

**FUNDAÇÃO INSTITUTO DE ADMINISTRAÇÃO
FACULDADE FIA DE ADMINISTRAÇÃO E NEGÓCIOS
PROGRAMA DE MESTRADO PROFISSIONAL EM GESTÃO DE NEGÓCIOS**

FLÁVIO AZAN CORRÊA DE TÁVORA

**INTELIGÊNCIA ARTIFICIAL E SISTEMAS DE INFORMAÇÃO GERENCIAL NO
TRANSPORTE RODOVIÁRIO DE CARGAS: UM ESTUDO DE CASO NO SETOR
DE TRANSPORTE BRASILEIRO**

**São Paulo
2026**

FLÁVIO AZAN CORRÊA DE TÁVORA

**INTELIGÊNCIA ARTIFICIAL E SISTEMAS DE INFORMAÇÃO GERENCIAL NO
TRANSPORTE RODOVIÁRIO DE CARGAS: UM ESTUDO DE CASO NO SETOR
DE TRANSPORTE BRASILEIRO**

Dissertação apresentada à Banca Examinadora do Programa de Mestrado Profissional em Gestão de Negócios, mantida pela Fundação Instituto de Administração, como requisito para a obtenção do título de Mestre em Gestão de Negócios, sob a orientação do Prof. Dr. Luís Fernando Ascensão Guedes.

**São Paulo
2026**

Ficha Catalográfica Elaborada pelo Bibliotecário Chefe
Kleber Zornoff Manrubia CRB-8 /7561

Távora, Flávio Azan Corrêa de.

Inteligência Artificial e Sistemas de Informação Gerencial no Transporte Rodoviário de Cargas: um estudo de caso no setor de transporte brasileiro. / Flávio Azan Corrêa de Távora. São Paulo, [s.n.]: 2026.

88 f.: il., tab.

Orientador: Prof. Dr. Luís Fernando Ascensão Guedes.

Área de concentração: Transporte e Logística.

Dissertação (Mestrado Profissional em Gestão de Negócios) – Faculdade FIA de Administração e Negócios, Programa de Pós-Graduação em Stricto Sensu, 2026.

1. Inteligência Artificial. 2. Sistemas de Informação Gerencial.
3. Transporte Rodoviário de Cargas. 4. Modelo de maturidade.
5. Transformação digital. 6. Setor logístico - Adoção de IA - Brasil.
I. Guedes, Luís Fernando Ascensão. II. Mestrado Profissional.
III. Faculdade FIA de Administração e Negócios. IV. Fundação Instituto de Administração.

DEDICATÓRIA

Dedico este trabalho à minha esposa, Michelle, companheira de vida e de jornada, pelo apoio incondicional, pela compreensão nos momentos de ausência e pelo incentivo constante ao longo de todo o percurso acadêmico. Sua presença foi essencial para que este projeto se tornasse realidade.

Aos meus filhos, Victor e Carol, que são minha maior motivação e inspiração diária. Que este trabalho represente não apenas uma conquista acadêmica, mas um exemplo de dedicação, perseverança e compromisso com o aprendizado contínuo.

Estendo também meus agradecimentos aos colaboradores, professores e equipe da Fundação Instituto de Administração (FIA), que, pelo rigor metodológico e pela orientação qualificada, contribuíram para o amadurecimento intelectual e profissional refletido nesta pesquisa.

Aos colegas de mestrado, pela troca de experiências, debates enriquecedores e pelo espírito de colaboração que marcou esta jornada. O aprendizado coletivo tornou o caminho mais leve e significativamente mais produtivo.

Este trabalho é fruto de um esforço conjunto, construído com apoio, confiança e parceria.

AGRADECIMENTOS

Aos professores do Programa de Mestrado Profissional em Gestão de Negócios da Fundação Instituto de Administração (FIA), agradeço pelo rigor intelectual e pela generosidade na transmissão de conhecimentos ao longo de todo o curso.

Cada disciplina, cada debate em sala, cada provocação teórica e cada orientação metodológica contribuíram não apenas para a construção desta pesquisa, mas para uma transformação mais ampla na forma de compreender a gestão, a estratégia e o papel das organizações na sociedade contemporânea.

Os ensinamentos recebidos ultrapassaram os limites técnicos e instrumentais. Essa formação ampliou nossa capacidade crítica, visão sistêmica e compreensão sobre os desafios econômicos, sociais e tecnológicos do nosso tempo.

A dedicação e o compromisso com a formação foram determinantes para o crescimento intelectual que este trabalho reflete.

Registro aqui meu reconhecimento e respeito a todos que, contribuíram para fortalecer nossa trajetória acadêmica e profissional.

“A melhor maneira de prever o futuro é criá-lo.”

Peter Drucker

RESUMO

O Transporte Rodoviário de Cargas (TRC) responde por 65% da movimentação de mercadorias no Brasil, o que confere ao setor papel central na competitividade econômica nacional. Apesar dessa relevância, a integração de Inteligência Artificial (IA) aos Sistemas de Informação Gerencial (SIG) das transportadoras permanece incipiente, com predomínio de *analytics* descritivo e ferramentas de *Business Intelligence* voltadas a análises retrospectivas. Esta pesquisa analisou como a integração de recursos de IA aos SIG impacta a eficiência operacional e a tomada de decisão gerencial em uma empresa de grande porte do TRC. Adotou-se estudo de caso exploratório e qualitativo junto à Empresa Alfa, complementado por entrevista semiestruturada com executivo da Empresa Beta, fornecedora de soluções tecnológicas para o setor logístico. Os resultados indicam que a infraestrutura baseada em TMS e ERP permite a coleta de dados operacionais, porém o uso efetivo de IA concentra-se em automações administrativas, com aplicação limitada de modelos preditivos na operação logística. Os principais benefícios percebidos referem-se à otimização de rotas, ao suporte à tomada de decisão e à redução de custos operacionais. O principal gargalo identificado reside na ausência de bases de dados estruturadas e na carência de competências analíticas. Como produto técnico, propõe-se o Modelo de Maturidade IM-TRC, estruturado em quatro dimensões equiponderadas (Dados, Tecnologia, Processos e Organização), cada uma com peso de 25%. A aplicação do modelo à Empresa Alfa classificou-a predominantemente entre os Níveis 2 e 3, indicando digitalização em estágio intermediário, com solidez na infraestrutura de sistemas mas lacunas na integração de dados e na adoção de modelos preditivos. O IM-TRC permite às empresas do setor avaliar seu estágio de adoção de IA e planejar a evolução tecnológica de forma gradual.

Palavras-chave: Inteligência Artificial; Sistemas de Informação Gerencial; Transporte Rodoviário de Cargas; Modelo de Maturidade; Transformação Digital; Setor logístico - Adoção de IA - Brasil.

ABSTRACT

Road Freight Transportation (RFT) accounts for 65% of goods movement in Brazil, making it central to national economic competitiveness. Despite this importance, the integration of Artificial Intelligence (AI) into the Management Information Systems (MIS) of freight carriers remains incipient, with a prevalence of descriptive analytics and Business Intelligence tools for retrospective analysis. This study analyzed how the integration of AI resources into MIS affects operational efficiency and managerial decision-making in a large road freight carrier. An exploratory, qualitative case study was conducted at Empresa Alfa, complemented by a semi-structured interview with a senior executive from Empresa Beta, a technology provider for the logistics sector. Findings indicate that the TMS- and ERP-based infrastructure supports data collection, but effective AI use remains concentrated on administrative automation, with limited deployment of predictive models in logistics operations. Key perceived benefits include route optimization, decision-support improvements, and operational cost reduction. The main barrier to technological progress lies in the lack of structured databases and analytical competencies. As a technical product, the study proposes the IM-TRC Maturity Model, structured around four equally weighted dimensions (Data, Technology, Processes, and Organization), each accounting for 25%. Application of the model to Empresa Alfa classified it predominantly at Levels 2 and 3, indicating intermediate-stage digitalization with solid systems infrastructure but gaps in data integration and predictive model adoption. The IM-TRC enables freight companies to assess their AI adoption stage and plan incremental technological evolution.

Keywords: Artificial Intelligence; Management Information Systems; Road Freight Transportation; Maturity Model; Digital Transformation; Logistics sector - AI adoption - Brazil.

LISTA DE ILUSTRAÇÕES

Figura 1 - Evolução da logística.....	26
Figura 2 - Fluxo da Cadeia de Suprimentos	27
Figura 3 - Complexidade do cenário da gestão	27
Figura 4 - Evolução e Organização das informações por meio dos Sistemas de Informação..	28
Figura 5 - Benefícios percebidos da IA nos SIG	58

LISTA DE QUADROS E TABELAS

Tabela 1 - Frota de veículos, por tipo e com placa, segundo as Grandes Regiões e Unidades da Federação - dez/2024.....	25
Quadro 1 - Tipos de transporte rodoviário de cargas	30
Quadro 2 - Áreas de aplicação da Inteligência Artificial na logística	34
Quadro 3 - Principais sistemas gerenciais utilizados no segmento logístico	35
Quadro 4 - Relação entre blocos do questionário, base teórica e objetivos	44
Quadro 5 - Triangulação das Evidências sobre Maturidade Digital no TRC.....	58
Quadro 6 - Subdimensões da Dimensão Dados.....	64
Quadro 7 - Subdimensões da Dimensão Tecnologia.....	65
Quadro 8 - Subdimensões da Dimensão Processos	67
Quadro 9 - Subdimensões da Dimensão Organização.....	68
Quadro 10 - Detalhamento das dimensões e níveis do Modelo IM-TRC	70

