na área, contribuindo com futuras investigações e aplicações relacionadas ao tema estudado.

4.5 DISCUSSÕES: COMPARAÇÃO ENTRE *SURVEY* E LITERATURA

O diagrama de afinidades, da Figura 11, ajuda na compreensão de que os principais problemas no gerenciamento do *Big Data* estão compreendidos em dois grandes grupos: problemas relacionados à *software* e *hardware*; e problemas relacionado à cultura e pessoas.

Com base na análise do Diagrama de Afinidades, indicado na Figura 11, e da revisão de literatura, observa-se que as dificuldades tecnológicas e de infraestrutura são recorrentes tanto na pesquisa de campo quanto nos estudos publicados. Questões como a complexidade na integração de sistemas, a gestão de grandes volumes de dados e a falta de infraestrutura adequada foram destacadas no diagrama (*insights* #2, #3, #10, #14, #15, #16). Esses desafios são corroborados por autores como Zhang *et al.* (2022), que apontam a “complexidade na integração de tecnologias e necessidade de infraestrutura adequada”, e Santos *et al.* (2021), que relatam “complexidade na integração de sistemas e na gestão de grandes volumes de dados” em sua implementação de *Big Data Warehouse*.

Outro eixo crítico identificado refere-se à qualidade e tratamento dos dados. Tanto o diagrama (*insights* #6, #7, #13) quanto a literatura revisada indicam que a má qualidade dos dados e a necessidade de seu tratamento prévio representam entraves significativos. Francisco e Costa (2023) mencionam a “má qualidade dos dados” como um dos principais obstáculos para a plena utilização de BI, enquanto Oliveira *et al.* (2023) relatam “dificuldades no tratamento e integração de diferentes bases de dados”, reforçando a relevância desse aspecto para o sucesso das iniciativas baseadas em dados.

A escassez de mão de obra qualificada também se mostra uma barreira consistente. O diagrama evidencia a “necessidade de profissionais qualificados” e “graduados” (*insights* #5, #12), alinhando-se com os achados de Costa Neto e Campos (2021), que identificaram a “necessidade de profissionais qualificados e integração com sistemas” como um dos principais

desafios. Da mesma forma, Zattar *et al.* (2023) observaram “dificuldades na adaptação cultural e na capacitação dos funcionários”, indicando que a qualificação não se restringe apenas à técnica, mas também à capacidade de adaptação a novas ferramentas e processos.

Por fim, a resistência organizacional e cultural emerge como um desafio humano e gerencial relevante. Itens como “resistência dos funcionários à mudança” (*insights* #8, #9) foram agrupados no diagrama sob essa categoria. Na literatura, Leka *et al.* (2025) constataram a “resistência dos funcionários” durante a implementação de ferramentas de BI. Ojha *et al.* (2024) também destacaram a “resistência à mudança” entre os obstáculos à implementação da Indústria 4.0, demonstrando que, além dos fatores técnicos, aspectos comportamentais e culturais exigem atenção estratégica para a adoção bem-sucedida de novas tecnologias.

No que diz respeito às aplicações, o desenvolvimento de Indicadores Chaves de Desempenho e o controle de qualidade em tempo real são predominantes. Essa focalização em monitoramento e qualidade reflete a natureza da indústria automotiva, onde precisão e conformidade são críticas. O *software* mais utilizado é o Power BI, o que sugere uma preferência por ferramentas de *Business Intelligence* com interface amigável, em detrimento de plataformas mais complexas ou de código aberto.

Apesar dos desafios, a percepção de valor do *Big Data* é alta. A avaliação de seu impacto nos resultados empresariais concentra-se nas notas altas. Essa avaliação está diretamente relacionada às vantagens esperadas, sendo a "Melhoria na tomada de decisão estratégica" a mais citada, seguida pela "Redução de custos operacionais".