LISTA DE ABREVIATURAS E SIGLAS

ANTT	Agência Nacional de Transportes Terrestres
AHP	<i>Analytic Hierarchy Process</i>
BI	<i>Business Intelligence</i>
BPM	<i>Business Process Management</i>
CETIC	Centro Regional de Estudos para o Desenvolvimento da Sociedade da Informação
CMM	<i>Capability Maturity Model</i>
CRM	<i>Customer Relationship Management</i>
CSCMP	<i>Council of Supply Chain Management Professionals</i>
CT-e	<i>Conhecimento de Transporte Eletrônico</i>
CTO	<i>Chief Technology Officer</i>
DW	<i>Data Warehouse</i>
EIS	<i>Executive Information System</i>
ERP	<i>Enterprise Resource Planning</i>
FIA	Fundação Instituto de Administração
IA	Inteligência Artificial
IBGE	Instituto Brasileiro de Geografia e Estatística
IBM	<i>International Business Machines</i>
IM-TRC	Índice de Maturidade do Transporte Rodoviário de Cargas
IoT	<i>Internet of Things</i>
KPI	<i>Key Performance Indicator</i>
LGPD	Lei Geral de Proteção de Dados
MIS	<i>Management Information Systems</i>
MIT	<i>Massachusetts Institute of Technology</i>
OMS	<i>Order Management System</i>
PED	Processamento Eletrônico de Dados
PETI	Planejamento Estratégico de Tecnologia da Informação
PIB	Produto Interno Bruto
PLN	Processamento de Linguagem Natural
RBV	<i>Resource-Based View</i>
RH	Recursos Humanos
RNTRC	Registro Nacional de Transportadores Rodoviários de Cargas
ROI	<i>Return on Investment</i>

SAD	Sistema de Apoio à Decisão
SCM	<i>Supply Chain Management</i>
SEFAZ	Secretaria da Fazenda
SIG	Sistemas de Informação Gerencial
TCLE	Termo de Consentimento Livre e Esclarecido
TI	Tecnologia da Informação
TIC	Tecnologias da Informação e Comunicação
TMS	<i>Transportation Management System</i>
TOE	<i>Technology-Organization-Environment</i>
TRC	Transporte Rodoviário de Cargas
UF	Unidade Federativa
VRIO	Valor, Raridade, Imitabilidade e Organização
WMS	<i>Warehouse Management System</i>
YMS	<i>Yard Management System</i>

SUMÁRIO

1 INTRODUÇÃO.....	15
1.1 Problema de investigação.....	18
1.2 Objetivos.....	18
1.3 Delimitação do Escopo	19
1.4 Justificativa	20
1.5 Esquema geral da dissertação.....	22
2 REFERENCIAL TEÓRICO	24
2.1 TRC - Relevância Estratégica e Desafios Operacionais	24
2.2 Sistemas de Informação Gerencial.....	27
2.3 Inteligência Artificial	31
2.4 Inteligência Artificial e o Transporte de Carga Rodoviário.....	33
2.5 Modelos de Maturidade Digital	38
3 MÉTODOS DE PESQUISA.....	41
3.1 Caracterização da Pesquisa	41
3.2 Delineamento das etapas da pesquisa	42
3.3 Procedimentos de Coleta de Dados.....	43
3.4 Estratégia de Análise e Triangulação das Evidências	45
3.5 Procedimentos de Construção do Produto Técnico.....	46
3.6 Limitações do Método de Pesquisa.....	47
4 APRESENTAÇÃO E ANÁLISE DOS RESULTADOS.....	49
4.1 Caracterização dos respondentes	49
4.2 Perspectiva do Fornecedor de Tecnologia.....	50
4.3 Infraestrutura Tecnológica e Maturidade Digital	52
4.4 Discussões dos resultados	56
4.4.1 Maturidade Tecnológica	56
4.4.2 Barreiras e Desafios.....	60
5 PRODUTO TÉCNICO/TECNOLÓGICO	63
5.1 Dimensão 1 — Dados	64
5.2 Dimensão 2 — Tecnologia.....	65
5.3 Dimensão 3 — Processos.....	66
5.4 Dimensão 4 — Organização	67

5.5 Operacionalização do Cálculo do IM-TRC.....	69
5.6 Classificação das empresas no modelo	69
6 CONSIDERAÇÕES FINAIS.....	73
7 REFERÊNCIAS	76
8 APÊNDICE A – QUESTIONÁRIO DE PESQUISA E TCLE	80
9 APÊNDICE B – ROTEIRO DE ENTREVISTA SEMIESTRUTURADA EMPRESA BETA.....	86

1 INTRODUÇÃO

A trajetória da humanidade é marcada pela evolução do raciocínio e pela capacidade de criar eventos e descobertas que impulsionam a sociedade na consolidação e o aperfeiçoamento da qualidade de vida (Harari, 2015), seja no aspecto de segurança, conforto, saúde e melhoria dos processos. Por exemplo, a invenção de ferramentas rudimentares para caça e cultivo permitiu maior domínio sobre a natureza e maior previsibilidade na sobrevivência. Esses movimentos de descontinuidade, onde o modelo antigo é substituído por outro mais eficiente, vão enriquecendo o saber coletivo e criando uma espiral de evolução por meio da memória coletiva e sistematização do conhecimento.

Com o passar dos séculos, sucessivos saltos tecnológicos impulsionaram a aceleração cultural e econômica. A máquina a vapor no século XVIII inaugurou a Revolução Industrial e permitiu a mecanização da produção e a transformação radical da sociedade. Já no século XX, o primeiro computador eletrônico iniciou a era da informação, seguida pela criação em 1971 pela INTEL do microprocessador (Harari, 2015).

Este chip de 4 bits, desenvolvido por uma equipe liderada por Federico Faggin, Ted Hoff e Stan Mazor, representou um avanço revolucionário, integrando toda a lógica de processamento num único chip de silício e pavimentando o caminho para a computação moderna e a era dos microcomputadores e smartphones. O telefone celular, criado na década de 1970 e popularizado nos anos 1990, expandiu a comunicação global preparando o caminho para a atual revolução digital, onde as relações políticas, econômicas e sociais estão caracterizadas pela tecnologia da informação e da comunicação (Castells, 1999).

A cada invenção decisiva, a humanidade deu saltos evolucionários ampliando sua capacidade de armazenar, processar e compartilhar informações. No século XXI, esse processo atinge um novo patamar com a Inteligência Artificial (IA). Assim como a roda multiplicou a mobilidade e a máquina a vapor potencializou a produção, a IA hoje expande a capacidade cognitiva humana, processando volumes massivos de dados e revelando padrões complexos antes invisíveis. Brynjolfsson e McAfee (2017) caracterizam esse momento como uma transição para uma era em que máquinas, plataformas e multidões colaboram, redefinindo a economia e a organização social.

Ao longo da história, a evolução das sociedades humanas esteve diretamente associada ao desenvolvimento de instrumentos que permitiram lidar com novos níveis de complexidade. No âmbito organizacional, esse mesmo movimento se repetiu, o crescimento das empresas e a

ampliação dos mercados exigiram mecanismos de coordenação mais eficientes, surgindo então práticas de contabilidade, sistemas de gestão, telecomunicações, internet e, atualmente, plataformas digitais baseadas em análise de dados e algoritmos inteligentes. Essas ferramentas respondem à crescente complexidade e, ao mesmo tempo, a aceleram, criando novos ciclos de inovação, competitividade e transformação social (Laudon; Laudon, 2020).

A evolução dos Sistemas de Informação Gerencial (SIG) acompanha e provoca mudanças na forma de gerir organizações (Laudon; Laudon, 2020). Nos anos 1950, quando o processamento eletrônico de dados (PED) emergiu, os grandes *mainframes* automatizaram rotinas antes manuais, como folha de pagamento, faturamento e contas a pagar e receber. Eram ambientes caros, centralizados e fechados, a TI operava “no porão”, processando lotes noturnos, enquanto as áreas de negócio aguardavam relatórios impressos dias depois. Ainda assim, apenas substituir planilhas e fichas por rotinas *batch* já reduziu erros e encurtou ciclos administrativos.

Na virada para as décadas de 1970 e 1980, dois vetores mudaram o jogo: Sistemas de Apoio à Decisão (SAD) e a popularização dos PCs (*Personal Computers*). Planilhas eletrônicas, bancos de dados departamentais e os primeiros *Executive Information Systems* (EIS) democratizaram a análise, um gerente de compras passou a simular cenários de demanda (“*what-if*”), comparar fornecedores e recalcular níveis de estoque em minutos. Ao mesmo tempo, multiplicaram-se os sistemas funcionais: financeiro, RH, produção, vendas e manutenção ganhavam soluções próprias, mais próximas do usuário e com relatórios cada vez mais ricos. O preço desse avanço foi a fragmentação, onde cada departamento falava uma “língua de dados” diferente (O’Brien; Marakas, 2013).

Os anos 1990 trouxeram a resposta a essa fragmentação, os sistemas integrados de gestão (ERP). Em vez de ilhas, uma “espinha-dorsal” única conectou processos ponta a ponta do pedido do cliente ao recebimento do caixa, unificando cadastros, padronizando processos e eliminando reconciliações manuais. Ao ERP somaram-se camadas especializadas, como CRM (relacionamento com clientes), SCM (cadeia de suprimentos), TMS (gestão de transporte) e WMS (operações de armazém). Uma indústria que antes conciliava dados de produção, compras e finanças em relatórios separados passou a enxergar, em tempo real, o impacto de uma ruptura de fornecedor no plano mestre de produção, na ocupação do armazém e nas entregas ao cliente (Laudon; Laudon, 2020).

Daí em diante, redes e internet conectaram filiais e parceiros globais; *data warehouses* e BI (*Business Intelligence*) consolidaram informações históricas; *Big Data* e IoT trouxeram telemetria de máquinas, caminhões e operações. A Inteligência Artificial se propõe a adicionar previsão e prescrição: manutenção preditiva de ativos, roteirização inteligente, precificação

dinâmica, detecção de anomalias e assistentes que interagem com ERP, TMS e CRM para sugerir a próxima ação (Turban; Volonino; Wood, 2015).

Na prática, um *e-commerce* integra WMS e TMS para prometer ETA (*Estimated Time of Arrival*) confiável, ajustar rotas conforme trânsito e clima e personalizar ofertas a partir do histórico do cliente. Uma transportadora combina ERP e TMS com dados de sensores para reduzir consumo de combustível e indisponibilidade da frota (Turban; Volonino; Wood, 2015).

O resultado desse percurso é um SIG contemporâneo como plataforma integrada, capaz de dar agilidade decisória, elevar a produtividade ao automatizar tarefas repetitivas e reduzir retrabalho, sustentar a competitividade ao otimizar processos e acelerar inovações, oferecer visão integrada do negócio, da estratégia ao operacional. Os ganhos, contudo, dependem de fundamentos não tecnológicos, como governança de dados, qualidade e integração, desenho de processos de ponta a ponta e capacitação das pessoas. Em resumo, saímos de sistemas funcionais que focavam para dentro de cada departamento, para ambientes integrados que transformam dados dispersos em decisões melhores e mais rápidas (Laudon; Laudon, 2020).

Atualmente, há um intenso debate na sociedade sobre os impactos da Inteligência Artificial nas organizações modernas (Schwab, 2016). Uma das principais preocupações gira em torno da possível destruição de postos de trabalho, o que poderia levar à criação de uma renda universal. Assim, a riqueza tenderia a se concentrar em grandes corporações, enquanto muitas pessoas, incapazes de se inserir em empregos formais, dependeriam de um valor mínimo pago pelo Estado para garantir sua sobrevivência. Em paralelo, multiplicam-se teorias de caráter apocalíptico, que surgem quase semanalmente e na maioria das vezes, essas visões resultam mais do desconhecimento ou de uma miopia analítica do que de uma compreensão histórica e concreta do momento que vivemos.

Governos têm intensificado esforços para estabelecer diretrizes e medidas que promovam a inovação, enquanto garantem os direitos individuais e coletivos, buscando equilibrar o avanço tecnológico com a proteção de dados. No Brasil, o Projeto de Lei n. 2238/2023 (Senado Federal, Brasil, 2023), aprovado no Senado, propõe a criação de um ambiente ético e regulatório sobre o tema, sendo acompanhado de perto por diversos setores da sociedade civil, academia e empresas.

As expectativas futuras apontam para uma situação em que a IA auxilia e apoia soluções, acelera descobertas científicas e médicas, personaliza experiências e redefine a forma como humanos e máquinas constroem o conhecimento. Trata-se, portanto, de uma nova revolução cognitiva, na qual a inteligência artificial é a mais recente ferramenta na longa trajetória de invenções que moldaram a humanidade (Brynjolfsson; McAfee, 2017).

1.1 Problema de investigação

A digitalização das cadeias de suprimentos tem sido apontada como vetor de transformação na gestão logística. Hennelly et al. (2020) observam que, apesar da difusão de tecnologias como IoT, big data e inteligência artificial, ainda há lacunas quanto à sua aplicação efetiva no dia a dia das operações. A literatura enfatiza o potencial de mudança dessas ferramentas, porém oferece poucas evidências empíricas sobre como elas de fato se integram aos processos operacionais das cadeias logísticas.

No transporte rodoviário de cargas, modal que concentra 65% da movimentação de mercadorias no Brasil (ANTT, 2024), essa lacuna se torna particularmente relevante. O setor lida com sinistralidade elevada, custos voláteis de combustível e uma estrutura empresarial fragmentada. A ausência de dados integrados em tempo real limita a visibilidade ponta a ponta da cadeia, comprometendo planejamento e controle. Por isso, a distância entre a promessa tecnológica e a viabilidade operacional reflete a realidade de transportadoras que ainda dependem de sistemas gerenciais fragmentados e processos pouco digitalizados.

Posto isso, a presente pesquisa busca responder à seguinte pergunta:

Como a integração de recursos de inteligência artificial aos Sistemas de Informação Gerencial é percebida, em termos de impactos na eficiência operacional e na tomada de decisão, em uma empresa de grande porte do Transporte Rodoviário de Cargas no Brasil?

1.2 Objetivos

A presente pesquisa se propõe a investigar como a Inteligência Artificial, integrada aos Sistemas de Informação Gerencial, pode contribuir para a eficiência operacional e a qualidade da tomada de decisão em uma empresa de grande porte do Transporte Rodoviário de Cargas. Para tanto, foram definidos o objetivo geral e os objetivos específicos a seguir.

Objetivo geral

Analisar como a integração de recursos de inteligência artificial aos Sistemas de Informação Gerencial impacta a eficiência operacional e na tomada de decisão gerencial em uma empresa de grande porte do setor de Transporte Rodoviário de Cargas no Brasil.

Objetivos específicos

Para alcançar o objetivo geral, foram estabelecidos os seguintes objetivos específicos:

- 1) Caracterizar a infraestrutura tecnológica e o estágio de maturidade digital da empresa estudada, com ênfase nos Sistemas de Informação Gerencial utilizados na operação logística.
- 2) Identificar, a partir da percepção de atores do ecossistema logístico (operador e fornecedor de tecnologia), os benefícios percebidos e as barreiras para a adoção de inteligência artificial integrada aos SIG no contexto do TRC.
- 3) Propor um modelo de maturidade de inteligência artificial aplicável a empresas de grande porte do TRC (IM-TRC), com base nas evidências empíricas e no referencial teórico.

1.3 Delimitação do Escopo

O estudo focaliza a integração de recursos de inteligência artificial aos Sistemas de Informação Gerencial em empresas do setor de Transporte Rodoviário de Cargas no Brasil. Para conferir profundidade à análise, optou-se por um estudo de caso com duas organizações selecionadas por critérios de porte, relevância setorial e engajamento com tecnologias digitais (Yin, 2015).

O escopo geográfico restringe-se ao território brasileiro, considerando as particularidades regulatórias, operacionais e de infraestrutura do TRC nacional. A unidade de análise, conforme a estratégia de caso único proposta por Yin (2015), é uma empresa de grande porte do setor, classificada segundo o critério do IBGE para atividades de serviços, que considera como grande empresa aquela com 100 ou mais pessoas ocupadas.

A escolha dessa organização justifica-se por três razões: atuação nacional com escala logística relevante, infraestrutura tecnológica consolidada (ERP, TMS, BI e telemetria) e iniciativas em curso de adoção de IA, o que permite observar o fenômeno em estágio intermediário de maturidade. Os procedimentos metodológicos detalhados são apresentados no Capítulo 3. Essa delimitação é coerente com a recomendação de Yin (2015) de que estudos de caso devem definir fronteiras claras para o fenômeno investigado, evitando generalizações indevidas.

1.4 Justificativa

A justificativa deste estudo fundamenta-se na relevância estratégica do setor de Transporte Rodoviário de Cargas (TRC), responsável pela maior parcela da movimentação de mercadorias no Brasil, o que o torna um elemento central para a competitividade econômica nacional. Nesse contexto, avanços tecnológicos aplicados ao setor possuem potencial significativo de impacto sobre a eficiência operacional, a redução de custos logísticos e a qualidade da tomada de decisão gerencial, fatores críticos em um ambiente caracterizado por elevada pressão por produtividade e margens cada vez mais reduzidas.

Paralelamente, a evolução da Indústria 4.0 tem impulsionado a incorporação de tecnologias como inteligência artificial (IA), Internet das Coisas (IoT), big data e sistemas ciberfísicos, promovendo uma transformação estrutural nos processos logísticos e ampliando a capacidade analítica das organizações (Marinagi et al., 2023). Essa transformação redefine a forma como as empresas coletam, processam e utilizam dados, deslocando o foco de uma gestão baseada em registros históricos para uma abordagem orientada por dados em tempo real e suportada por modelos preditivos e prescritivos.

No contexto logístico, tais avanços possibilitam melhorias significativas na otimização de rotas, previsão de demanda, gestão de frota, controle de custos e mitigação de riscos operacionais. Entretanto, embora essas tecnologias estejam cada vez mais presentes nas cadeias de suprimentos, sua aplicação no setor de transporte rodoviário de cargas ainda ocorre de forma heterogênea e, em muitos casos, limitada a iniciativas pontuais, sem integração plena aos sistemas estruturantes da organização.

Nesse sentido, os Sistemas de Informação Gerencial (SIG) assumem papel central, na medida em que constituem a base para a coleta, integração e análise das informações organizacionais. Conforme destacam Laudon e Laudon (2020), os SIG são fundamentais para a eficiência organizacional, pois permitem transformar dados em informações úteis para o processo decisório. No entanto, em muitos casos, esses sistemas ainda operam predominantemente com análises descritivas, apresentando limitações quanto à capacidade de antecipação de cenários e geração de insights estratégicos.

A incorporação de recursos de inteligência artificial aos SIG representa, portanto, um avanço significativo, ao possibilitar a evolução para níveis mais sofisticados de análise, incluindo modelos preditivos e prescritivos. De acordo com Thomas Davenport e Jeanne Harris (2017), organizações orientadas por dados tendem a apresentar melhor desempenho, justamente

por sua capacidade de transformar grandes volumes de dados em decisões mais rápidas e assertivas. Dessa forma, a integração entre IA e SIG não apenas amplia a capacidade analítica das empresas, como também se configura como um elemento-chave para a geração de vantagem competitiva.