Por fim, a visão sobre o futuro é unânime e otimista: profissionais acreditam que o *Big Data* será "totalmente essencial" para a competitividade do setor automotivo nos próximos 5 anos. Este dado, somado aos anteriores, pinta um panorama claro: a indústria automotiva do Sul Fluminense reconhece a criticalidade do *Big Data*, investe em sua estrutura e enxerga seus benefícios, mas ainda trava uma batalha contra limitações de infraestrutura, segurança e, sobretudo, uma cultura organizacional resistente à transformação digital necessária para aproveitar todo seu potencial.

5. CONCLUSÃO

Os resultados desta pesquisa evidenciam que, embora as empresas automotivas do Sul Fluminense enfrentem barreiras significativas para a adoção da tecnologia *Big Data*, como falta de infraestrutura, escassez de mão de obra qualificada e dificuldades de integração de sistemas, existe um potencial significativo de retorno financeiro. A implementação bem-sucedida dessa tecnologia pode levar à redução de custos operacionais, aumento da eficiência produtiva e melhoria nos processos decisórios. Isso sugere que o investimento inicial pode ser amortizado a médio prazo, especialmente em empresas que conseguem transformar dados em inteligência estratégica.

No tocante aos impactos acadêmicos, este estudo contribui para a ampliação do conhecimento sobre os desafios da gestão do *Big Data* em contextos regionais e setoriais específicos. Ao abordar uma realidade localizada, o polo automotivo do Sul Fluminense, além disso, fornece insumos empíricos relevantes para pesquisadores e formuladores de políticas públicas que desejam entender como as inovações digitais se disseminam fora dos grandes centros industriais do país. Outro ponto, é que o presente estudo reforça a importância da cooperação entre universidades, indústrias e governos para promover o desenvolvimento tecnológico sustentável e inclusivo.

A pesquisa bibliográfica demonstrou que os principais entraves relatados globalmente também se repetem na região estudada, como limitações tecnológicas e lacunas na capacitação. No entanto, tanto a literatura quanto os dados de campo indicam que os benefícios da aplicação de *Big Data* superam significativamente os obstáculos, desde que haja planejamento estratégico.

A partir da pesquisa de campo, observou-se que há uma crescente conscientização por parte dos profissionais locais sobre a importância da transformação digital. Apesar da baixa implementação efetiva, os respondentes reconhecem o papel essencial do gerenciamento da massa de dados para a competitividade futura do setor automotivo. Esse dado é crucial, pois aponta uma janela de oportunidade para o desenvolvimento de ações voltadas à qualificação técnica, à criação de políticas de incentivo à inovação e à estruturação de ecossistemas colaborativos de inovação.

Embora a pesquisa tenha adotado a amostragem por conveniência, reconhece-se que essa escolha metodológica pode trazer limitações quanto à representatividade dos resultados. Esse tipo de seleção, baseada na facilidade de acesso e disponibilidade dos respondentes, pode introduzir vieses relacionados ao perfil dos participantes e restringir a diversidade de

perspectivas analisadas. No entanto, também apresenta vantagens relevantes, como a agilidade na coleta de dados, a redução de custos operacionais e a viabilidade prática em contextos com restrições de tempo e recursos, características comuns em pesquisas aplicadas e exploratórias. Assim, o método mostrou-se adequado aos objetivos deste estudo, possibilitando a obtenção de informações consistentes e alinhadas à realidade das indústrias automotivas do Sul Fluminense.

Com isso, conclui-se que, embora a região Sul Fluminense enfrente barreiras estruturais e humanas, há uma base de conscientização e interesse crescente que pode ser alavancada por meio de ações conjuntas entre empresas, academia e governo.

Além disso, devido ao alinhamento entre a expectativa dos profissionais, as evidências da literatura e as possibilidades de retorno financeiro demonstra que este é o momento oportuno para que empresas e instituições de ensino invistam em tecnologias emergentes e qualificação de pessoal.