Apesar da crescente relevância do tema, observa-se uma lacuna significativa na literatura acadêmica. Estudos como os de Pereira e Simonetto (2018) e Richey et al. (2023) indicam que a maior parte das pesquisas sobre inteligência artificial na logística concentra-se em ambientes industriais ou em operações de armazenagem e distribuição, havendo escassez de investigações voltadas especificamente ao setor de transporte rodoviário de cargas, especialmente sob a perspectiva da integração entre IA e Sistemas de Informação Gerencial. Essa ausência de estudos empíricos aplicados ao contexto brasileiro limita a compreensão dos desafios, benefícios e condições necessárias para a adoção efetiva dessas tecnologias no setor.

Adicionalmente, o contexto brasileiro apresenta particularidades relevantes, como a fragmentação do setor, a heterogeneidade no nível de maturidade digital das empresas e limitações estruturais relacionadas à infraestrutura tecnológica e à governança de dados. Tais fatores contribuem para a existência de barreiras à adoção de inteligência artificial, reforçando a necessidade de estudos que investiguem não apenas o potencial das tecnologias, mas também as condições organizacionais necessárias para sua implementação bem-sucedida.

Do ponto de vista estratégico, a adoção dessas tecnologias está diretamente relacionada à construção de vantagem competitiva. Para Michael Porter (1996), a estratégia consiste na realização de escolhas que permitam à organização diferenciar-se de seus concorrentes de forma sustentável, sendo a tecnologia um dos principais vetores dessa diferenciação. Complementarmente, Barney (1991) argumenta que recursos valiosos, raros, difíceis de imitar e organizacionalmente exploráveis, como dados estruturados e capacidades analíticas, constituem a base para a geração de vantagem competitiva sustentável.

Nesse cenário, a capacidade de integrar dados provenientes de diferentes sistemas, transformando-os em informações relevantes e acionáveis, torna-se um diferencial competitivo crítico. A inteligência artificial, ao potencializar essa capacidade, posiciona-se como um elemento central na transformação dos Sistemas de Informação Gerencial em plataformas mais inteligentes, adaptativas e orientadas à decisão.

Diante desse contexto, evidencia-se a necessidade de instrumentos que permitam avaliar o nível de maturidade das organizações quanto à adoção de inteligência artificial no âmbito dos seus sistemas de informação. Nesse sentido, este estudo sugere desenvolvimento de um modelo de maturidade específico para o setor de transporte rodoviário de cargas, o IM-TRC, estruturado

a partir de dimensões como dados, tecnologia, processos e organização, que se propõe a refletir os principais pilares da transformação digital,

No plano prático, a pesquisa contribui ao mapear o cenário tecnológico e o grau de digitalização de uma empresa de grande porte do setor, identificar benefícios percebidos e barreiras à adoção de IA, e oferecer um instrumento gerencial que pode apoiar gestores na priorização de investimentos e na definição de estratégias de transformação digital. No plano teórico, o estudo contribui para o avanço da literatura ao explorar um campo ainda pouco investigado, analisando conceitos de inteligência artificial, sistemas de informação gerencial e logística no contexto específico do transporte rodoviário de cargas no Brasil.

Assim, a presente pesquisa justifica-se tanto pela sua relevância acadêmica, ao preencher uma lacuna na literatura, quanto a percepção do uso da IA para a tomada de decisão em uma empresa de grande porte do TRC, em um setor essencial para a economia brasileira.

1.5 Esquema geral da dissertação

A presente dissertação está estruturada em seis capítulos, organizados para conduzir o leitor desde a contextualização do problema de pesquisa até a apresentação dos resultados e a proposição do produto técnico. O Capítulo 1 apresenta a introdução do estudo, abordando o contexto em que a pesquisa está inserida, a relevância do tema investigado e a problemática que motivou o desenvolvimento do trabalho. Nesse capítulo são apresentados a pergunta de pesquisa, os objetivos geral e específicos, a delimitação do escopo, a justificativa e o esquema geral da dissertação.

O Capítulo 2 apresenta o referencial teórico que fundamenta a pesquisa, estruturado em cinco seções articuladas em um fluxo argumentativo: primeiro, contextualiza o Transporte Rodoviário de Cargas e seus desafios operacionais; em seguida, examina os Sistemas de Informação Gerencial e suas limitações analíticas; na terceira seção, discute o potencial da Inteligência Artificial como evolução tecnológica; a quarta seção analisa a convergência entre IA e TRC como fronteira de inovação; e, por fim, a quinta seção apresenta os modelos de maturidade digital que fundamentam a proposição do modelo IM-TRC.

O Capítulo 3 descreve os procedimentos metodológicos adotados, incluindo a caracterização do estudo como pesquisa exploratória qualitativa com delineamento de estudo de caso, os instrumentos de coleta de dados (questionário estruturado e entrevista semiestruturada), a estratégia de triangulação das evidências e as limitações do método.

O Capítulo 4 apresenta e discute os resultados da pesquisa de campo, organizados segundo os objetivos específicos: caracterização da infraestrutura tecnológica e maturidade digital da empresa estudada (OE1), identificação dos benefícios percebidos e das barreiras para adoção de IA (OE2), e análise com base no referencial teórico.

O Capítulo 5 apresenta o Produto Técnico/Tecnológico resultante da pesquisa, o Modelo de Maturidade de IA para o TRC (IM-TRC), incluindo suas dimensões, níveis, critérios e exemplo de aplicação ao caso estudado (OE3). O Capítulo 6 traz as considerações finais e destaca as contribuições do estudo, as limitações da pesquisa e sugestões para estudos futuros.

2 REFERENCIAL TEÓRICO

Neste capítulo, são apresentados os conceitos que fundamentam a presente pesquisa. A estrutura segue um fluxo argumentativo progressivo pois parte-se do contexto macro do Transporte Rodoviário de Cargas e de seus desafios operacionais (seção 2.1); em seguida, examinam-se os Sistemas de Informação Gerencial que suportam a gestão logística (seção 2.2); a terceira seção introduz a Inteligência Artificial como resposta tecnológica às limitações analíticas dos SIG (seção 2.3).

A quarta seção discute a convergência entre IA e TRC (seção 2.4); e, por fim, apresentam-se os modelos de maturidade digital que fundamentam a proposição do modelo IM-TRC (seção 2.5). Conforme destacam Webster e Watson (2002), a revisão de literatura deve organizar-se em torno dos conceitos centrais da pesquisa, de modo a identificar as lacunas que justificam a investigação.

2.1 TRC - Relevância Estratégica e Desafios Operacionais

O transporte é um pilar da logística, pois garante o deslocamento físico de matérias-primas, insumos e produtos acabados entre os diferentes elos da cadeia de suprimentos. Mais do que movimentar mercadorias, ele conecta mercados, possibilita a expansão geográfica das empresas e influencia diretamente o nível de serviço ao cliente. Segundo Ballou (2006), essa atividade é responsável por grande parte dos custos logísticos totais, podendo representar mais de 60% em determinados setores, o que demonstra seu peso na competitividade empresarial (Ballou, 2006).

A eficiência operacional, no contexto do Transporte Rodoviário de Cargas (TRC), pode ser compreendida como a capacidade da organização de maximizar a utilização de seus recursos tais como frota, combustível, tempo e mão de obra ao menor custo possível, mantendo níveis adequados de serviço (BALLOU, 2006; DAVENPORT; HARRIS, 2017).

No âmbito dos Sistemas de Informação Gerencial (SIG) e da Inteligência Artificial, a eficiência operacional está diretamente associada à capacidade de transformar dados em decisões mais precisas, reduzindo desperdícios, melhorando o planejamento logístico e aumentando a previsibilidade das operações (LAUDON; LAUDON, 2020).

No Brasil, o Transporte Rodoviário de Cargas (TRC) é a espinha dorsal da economia (Novaes, 2007). Com uma frota que ultrapassa 4 milhões de caminhões (Tabela 1) e uma malha

viária de mais de 1,7 milhão de quilômetros, este modal é responsável por 65% de toda a movimentação de mercadorias, e conecta as zonas de produção aos centros de consumo e impulsionar setores vitais como o agronegócio e a indústria. Sua relevância é tamanha que o desempenho do setor impacta diretamente o Produto Interno Bruto (PIB) nacional.

Tabela 1 - Frota de veículos, por tipo e com placa, segundo as Grandes Regiões e Unidades da Federação - dez/2024

Região/UF	Caminhão	Caminhão Trator
Brasil	3.153.857	968.421
Norte	163.593	57.889
Nordeste	409.831	104.984
Sudeste	1.378.972	398.231
Sul	784.531	298.745
Centro-Oeste	416.930	108.572

Fonte: Registro Nacional de Veículos Automotores – RENAVAL 2024. Brasília, 2024.

Nesse sentido, Caixeta-Filho (2001) define o termo “logística” como um processo de controle, planejamento e implementação eficaz, além da armazenagem e do fluxo das matérias-primas, insumos e produtos acabados desde a fase inicial de produção até o consumidor final, atendendo ao cliente satisfatoriamente (Caixeta-Filho, 2001).


A logística é uma área adaptativa que historicamente se modificou com o objetivo de acompanhar mudanças sociais, industriais e tecnológicas, conforme ilustra a Figura 1. A logística em sua evolução histórica foi marcada por quatro fases, sendo a atual e quarta fase conceituada como “Logística 4.0” que surgiu como consequência da quarta revolução industrial (Indústria 4.0) e dos desenvolvimentos tecnológicos do século XXI, como as novas tecnologias para solução de problemas, e a utilização da Internet em sistemas de negócios (Radivojević; Milosavljević, 2019).

Logística é a parte do processo da cadeia de suprimentos que planeja, estabelece e controla os fluxos e estoques de matéria-prima, produtos intermediários e acabados, serviços e informação, de forma eficiente e eficaz, desde a origem até o consumidor final, o desempenho logístico depende da capacidade para controlar e explorar os fluxos de informação associados à movimentação de materiais e produto (CSCMP, 2013).

A logística integrada, ao buscar otimizar os fluxos ao longo da cadeia de suprimentos, exige tanto a integração quanto a coordenação eficiente de informações entre os agentes

envolvidos. Nesse contexto, os Sistemas de Informação Gerencial desempenham papel central ao viabilizar a troca de dados entre embarcadores, transportadores e destinatários, possibilitando maior visibilidade e controle sobre as operações (Bowersox; Closs; Cooper, 2014). A eficiência dessa integração depende da qualidade dos dados compartilhados e da interoperabilidade entre as plataformas utilizadas pelos diferentes elos da cadeia (Laudon; Laudon, 2020).


Figura 1 - Evolução da logístitca



Fonte: Radivojević; Milosavljević, 2019.

Esse processo, em geral, é liderado por uma ou mais organizações que assumem o papel de coordenadoras, definindo padrões operacionais que os demais participantes seguem. Assim, integração e coordenação não se limitam a aspectos técnicos ou informacionais, mas envolvem a construção de relações de confiança e o fortalecimento de parcerias estratégicas, fundamentais para elevar a eficiência logística e gerar vantagem competitiva sustentável no mercado (Christopher, 2016), como sintetiza a Figura 2.

Figura 2 - Fluxo da Cadeia de Suprimentos




Fonte: elaborado pelo autor.

2.2 Sistemas de Informação Gerencial

Diante da complexidade operacional e da intensidade informacional do TRC, descritas na seção anterior, os Sistemas de Informação Gerencial (SIG) assumem o seu papel. Eles possibilitam a coleta, o processamento e a análise de grandes volumes de dados, transformando-os em informações relevantes para a tomada de decisão. Dessa forma, os SIG tornam-se instrumentos indispensáveis para assegurar a integração e a coordenação eficazes na logística contemporânea (Laudon; Laudon, 2020). A Figura 3 sintetiza a complexidade desse cenário.

Figura 3 - Complexidade do cenário da gestão



Fonte: elaborado pelo autor.

Os Sistemas de Informação Gerencial, são um conjunto de ferramentas (*software* de gestão) para empresas de diversos portes, que reúne dados e informações do negócio. Desse modo, permite que os usuários, em uma só plataforma, realizem os controles operacionais, financeiros e comerciais, acompanhando, revisando, melhorando e implementando valores ao processo (O'Brien; Marakas, 2013). A Figura 4 ilustra essa evolução organizacional dos sistemas de informação.

Além de participarem dos processos internos das organizações, os Sistemas de Informação Gerencial (SIG) precisam estar conectados ao ambiente externo para viabilizar a troca de informações com parceiros, clientes e órgãos reguladores. Laudon e Laudon (2020) argumentam que os SIG contemporâneos devem integrar fontes internas e externas de dados, dado que a competitividade organizacional depende cada vez mais da capacidade de processar informações em tempo real e de forma interoperável.



Fonte: elaborado pelo autor.

A capacidade de captura, processamento e análise ágil desses múltiplos fluxos de dados torna-se fundamental para sustentar a tomada de decisão em tempo real. As organizações que se destacam e conquistam diferenciais competitivos no mercado são justamente aquelas que conseguem transformar dados complexos e dispersos em insights, antecipando riscos e explorando oportunidades com maior rapidez e eficiente que seus concorrentes (Laudon; Laudon, 2020).

No contexto da logística integrada, o transporte não atua isoladamente, mas sim como elo entre atividades como gestão de estoques, armazenagem, processamento de pedidos e distribuição física. Sua participação envolve a definição de rotas otimizadas, a seleção adequada de modais, além da utilização de tecnologias de rastreamento e monitoramento em tempo real. Essa função garante o equilíbrio entre custo e nível de serviço. Isso permite que as empresas alinhem eficiência operacional à necessidade de atendimento ágil e flexível dos mercados.

Portanto, o transporte é tanto um componente operacional quanto um diferencial competitivo, uma vez que sua eficácia pode determinar o sucesso ou o fracasso da cadeia de suprimentos como um todo (Bowersox et al., 2014).

Apesar da importância dos Sistemas de Informação Gerencial no suporte às atividades organizacionais, os modelos tradicionais de SIG apresentam limitações quando confrontados com a complexidade e o volume de dados gerados pelas operações logísticas contemporâneas. Davenport (2018) argumenta que a transição de sistemas descritivos para sistemas com capacidade preditiva e prescritiva é condição necessária para que as organizações capturem valor a partir de seus dados. Nesse cenário, a incorporação de técnicas de inteligência artificial aos SIG emerge como resposta às limitações dos modelos convencionais.

Entretanto, no contexto atual de transformação digital, marcado pela intensificação da competitividade, pela digitalização dos processos logísticos e pela geração massiva de dados provenientes de diferentes fontes, como sensores, sistemas operacionais, plataformas digitais e dispositivos conectados, as organizações passaram a demandar capacidades analíticas mais avançadas. A simples consolidação de dados históricos já não é suficiente para sustentar processos decisórios cada vez mais dinâmicos e complexos. Torna-se necessário desenvolver mecanismos capazes de identificar padrões, antecipar eventos futuros e recomendar ações estratégicas automaticamente (Schwab, 2016).

Surgem, assim, novas abordagens analíticas baseadas em técnicas de ciência de dados, aprendizado de máquina e inteligência artificial, capazes de ampliar o potencial dos sistemas de informação gerencial. Essas tecnologias permitem evoluir do modelo tradicional de análise descritiva para abordagens preditivas e prescritivas, nas quais os sistemas passam a registrar e organizar informações e, adicionalmente, a gerar previsões, simular cenários e apoiar decisões estratégicas com maior proativa (Davenport; Harris, 2007).

De acordo com Davenport (2017), a efetividade da utilização de dados nas organizações não depende apenas de sua disponibilidade, mas da capacidade de gerenciá-los de forma estruturada, garantindo qualidade, consistência e confiabilidade. Nesse sentido, a governança de dados pode ser compreendida como o conjunto de políticas, processos, padrões e responsabilidades que asseguram o uso adequado dos dados ao longo de seu ciclo de vida, desde a sua geração até sua utilização na tomada de decisão.

No setor de transporte rodoviário de cargas, essa temática assume relevância ainda maior em função da fragmentação do setor e da heterogeneidade tecnológica entre as empresas. Muitas organizações operam com sistemas legados, bases de dados descentralizadas e baixa integração entre plataformas, o que dificulta a consolidação de informações e compromete a

geração de insights confiáveis. Conforme argumentam Laudon e Laudon (2020), a ausência de integração entre sistemas de informação constitui uma das principais barreiras à eficiência organizacional, uma vez que limita a capacidade de análise e a qualidade das decisões gerenciais.

Adicionalmente, a governança de dados está diretamente relacionada à capacidade de adoção de tecnologias mais avançadas, como a inteligência artificial. Modelos de IA dependem de dados estruturados, consistentes e historicamente confiáveis para gerar resultados acurados. Nesse sentido, a ausência de práticas adequadas de governança pode comprometer não apenas a qualidade das análises, mas também a viabilidade de implementação dessas tecnologias. Para Davenport e Harris (2017), organizações que não estabelecem uma base sólida de dados enfrentam dificuldades significativas para evoluir em sua maturidade analítica.

Assim, a evolução dos sistemas de informação gerencial passa a incorporar novas camadas de inteligência analítica, e os SIG passam a ser plataformas capazes de integrar dados operacionais, modelos analíticos e algoritmos de inteligência artificial. Esse movimento é um passo importante para que as organizações consigam lidar com a crescente complexidade dos ambientes competitivos e extrair valor dos dados disponíveis. A inteligência artificial surge como componente essencial na evolução dos sistemas de informação gerencial e ampliar sua capacidade de suporte à tomada de decisão e à gestão eficiente das operações organizacionais (Laudon; Laudon, 2020). O Quadro 1 apresenta os principais tipos de transporte rodoviário de cargas e suas atividades.

Quadro 1 - Tipos de transporte rodoviário de cargas

Tipos de transporte	Atividade
Cargas Gerais	Empresas que transportam uma variedade de produtos não especializados, como bens de consumo, produtos alimentícios e insumos em geral.
Cargas Fracionadas	Empresas que organizam o transporte de pequenas quantidades de mercadorias que não preenchem um caminhão inteiro, unindo diferentes cargas em um mesmo veículo para otimizar custos e tempo.
Cargas Refrigeradas	Empresas especializadas no transporte de produtos que exigem controle de temperatura, como alimentos, medicamentos e produtos farmacêuticos, utilizando veículos com baús ou tanques refrigerados.
Cargas Perigosas	Transportadoras que, com veículos e motoristas especializados, lidam com o transporte de produtos químicos ou outras substâncias que representam risco à segurança e ao meio ambiente.
Cargas Especiais	Empresas que transportam mercadorias de grande porte, como máquinas industriais e equipamentos pesados, que necessitam de veículos como pranchas e veículos adaptados.
Entregas Expressas e Especiais	Empresas focadas na rapidez e agilidade, especialmente para o e-commerce, com serviços de entrega rápida de produtos de alto valor.
Logística e Distribuição	Empresas que atuam em toda a cadeia logística, incluindo o armazenamento e a distribuição de produtos de diversos setores.

Fonte: elaborado pelo autor.