Para trabalhos futuros, recomenda-se a realização de um estudo de retorno sobre o investimento (ROI) nas tecnologias de *Big Data*, com o objetivo de mensurar financeiramente os benefícios obtidos e o impacto sobre a eficiência operacional das empresas. Além disso, sugere-se a execução de estudos de caso aprofundados em diferentes empresas do setor automotivo e a comparação entre polos industriais de distintas regiões brasileiras. Essas iniciativas poderão fornecer uma visão mais abrangente sobre o nível de maturidade digital da indústria nacional e apoiar a formulação de estratégias mais eficazes de gestão e aproveitamento do *Big Data*.

REFERÊNCIAS

ANFAVEA. Anuário da Indústria Automobilística Brasileira. **Brazilian Automotive Industry Yearbook**, 2025.

BLOISE, Denise Martins. A importância da metodologia científica na construção da ciência. **Revista Científica Multidisciplinar Núcleo do Conhecimento**, p. 105–122, 24 jun. 2020.

BRYMAN, Alan; BELL, Emma. **Business Research Methods**. 4. ed. Oxford University Press, 2015.

BRYNJOLFSSON, Erik; MCAFEE, Andrew. **The Second Machine Age: Work, Progress, and Prosperity in a Time of Brilliant Technologies**. 1. ed. Estados Unidos da América: W. W. Norton & Company, 2016.

BUSINESS RESEARCH *INSIGHTS*. **Big Data and Data Engineering Services Market Size, Share, Growth, And Industry Analysis, By Type (Data Modeling, Data Integration, Data Quality, and Analytics), By Application (Marketing and Sales, Finance, Operations, and Human Resources and Legal) , Regional Insights and Forecast From 2025 To 2033** Source: <https://www.businessresearchinsights.com/market-reports/big-data-and-data-engineering-services-market-111571>. Disponível em: <<https://www.businessresearchinsights.com/market-reports/big-data-and-data-engineering-services-market-111571>>. Acesso em: 13 jun. 2025.

CHEN, H.; CHIANG, R. H. L. Business Intelligence and Analytics: From *Big Data* to Big Impact. **MIS Quarterly**, v. 36, n. 4, p. 1165–1188, 2014.

CRONIN, Matthew A.; GEORGE, Elizabeth. The Why and How of the Integrative Review. **Organizational Research Methods**, v. 26, n. 1, p. 168–192, 6 jan. 2023.

DA COSTA NETO, Luiz Gonzaga; CAMPOS, Fernando Celso de. Oportunidades de aplicações de Business Intelligence no contexto da indústria 4.0: revisão sistemática da literatura 2015-2020. **Exacta**, v. 21, n. 2, p. 503–519, 12 jun. 2023.

DAVENPORT, Thomas H.; HARRIS, Jeanne G. **Competing on Analytics: The New Science of Winning**. 1. ed. Harvard Business School Press, 2017.

ECKERSON, Wayne W. **Performance Dashboards: Measuring, Monitoring, and Managing Your Business**. 2. ed. Wiley, 2010.

EKBIA, Hamid *et al.* *Big Data*, bigger dilemmas: A critical review. **Cornell University**, 2 set. 2015.

ETIKAN, Ilker; MUSA, Sulaiman Abubakar; ALKASSIM, Rukayya Sunusi. Comparison of Convenience Sampling and Purposive Sampling. **American Journal of Theoretical and Applied Statistics**, v. 5, n. 1, p. 1, 2016.

FEW, Stephen. **Show Me the Numbers: Designing Tables and Graphs to Enlighten**. 2. ed. Analytics Press, 2012.

FORZA, Cipriano. *Survey* research in operations management: a process-based perspective. **International Journal of Operations & Production Management**, v. 22, n. 2, p. 152–194, 1 fev. 2002.

FOWLER, Floyd J. **Survey Research Methods (Applied Social Research Methods)**. 5. ed. SAGE Publications, 2013.