2.3 Inteligência Artificial

A Inteligência Artificial (IA) pode ser compreendida como o conjunto de tecnologias, algoritmos e modelos computacionais capazes de processar grandes volumes de dados, identificar padrões, gerar previsões e apoiar a tomada de decisão organizacional de forma automatizada ou semi-automatizada. No ambiente dos Sistemas de Informação Gerencial (SIG), a IA atua como um mecanismo de ampliação da capacidade analítica das organizações, permitindo transformar dados operacionais em informações estratégicas relevantes para o desempenho empresarial.

No setor de Transporte Rodoviário de Cargas (TRC), objeto deste estudo, a IA manifesta-se principalmente por meio da integração com sistemas corporativos como ERP, TMS, WMS, plataformas de telemetria, Business Intelligence (BI) e ferramentas analíticas avançadas. Sua aplicação envolve desde automações operacionais simples até modelos preditivos capazes de apoiar decisões relacionadas à roteirização, gestão de frotas, manutenção preditiva, análise de risco, redução de custos logísticos e otimização da eficiência operacional.

Essa visão está alinhada à literatura de Sistemas de Informação, que compreende a IA como uma evolução das capacidades analíticas organizacionais. Para Kenneth Laudon e Jane Laudon (2020), os sistemas inteligentes ampliam a capacidade das organizações de coletar, processar e interpretar informações para suportar decisões estratégicas. Já Thomas Davenport e Harris (2017) destacam que organizações orientadas por dados utilizam recursos analíticos e inteligência artificial para transformar informação em vantagem competitiva.

Portanto, no contexto deste trabalho, a Inteligência Artificial é definida como a capacidade tecnológica integrada aos Sistemas de Informação Gerencial de analisar dados, aprender padrões e apoiar decisões operacionais, táticas e estratégicas, contribuindo para o aumento da eficiência, da competitividade e da maturidade digital das empresas de Transporte Rodoviário de Cargas.

As limitações dos SIG tradicionais, apontam para a necessidade de novas camadas de inteligência analítica. É neste contexto que a aplicação da Inteligência Artificial (IA) se apresenta como solução tecnológica de alto impacto, com potencial para transformar radicalmente a gestão logística. A IA oferece um conjunto de ferramentas capazes de analisar um volume massivo de dados em tempo real para otimizar operações de ponta a ponta, como otimização de rotas, manutenção preditiva e gestão de frotas (Russell; Norvig, 2021).

A transformação digital no setor de transportes demanda uma revisão dos pressupostos

tradicionais da Gestão de Processos de Negócio (BPM). Syed et al. (2020) identificam tensões nos três princípios clássicos de BPM, propondo novas lógicas adequadas ao contexto dinâmico da digitalização como os processos de contato leve, facilmente adaptáveis em ambientes de mudança acelerada; infraestrutura flexível, que permite rápida reconfiguração segundo demandas recentes; e atores conscientes, capazes de agir adequadamente mesmo quando processos formais estão ausentes (Syed et al., 2020).

De acordo com Dijkman, Lammers e De Jong (2015), a maturidade em Gestão de Processos de Negócio (BPM) exerce impacto direto no desempenho organizacional, sendo fortalecida por características como a inovação. a incorporação de tecnologias emergentes, como a Inteligência Artificial, pode acelerar a evolução da maturidade dos sistemas de gestão empresarial, o que favorece tanto a eficiência operacional quanto a capacidade inovativa.

De acordo também com McKinsey; Company (2019), empresas que implementam Inteligência Artificial em sua cadeia de suprimentos podem alcançar uma redução de até 15% nos custos logísticos. O mercado de IA está crescendo com uma taxa anual composta estimada em 37,3%, entre 2023 e 2030, o que sinaliza a crescente importância dessa tecnologia em todos os setores (Grand View Research, 2023), sendo que mais de 95% dos executivos concordam que a IA Gerativa vai transformar significativamente onde e como a IA será usada.

O aumento exponencial na geração global de dados é um dos principais impulsionadores do crescimento do mercado de IA De acordo com estimativas do setor, a quantidade de dados gerados e copiados em 2020 foi de cerca de 64,2 Zettabytes, com previsões indicando que aumentará para 175 Zettabytes até 2025. Esse enorme volume de dados exige ferramentas e algoritmos de análise poderosos, impulsionados por Inteligência Artificial. Grandes empresas como Google e Microsoft reconheceram essa tendência e estão investindo extensivamente em tecnologia de IA para lidar e analisar grandes volumes de dados, melhorando assim a tomada de decisões e a eficiência operacional (Schwab, 2016).

Outro impulsionador significativo para o mercado de Inteligência Artificial são os rápidos avanços em algoritmos de aprendizado de máquina. O aprendizado de máquina evoluiu substancialmente com melhorias no poder de processamento e acesso a grandes conjuntos de dados, o que permite o desenvolvimento de modelos mais complexos.

Um relatório do Índice de Economia e Sociedade Digital da União Europeia afirma que quase 70% das empresas em toda a Europa devem integrar alguma forma de IA até 2025, impulsionadas por técnicas aprimoradas de aprendizado de máquina (Goodfellow; Bengio; Courville, 2016).

Empresas como IBM e Amazon estão liderando o caminho ao implementar soluções de

aprendizado de máquina de última geração para aprimorar suas ofertas, resultando em maior competitividade de mercado e expansão de aplicações para o consumidor, o que reforça assim a tendência em direção à automação e à tomada de decisões otimizada (Davenport et al., 2020).

O alinhamento estratégico é o elo entre o Plano Estratégico de Tecnologia de Informação (PETI) e o Plano Estratégico de Negócio (PEN) das organizações. Através do alinhamento entre estes dois planos, os recursos informacionais da empresa suportam os objetivos do negócio, o que permite a obtenção de vantagens estratégicas a partir do uso dos sistemas (Brodbeck e Hoppen, 2002).

2.4 Inteligência Artificial e o Transporte de Carga Rodoviário

Após a apresentação dos fundamentos da IA na seção anterior, cabe agora examinar sua aplicação específica ao Transporte Rodoviário de Cargas, foco empírico desta pesquisa. A crescente digitalização das operações logísticas tem ampliado a disponibilidade de dados provenientes de diferentes fontes, como sistemas corporativos, sensores embarcados, dispositivos de rastreamento e plataformas digitais (Laudon; Laudon, 2020).

Os Sistemas de Informação Gerencial (SIG) desempenham função importante na coleta, organização e disseminação dessas informações para apoio às atividades de planejamento, controle e tomada de decisão nas organizações. Entretanto, conforme discutido nas seções anteriores, os SIG tradicionais foram historicamente concebidos para registrar e consolidar informações operacionais, oferecendo suporte principalmente a análises descritivas e retrospectivas (Laudon; Laudon, 2020).

A incorporação de técnicas de inteligência artificial (IA) representa, portanto, uma evolução natural desses sistemas ao ampliar sua capacidade analítica e transformar grandes volumes de dados em conhecimento útil para a gestão. De acordo com Davenport e Harris (2007), a utilização de análises avançadas e modelos algorítmicos possibilita que as organizações evoluam de uma abordagem baseada apenas em relatórios históricos para uma lógica orientada por previsões, simulações e recomendações de decisão. Desse modo, a integração entre inteligência artificial e sistemas de informação gerencial permite que as empresas desenvolvam maior capacidade de antecipação e resposta frente às dinâmicas do ambiente competitivo.

No setor de transporte rodoviário de cargas (TRC), essa evolução tecnológica ocorre principalmente por meio da integração de algoritmos de aprendizado de máquina e técnicas de

otimização aos sistemas de gestão logística, como *Transport Management Systems* (TMS), plataformas de planejamento de recursos empresariais (ERP) e sistemas de monitoramento de frota. Esses sistemas passam a incorporar modelos analíticos capazes de apoiar decisões relacionadas ao planejamento de rotas, alocação de veículos, gestão de riscos e manutenção de ativos logísticos (Winkelhaus; Grosse, 2020).

A literatura identifica múltiplas áreas de aplicação da inteligência artificial no contexto logístico, abrangendo desde a otimização operacional até o suporte estratégico à decisão. Bowersox, Closs e Cooper (2014) destacam que a logística é um campo fértil para tecnologias analíticas, dada a quantidade de variáveis envolvidas no planejamento e na execução das operações de transporte. Winkelhaus e Grosse (2020) corroboram ao mapear aplicações de IA em diferentes elos da cadeia logística, incluindo armazenagem, transporte e atendimento ao cliente.

No mesmo sentido, Russell e Norvig (2021) argumentam que tarefas caracterizadas por elevado volume de dados e necessidade de reconhecimento de padrões são particularmente adequadas à automação por algoritmos de aprendizado de máquina. O Quadro 2 sintetiza as principais áreas de aplicação da inteligência artificial na logística, compiladas a partir da revisão da literatura. Os parágrafos seguintes detalham cada uma dessas aplicações no contexto específico do TRC.

Quadro 2 - Áreas de aplicação da Inteligência Artificial na logística

Área de Aplicação	Exemplo de Uso da Inteligência Artificial
Otimização de Rotas	Sistemas como o Waze e soluções de roteirização/telemetria de frotas utilizam IA para analisar o tráfego em tempo real, as condições das vias e os dados históricos para calcular as rotas mais rápidas e econômicas, reduzindo o consumo de combustível e o tempo de entrega.
Gestão de Armazéns	Robôs autônomos, guiados por aprendizado por reforço, navegam pelos armazéns para coletar, organizar e despachar produtos. A visão computacional é usada para inspecionar itens, ler códigos de barras e garantir a precisão dos pedidos.
Previsão de Demanda	Algoritmos de Machine Learning analisam dados de vendas, sazonalidade, tendências de mercado e até mesmo fatores externos (como feriados e eventos climáticos) para prever a demanda futura de produtos com alta precisão, evitando excesso ou falta de estoque.
Manutenção Preditiva	Sensores instalados em veículos e equipamentos da frota coletam dados sobre o desempenho de componentes críticos. A IA analisa esses dados para prever falhas antes que elas ocorram, permitindo que a manutenção seja agendada de forma proativa, evitando paradas não planejadas e reduzindo custos.