FRANCISCO, Leticia Carneiro; COSTA, Simone Alves. Os desafios para a utilização plena do Business Intelligence: um estudo no setor de consumo cíclico. **LICEU on-line**, 2024.

GAO, Jiejing. *Big Data* Analysis for Supply Chain Management in Vehicle Industry. **BCP Business & Management**, v. 34, p. 1192–1197, 14 dez. 2022.

GARTNER. **Gartner Glossary: Big Data**. Disponível em: <<https://www.gartner.com/en/information-technology/glossary/big-data#:~:text=Big%20data%20is%20high%2Dvolume,decision%20making%2C%20and%20process%20automation.>>. Acesso em: 14 maio. 2025.

HERMANN, Mario; PENTEK, Tobias; OTTO, Boris. **Design Principles for Industrie 4.0 Scenarios: A Literature Review**. Dortmund. 2015

HOBBSAWM, Eric. **A era das revoluções: 1789-1848**. 1. ed. Paz & Terra, 2012.

KAGERMANN, H.; WAHLSTER, W.; HELBIG, J. Recommendations for implementing the strategic initiative INDUSTRIE 4.0. **National Academy of Science and Engineering**, 2013.

KANGERMANN, Henning; HELBING, Johannes; WAHLSTER, Wolfgang. **Recommendations for implementing the strategic initiative INDUSTRIE 4.0**. National Academy of Science and Engineering, , 2013.

KIMBALL, Ralph; ROSS, Margy. **The Data Warehouse Toolkit: The Definitive Guide to Dimensional Modeling**. 3. ed. Wiley, 2013.

KOTHARI, C. R.; GARG, G. **Research Methodology: Methods and Techniques**. 4. ed. New Age Publishers, 2019.

LAKATOS, Eva Maria; MARCONI, Marina de Andrade. **Fundamentos de Metodologia Científica**. 8. ed. São Paulo: Atlas, 2017.

LANDES, David. **The Unbound Prometheus: Technological Change and Industrial Development in Western Europe from 1750 to the Present**. 2. ed. Cambridge University Press, 2010.

LEE, Jay; BAGHERI, Behrad; KAO, Hung-An. A Cyber-Physical Systems architecture for Industry 4.0-based manufacturing systems. **Manufacturing Letters**, v. 3, p. 18–23, jan. 2015.

LEKA, Blerta; LEKA, Daniel; BARAKU, Brunilda. Driving Operational Excellence: Business Intelligence in the Car Parts Industry. **WSEAS TRANSACTIONS ON BUSINESS AND ECONOMICS**, v. 22, p. 270–279, 26 fev. 2025.

MACHADO, Felipe Nery Rodrigues. **Big Data: O futuro dos dados e aplicações**. 1. ed. Editora Érica - Sob Demanda, 2018.

MAHMOUD ELHOUSHY, Mohamed; MAHMOUD ELHENNAWY, Elsayed; KHAMIS ZAYTOUN, Mohamed. The Impact of *Big Data*'s Characteristics on the Management Accountant's Role as A Business Partner - A Field Evidence from Egyptian Environment. **Journal of Finance and Accounting**, v. 11, n. 1, p. 19–27, 9 maio 2023.

MCAFEE, Andrew; BRYNJOLFSSON, Erik. *Big Data: The Management Revolution*. In: Harvard business review, 2012.

MCKINNEY, Wes. **Python for Data Analysis: Data Wrangling with Pandas, NumPy, and IPython**. 1. ed. O'Reilly Media, 2012.

MONDAL, Himel *et al.* Using Google Forms for Medical *Survey*: A Technical Note. **International Journal of Clinical and Experimental Physiology**, v. 5, n. 4, p. 216–218, 30 dez. 2019.

OJHA, Radhe Shyam *et al.* Industry 4.0 implementation barriers in automotive manufacturing industry: Interpretive structural modelling approach. **Concurrent Engineering**, v. 32, n. 1–4, p. 34–45, 27 dez. 2024.

OLIVEIRA, Guilherme Vieira de *et al.* Aplicação do Business Intelligence na gestão da cadeia de suprimentos. **Brazilian Journal of Production Engineering**, v. 9, n. 5, p. 60–69, 23 out. 2023.

PALANDI CARDOSO, Ronald *et al.* SUSTAINABLE QUALITY MANAGEMENT: UNFOLDINGS, TRENDS AND PERSPECTIVES FROM THE TRIPLE BOTTOM LINE. **Proceedings on Engineering Sciences**, v. 4, n. 3, p. 359–370, 29 jul. 2022.

PEFFERS, Ken *et al.* A Design Science Research Methodology for Information Systems Research. **Journal of Management Information Systems**, v. 24, n. 3, p. 45–77, 8 dez. 2007.

PILLAI, Vinayak. Data Analytics and Engineering in Automobile Data Systems. **Journal of Science & Technology**, 2023.

PRODANOV, Cleber Cristiano; FREITAS, Ernani Cesar de. **Metodologia do Trabalho Científico: Métodos e Técnicas da Pesquisa e do Trabalho Acadêmico**. 2. ed. Novo Hamburgo: Feevale, 2013.

RIFKIN, Jeremy. **A Terceira Revolução Industrial**. 1. ed. M.Books, 2000.

ROSSI, Rogerio; HIRAMA, Kechi. Characterizing *Big Data* Management. **Cornell University**, 15 jan. 2022.

SANTOS, Maribel Y. *et al.* Advancing Logistics 4.0 with the Implementation of a *Big Data* Warehouse: A Demonstration Case for the Automotive Industry. **Electronics**, v. 10, n. 18, p. 2221, 10 set. 2021.

SCAGLIONE, Thais *et al.* Estado da Arte sobre o uso de *Big Data* no Design: Perspectiva de

Sistemas Produtos + Serviços Sustentáveis. **DAT Journal**, v. 6, n. 1, p. 229–244, 31 dez. 2021.

SCHWAB, Klaus. **A Quarta Revolução Industrial**. 1. ed. Edipro, 2018.

SETIYANTO, Sigit; SETIAWAN, Ismail. Data Science With Excel. **International Journal of Computer and Information System (IJCIS)**, v. 3, n. 3, p. 104–110, 11 ago. 2022.

SHA, Xin Wei; CAROTTI-SHA, Gabriele. *Big Data*. **AI & SOCIETY**, v. 38, n. 6, p. 2705–2708, 29 dez. 2023.

SHARDA, Ramesh; DELEN, Dursun; TURBAN, Efraim. **Business Intelligence, Analytics, And Data Science: A Managerial Perspective**. 4. ed. Pearson, 2017.

TAYLOR, Frederick Winslow. **The Principles of Scientific Management**. 1. ed. Dover Publications, 1997.

VIANNA, Mauricio José; VIANNA, Ysmar; ADLER, Isabel Krumholz. **Design Thinking: Inovação em negócios**. 1. ed. Rio de Janeiro: MJV Press, 2012.

WANG, Junliang *et al.* *Big Data* analytics for intelligent manufacturing systems: A review. **Journal of Manufacturing Systems**, v. 62, p. 738–752, jan. 2022.

WOOD, Gregory; TURBAND, Efraim; POLLARD, Carol. **Information Technology for Management: On-Demand Strategies for Performance, Growth and Sustainability**. 11. ed. John Wiley & Sons, Inc, 2018.

WU, Caesar; BUYYA, Rajkumar; RAMAMOHANARAO, Kotagiri. *Big Data* Analytics = Machine Learning + Cloud Computing. **Cornell University**, 12 jan. 2016.

ZATTAR, Izabel Cristina *et al.* Aplicação de software para automatizar a visibilidade de dados em uma indústria automotiva por meio do Design Thinking. **Brazilian Journal of Production Engineering**, v. 9, n. 3, p. 77–91, 28 jul. 2023.