Atendimento ao Cliente	Chatbots avançados, equipados com Processamento de Linguagem Natural (PLN), fornecem suporte 24/7, respondendo a perguntas sobre o status de entregas, políticas de frete e outras dúvidas comuns, liberando a equipe humana para lidar com questões mais complexas.
Veículos Autônomos	Empresas como a Tesla e a Waymo estão desenvolvendo caminhões e veículos de entrega autônomos que prometem revolucionar o transporte de cargas, aumentando a segurança e a eficiência das operações de longa distância.

Fonte: elaborado pelo autor com base em Novaes (2007), Laudon e Laudon (2020) e Schwab (2016).

Uma das aplicações mais diretas da inteligência artificial na logística refere-se à otimização de rotas e planejamento de transporte. Segundo Bowersox, Closs e Cooper (2014), a definição eficiente de rotas é um dos fatores que mais impactam os custos logísticos e o nível de serviço ao cliente. A utilização de algoritmos de otimização e aprendizado de máquina permite analisar simultaneamente múltiplas variáveis operacionais, como distância, condições de tráfego, restrições de entrega e capacidade dos veículos, o que permite a identificação de trajetos mais eficientes e economicamente viáveis. Essa capacidade analítica amplia significativamente o potencial dos sistemas de gestão de transporte ao permitir decisões logísticas mais rápidas e baseadas em dados.

O Quadro 3 apresenta os principais sistemas gerenciais utilizados por empresas do segmento logístico, compilados a partir da revisão da literatura. A variedade de plataformas evidencia a complexidade do ecossistema informacional no qual as transportadoras operam.

Quadro 3 - Principais sistemas gerenciais utilizados no segmento logístico

Sistema Gerencial	Descrição	Aplicações	Referencial Teórico
ERP (Enterprise Resource Planning)	Sistema integrado de gestão empresarial que consolida dados financeiros, operacionais e administrativos em uma única plataforma.	Controle financeiro, faturamento, gestão de custos logísticos, integração com TMS e BI.	Kenneth Laudon; Jane Laudon (2020); O'Brien e Marakas (2013).
TMS (Transportation Management System)	Sistema especializado na gestão do transporte, responsável pelo planejamento, execução e monitoramento das operações logísticas.	Roteirização, gestão de fretes, controle de entregas, cálculo de custos de transporte e SLA.	Ballou (2006); Bowersox, Closs e Cooper (2014); Pereira e Simonetto (2018).
WMS (Warehouse Management System)	Sistema de gestão de armazéns que controla o fluxo e o armazenamento de mercadorias.	Controle de estoque, separação de pedidos, endereçamento e expedição de cargas.	Bowersox, Closs e Cooper (2014); Laudon e Laudon (2020).
YMS (Yard Management System)	Sistema voltado à gestão de pátios logísticos e movimentação de veículos dentro das instalações.	Controle de docas, filas de carga/descarga, agendamento de veículos e otimização de fluxo no pátio.	Hennelly et al. (2020); Pereira e Simonetto (2018).

Sistema Gerencial	Descrição	Aplicações	Referencial Teórico
OMS (Order Management System)	Sistema responsável pela gestão e acompanhamento de pedidos ao longo do ciclo logístico.	Processamento de pedidos, rastreamento de entregas, integração com estoque e transporte.	Turban, Volonino e Wood (2015); Laudon e Laudon (2020).
BI (Business Intelligence)	Plataforma de análise de dados que transforma informações operacionais em indicadores e dashboards para suporte à decisão.	Monitoramento de KPIs logísticos, análise de desempenho, identificação de ineficiências operacionais.	Davenport e Harris (2017); Laudon e Laudon (2020).
APS (Advanced Planning and Scheduling)	Sistema avançado de planejamento que utiliza algoritmos para otimizar produção e logística.	Planejamento de demanda, otimização de carga, programação de rotas e recursos logísticos.	Brynjolfsson e McAfee (2017); Hennelly et al. (2020).
Telemetria / Rastreamento	Sistemas baseados em sensores e GPS que monitoram veículos e cargas em tempo real.	Controle de frota, monitoramento de consumo de combustível, segurança e gestão de risco.	Pereira e Simonetto (2018).
EDI (Electronic Data Interchange)	Tecnologia que permite a troca eletrônica de dados entre empresas de forma padronizada.	Integração com embarcadores, envio de documentos fiscais, automatização de processos logísticos.	Laudon e Laudon (2020); O'Brien e Marakas (2013).
SCM (Supply Chain Management)	Sistema que integra e gerencia toda a cadeia de suprimentos, do fornecedor ao cliente final.	Planejamento logístico, coordenação de cadeia, gestão de fornecedores e distribuição.	Bowersox, Closs e Cooper (2014); Ballou (2006).
CRM (Customer Relationship Management)	Sistema de gestão do relacionamento com clientes, integrado aos processos comerciais e operacionais.	Gestão de clientes, acompanhamento de contratos, melhoria do nível de serviço logístico.	Laudon e Laudon (2020); Turban, Volonino e Wood (2015).
Sistemas de Frete / Freight Platforms	Plataformas digitais para contratação e gestão de fretes, muitas vezes com marketplace integrado.	Cotação de fretes, contratação de transportadores, otimização de carga e redução de custos.	Brynjolfsson e McAfee (2017); Hennelly et al. (2020); Marinagi et al. (2023)

Fonte: elaborado pelo autor.

A diversidade de plataformas apresentada no Quadro 3 ilustra a complexidade do ecossistema tecnológico no qual as transportadoras operam. A convergência desses sistemas em uma base integrada de dados é pré-requisito para a aplicação de técnicas de inteligência artificial, dado que algoritmos de aprendizado de máquina dependem de fontes consolidadas e padronizadas de informação (Davenport, 2018).

Outra aplicação refere-se aos modelos de precificação e planejamento da demanda de transporte. Em ambientes logísticos caracterizados por elevada variabilidade de demanda, algoritmos preditivos podem auxiliar na definição de preços e na alocação de recursos operacionais e melhorar o equilíbrio entre oferta e demanda de transporte. Brynjolfsson e

McAfee (2014) destacam que o uso de inteligência artificial e análise avançada de dados tem potencial para transformar processos decisórios em diversos setores econômicos. As organizações podem utilizar dados históricos e informações contextuais para antecipar tendências e ajustar suas estratégias operacionais (Richey et al., 2023).

A manutenção preditiva de frotas também é um campo de aplicação da inteligência artificial no transporte rodoviário de cargas. Sensores embarcados nos veículos permitem coletar continuamente dados sobre desempenho mecânico, consumo de combustível e padrões de operação. Esses dados podem ser analisados por modelos de aprendizado de máquina capazes de identificar padrões de falhas ou anomalias operacionais antes que ocorram interrupções no funcionamento dos equipamentos (Russell; Norvig, 2021).

Sistemas baseados em inteligência artificial são particularmente eficientes em tarefas que envolvem reconhecimento de padrões e previsão de eventos futuros, características que tornam essas tecnologias adequadas para aplicações de manutenção preditiva e gestão de ativos (Winkelhaus; Grosse, 2020).

A inteligência artificial pode contribuir também para a gestão de riscos e segurança logística. No transporte rodoviário de cargas, a análise de dados históricos de incidentes, condições geográficas e padrões operacionais pode apoiar a identificação de rotas mais seguras e o desenvolvimento de estratégias preventivas de mitigação de riscos. Sistemas analíticos avançados permitem que gestores logísticos adotem decisões baseadas em evidências, reduzindo a exposição a eventos adversos e aumentando a confiabilidade das operações (Tsoulakis et al., 2023).

Mais recentemente, avanços em modelos de linguagem baseados em inteligência artificial têm possibilitado novas formas de interação entre usuários e sistemas corporativos. Esses modelos permitem a criação de agentes digitais capazes de interagir com plataformas de gestão logística e sistemas de informação empresarial, facilitando o acesso a informações e o suporte à tomada de decisão. De acordo com Davenport, Guha, Grewal e Bressgott (2020), o desenvolvimento de sistemas baseados em inteligência artificial generativa tem potencial para transformar a forma como usuários interagem com sistemas corporativos e ampliar a capacidade de automação e suporte às atividades organizacionais.

Apesar do potencial dessas tecnologias, o grau de adoção da inteligência artificial no setor de transporte rodoviário de cargas ainda varia entre organizações. Essa variação reflete diferenças de maturidade tecnológica, disponibilidade de dados e capacidade de investimento em inovação. Conforme destacam Christopher (2016) e Bowersox, Closs e Cooper (2014), a adoção bem-sucedida de tecnologias avançadas na logística depende tanto da disponibilidade

de ferramentas tecnológicas quanto da capacidade organizacional de integrar sistemas, estruturar dados e desenvolver competências analíticas (Culot et al., 2024).

A integração entre inteligência artificial e sistemas de informação gerencial é parte do futuro da evolução tecnológica das operações logísticas. Ao ampliar a capacidade analítica dos SIG e possibilitar decisões mais rápidas, precisas e baseadas em dados, a inteligência artificial contribui para melhorar a eficiência operacional, reduzir riscos e fortalecer a competitividade das empresas no setor de transporte rodoviário de cargas. Cabe investigar de que maneira a adoção dessas tecnologias pode impactar os processos decisórios e a eficiência operacional das empresas do setor, questão que orienta o desenvolvimento da presente pesquisa (Richey et al., 2023).