APÊNDICE A – RESULTADO DA PESQUISA BIBLIOGRÁFICA

Título do Artigo	Autor e ano	Revista	O que foi feito no trabalho	Resultados	Dificuldades no Gerenciamento
<i>Big Data analytics for intelligent manufacturing systems: A review</i>	(Wang <i>et al.</i> , 2022)	<i>Journal of Manufacturing Systems</i>	Revisão abrangente sobre o uso de <i>Big Data Analytics</i> em sistemas de manufatura inteligente, discutindo tecnologias-chave, desafios e oportunidades futuras.	Identificação de tendências e lacunas na aplicação de <i>Big Data</i> na manufatura.	Complexidade na integração de tecnologias e necessidade de infraestrutura adequada.
<i>Big Data Analysis for Supply Chain Management in Vehicle Industry</i>	(Gao, 2022)	<i>BCP Business & Management</i>	Análise do impacto do <i>Big Data</i> na gestão da cadeia de suprimentos na indústria automotiva, destacando melhorias e desafios.	Melhoria na eficiência da cadeia de suprimentos e na tomada de decisões.	Limitações tecnológicas e dificuldades na integração de dados.
Aplicação do <i>Business Intelligence</i> na gestão da cadeia de suprimentos	(Oliveira <i>et al.</i> , 2023),	<i>Brazilian Journal of Production Engineering</i>	Desenvolvimento e implementação de um sistema de BI para reduzir o tempo de execução de atividades na cadeia de suprimentos.	Redução de 54,95% no tempo de execução de atividades não agregadoras de valor.	Necessidade de tratamento e integração de diferentes bases de dados.
<i>Industry 4.0 implementation barriers in automotive manufacturing industry: Interpretive structural modelling approach</i>	(Ojha <i>et al.</i> , 2024)	<i>Concurrent Engineering</i>	Identificação e modelagem dos principais obstáculos à implementação da Indústria 4.0 na indústria automotiva.	Hierarquização de 13 barreiras, destacando riscos de obsolescência e resistência organizacional.	Resistência à mudança e complexidade tecnológica.

(continua)

(continuação)					
<i>Driving Operational Excellence: Business Intelligence in the Car Parts Industry</i>	(Leka; Leka; Baraku, 2025)	Wseas Transactions On Business And Economics	Explora como a implementação de ferramentas de Business Intelligence (BI) pode impulsionar a excelência operacional na indústria de autopeças.	Aumento da precisão na tomada de decisões, redução no tempo de elaboração de relatórios.	Resistência dos funcionários, falta de treinamento adequado e dificuldade na integração de sistemas.
Aplicação de <i>software</i> para automatizar a visibilidade de dados em uma indústria automotiva por meio do <i>Design Thinking</i>	(Zattar <i>et al.</i> , 2023)	<i>Brazilian Journal of Production Engineering</i>	Implementação de <i>software</i> para automatizar a visibilidade de dados em uma indústria automotiva utilizando <i>Design Thinking</i> .	Melhoria na visibilidade e na tomada de decisões baseada em dados.	Dificuldades na adaptação cultural e na capacitação dos funcionários.
<i>Advancing Logistics 4.0 with the Implementation of a Big Data Warehouse: A Demonstration Case for the Automotive Industry</i>	(Santos <i>et al.</i> , 2021)	<i>Electronics</i>	Demonstração da implementação de um <i>data warehouse</i> de <i>Big Data</i> para aprimorar a logística na indústria automotiva.	Melhoria na eficiência logística e na tomada de decisões.	Complexidade na integração de sistemas e na gestão de grandes volumes de dados.
Os desafios para a utilização plena do <i>Business Intelligence</i> : um estudo no setor de consumo cíclico	(Francisco; Costa, 2024)	Revista Liceu On-Line	Estudo de caso sobre os desafios na implementação e uso pleno do BI em uma empresa do setor de consumo cíclico.	Identificação de ganhos em eficiência e produtividade.	Resistência dos colaboradores, má qualidade dos dados e escolha inadequada de ferramentas.

(continua)

(continuação)

Oportunidades de aplicações de <i>Business Intelligence</i> no contexto da indústria 4.0: revisão sistemática da literatura 2015-2020	(Da Costa Neto; Campos, 2023)	Exacta	Revisão sistemática da literatura sobre as aplicações de BI no contexto da Indústria 4.0.	Identificação de 11 tópicos principais e oportunidades de aplicação do BI.	Necessidade de profissionais qualificados.
<i>Data Analytics and Engineering in Automobile Data Systems</i>	(Pillai, 2023)	<i>Journal of Science & Technology</i>	Revisão sobre a aplicação de análise de dados e engenharia em sistemas de dados automotivos.	Melhoria na manutenção preditiva e na eficiência operacional.	Desafios na integração de dados e na implementação de tecnologias emergentes.

Fonte: o autor (2025)

APÊNDICE B – QUESTIONÁRIO

1) A empresa que você trabalha é automotiva e está situada no Sul Fluminense?

- a) Sim
- b) Não

2) Qual é o porte da empresa em que você trabalha?

- c) Pequena (até 99 funcionários)
- d) Média (100 a 499 funcionários)
- e) Grande (500 ou mais funcionários)

3) Qual é o seu cargo na empresa?

- a) Executivo
- b) Analista
- c) Assistente
- d) Programador
- e) Outro: _____

4) Sua empresa utiliza *Big Data*?

- a) Sim, de forma estruturada
- b) Sim, mas de forma limitada
- c) Não utiliza, mas tem planos de implementação
- d) Não utiliza e não pretende implementar

5) Se a sua empresa já utiliza o *Big Data*, quais são as aplicações mais utilizadas?

- () Desenvolvimento de indicadores chaves
- () Previsão de demanda para logística
- () Manutenção preditiva de máquinas
- () Controle de qualidade em tempo real
- () Outro: _____

6) Se a sua empresa já utiliza o *Big Data*, qual é o *software* utilizado?

- a) Excel
- b) Python
- c) SQL
- d) PowerBI
- e) Qlik Sense
- f) Outro: _____

7) Quais são os principais desafios no gerenciamento do *Big Data*, marque até 3 opções?

- () Dificuldade na coleta e armazenamento de dados
- () Falta de integração entre sistemas e plataformas

() Necessidade de investimentos em infraestrutura

() Falta de profissionais capacitados para análise de dados

() Preocupações com segurança e privacidade dos dados

() Falta de hardware para tratar e analisar os dados

() Resistência cultural à mudanças

() Outro: _____

8) Sua empresa possui especialistas dedicados ao gerenciamento do *Big Data*?

- a) Sim, equipe interna especializada
- b) Sim, mas terceirizamos o serviço
- c) Não, mas estamos buscando contratar especialistas
- d) Não e não há planos para isso

9) Em uma escala de 1 a 5, como você avaliaria o impacto do gerenciamento do *Big Data* nos resultados de sua empresa?

- 1 2 3 4 5
- Nenhum impacto Impacto extremamente positivo

10) Quais são as principais vantagens que sua empresa tem e/ou espera ter ao implementar *Big Data*?

- () Aumento da eficiência produtiva
- () Redução de custos operacionais
- () Melhoria na tomada de decisão estratégica
- () Maior controle sobre a qualidade dos produtos
- () Outro: _____

11) Você acredita que o *Big Data* será um fator de competitividade no setor automotivo nos próximos 5 anos?

- a) Sim, totalmente essencial
- b) Sim, mas apenas em algumas áreas
- c) Não, a mudança será gradual e não disruptiva
- d) Não, não terá grande impacto na empresa.