Cabe ressaltar que a literatura empírica sobre IA aplicada especificamente ao transporte rodoviário de cargas ainda é incipiente, concentrando-se predominantemente em relatos de caso isolados e em análises de viabilidade tecnológica. Richey et al. (2023) observam que a pesquisa sobre IA na cadeia de suprimentos tem avançado mais rapidamente em setores manufatureiros e varejistas, restando lacunas significativas em segmentos como o transporte rodoviário. Seja este cenário provocado pela capacidade financeira e ou pelo ecossistema do modelo de negócio, essa constatação reforça a relevância da presente pesquisa ao contribuir para um campo ainda pouco explorado.

A avaliação da integração entre inteligência artificial e sistemas de informação gerencial requer, portanto, um framework que capture a progressão organizacional em múltiplas dimensões. Os modelos de maturidade oferecem essa estrutura ao definir estágios sequenciais de evolução, permitindo que organizações identifiquem seu patamar atual e planejem a transição para níveis superiores de capacidade (De Bruin et al., 2005). Essa constatação justifica a adoção de modelos de maturidade como base teórica para a proposição do Produto Técnico desta pesquisa.

2.5 Modelos de Maturidade Digital

A compreensão dos estágios de evolução tecnológica nas organizações é importante para esta pesquisa, na medida em que o terceiro objetivo específico propõe um modelo de maturidade aplicável ao TRC. Modelos de maturidade são frameworks que descrevem estágios progressivos de desenvolvimento de uma capacidade organizacional, desde um estado inicial até um patamar otimizado (De Bruin et al., 2005). Becker, Knackstedt e Pöppelbuß (2009) propõem que o desenvolvimento de modelos de maturidade deve seguir procedimentos metodológicos rigorosos, incluindo definição de escopo, comparação com modelos existentes,

design iterativo e validação empírica.

Na literatura, os modelos de maturidade podem ser classificados em três categorias: descritivos, prescritivos e comparativos (De Bruin et al., 2005). Modelos descritivos avaliam o estado atual de uma organização; prescritivos indicam caminhos de melhoria; e comparativos permitem benchmarking entre organizações. O IM-TRC proposto nesta pesquisa é predominantemente descritivo, dado que seu objetivo primário é diagnosticar o nível de maturidade em IA, embora ofereça elementos prescritivos ao indicar os critérios de cada nível de evolução.

Na década de 1990, Paulk et al. (1993) propuseram o *Capability Maturity Model* (CMM), um dos *frameworks* mais influentes na avaliação de maturidade organizacional. O CMM estabelece cinco níveis progressivos, do inicial ao otimizado, definindo práticas-chave para cada estágio. Embora originalmente concebido para processos de *software*, o modelo foi amplamente adaptado a outros domínios, incluindo a gestão de infraestrutura tecnológica e a adoção de novas tecnologias (Paulk et al., 1993).

De Bruin et al. (2005) avançaram nessa tradição ao sistematizar as fases genéricas de desenvolvimento de modelos de maturidade, oferecendo uma metodologia replicável para a construção de instrumentos de avaliação em diferentes domínios. Os autores argumentam que um modelo de maturidade consistente deve contemplar escopo definido, design estruturado, validação empírica e manutenção contínua, ou seja, um processo que vai além da mera replicação de *frameworks* existentes (De bruin et al., 2005).

No contexto específico da transformação digital, Westerman, Bonnet e McAfee (2014) demonstram que a maturidade digital depende de dois eixos complementares: a intensidade digital, relativa à adoção de tecnologias como IA e *analytics*, e a intensidade de gestão da transformação, que envolve liderança, governança e engajamento organizacional. Essa abordagem reforça que a maturidade não se restringe à infraestrutura tecnológica, mas abrange também as capacidades gerenciais necessárias para extrair valor das tecnologias adotadas (Westerman; Bonnet; McAfee, 2014).

Tornatzky e Fleischer (1990), por sua vez, propuseram o *framework* TOE (*Technology-Organization-Environment*), que identifica três contextos determinantes na adoção de inovações tecnológicas: o tecnológico, que abrange as tecnologias disponíveis; o organizacional, que inclui porte, recursos e estrutura de gestão; e o ambiental, que contempla regulação, competição e dinâmica setorial. No caso do TRC, esses três contextos são particularmente relevantes, dadas as especificidades regulatórias da ANTT e a heterogeneidade do setor (Tornatzky; Fleischer, 1990).

Venkatraman (1994) complementa essa perspectiva ao propor cinco estágios de transformação organizacional viabilizada pela TI, desde a automação localizada até a redefinição do escopo de negócio. Esse modelo hierárquico evidencia que os benefícios percebidos da tecnologia crescem à medida que a organização avança nos estágios de integração, sendo que as barreiras também se intensificam nos níveis mais elevados de transformação (Venkatraman, 1994).

A tradição de modelos de maturidade oferece o arcabouço teórico para a proposição do Modelo de Maturidade de IA para o TRC (IM-TRC), objetivo específico desta pesquisa. A convergência entre os estágios de Nolan (1973), a estrutura do CMM (Paulk et al., 1993), a metodologia de De Bruin et al. (2005), os eixos de maturidade digital de Westerman, Bonnet e McAfee (2014) e o *framework* TOE de Tornatzky e Fleischer (1990) fornece as bases conceituais para um modelo que avalie a maturidade de IA considerando infraestrutura tecnológica, capacidades analíticas e governança organizacional no contexto do transporte rodoviário de cargas.

Apresentados os fundamentos teóricos que sustentam esta pesquisa, o capítulo seguinte detalha os procedimentos metodológicos adotados para a coleta e análise dos dados.

3 MÉTODOS DE PESQUISA

Este capítulo apresenta os procedimentos metodológicos adotados para a realização da presente pesquisa. Considerando o caráter ainda incipiente da aplicação da inteligência artificial no setor logístico brasileiro, optou-se por uma pesquisa de natureza exploratória, com abordagem qualitativa e suporte em evidências empíricas provenientes do setor. A escolha da abordagem metodológica buscou garantir consistência analítica e correspondência entre os objetivos do estudo, o referencial teórico e as evidências empíricas coletadas (Gil, 2002; Vergara, 2016).

3.1 Caracterização da Pesquisa

A presente pesquisa possui natureza exploratória e abordagem predominantemente qualitativa, tendo como objetivo compreender como a adoção de recursos de inteligência artificial em sistemas de informação gerencial pode impactar a eficiência operacional e a qualidade da tomada de decisão nas empresas do setor de transporte rodoviário de cargas (TRC). A escolha por uma abordagem exploratória justifica-se pelo fato de que a aplicação da inteligência artificial no contexto específico do transporte rodoviário de cargas ainda se encontra em estágio inicial de maturidade no Brasil, o que demanda investigações que permitam compreender o fenômeno em profundidade e identificar padrões incipientes no setor (Gil, 2002).

Do ponto de vista metodológico, a pesquisa foi estruturada a partir da estratégia de estudo de caso com apoio em múltiplas fontes de evidência e analisar o fenômeno em seu contexto real de ocorrência. Essa abordagem é particularmente adequada quando se busca compreender processos organizacionais complexos, que envolvem a interação entre tecnologia, práticas gerenciais e tomada de decisão estratégica. Considerando esse contexto, a utilização de diferentes fontes de informação contribui para aumentar a consistência analítica da pesquisa e fortalecer a confiabilidade dos resultados obtidos (Yin, 2015; Eisenhardt, 1989).

A investigação empírica foi conduzida por meio da combinação de duas técnicas principais de coleta de dados, conforme recomendado por Gil (2002) para pesquisas exploratórias. A primeira consistiu na aplicação de um questionário estruturado junto à empresa Empresa Alfa, organização com atuação no transporte rodoviário de cargas no Brasil. O instrumento de pesquisa buscou identificar aspectos relacionados à infraestrutura tecnológica

da empresa, ao uso de sistemas de informação gerencial, à adoção de recursos analíticos avançados e à percepção dos impactos da inteligência artificial na eficiência operacional e nos processos de tomada de decisão.

A segunda fonte de evidência empírica foi obtida por meio de uma entrevista semiestruturada realizada com um executivo da Empresa Beta, organização especializada no desenvolvimento de soluções de inteligência artificial para o setor logístico. A entrevista semiestruturada é indicada quando se busca captar percepções aprofundadas sobre fenômenos complexos, permitindo ao pesquisador explorar temas emergentes durante a interação (Gil, 2002). Essa abordagem possibilitou captar a perspectiva de um agente do setor tecnológico sobre os desafios e oportunidades da IA no transporte rodoviário de cargas.

A combinação dessas fontes permitiu triangular os dados: confrontar a prática organizacional de uma transportadora, a visão de um fornecedor de tecnologia e o referencial teórico. Essa estratégia amplia a consistência das conclusões sobre a utilização de IA em SIG no TRC (Yin, 2015).

3.2 Delineamento das etapas da pesquisa

O desenvolvimento da presente pesquisa foi estruturado em etapas sequenciais, seguindo a lógica proposta por Creswell e Creswell (2018) para garantir coerência entre o problema de pesquisa, o referencial teórico e as evidências empíricas. O processo de investigação foi conduzido em quatro etapas principais, que permitiram construir progressivamente a base analítica do estudo.

A primeira etapa consistiu na revisão da literatura, seguindo as diretrizes de Creswell e Creswell (2018), sobre os principais conceitos relacionados aos sistemas de informação gerencial, à transformação digital nas organizações e à aplicação da inteligência artificial em processos decisórios. Essa etapa teve como finalidade estabelecer o referencial teórico que fundamenta a pesquisa, além de identificar modelos conceituais e contribuições acadêmicas para a compreensão do fenômeno investigado.

Na segunda etapa foi elaborado o instrumento de pesquisa aplicado junto à empresa selecionada, seguindo as diretrizes de Gil (2002) para construção de questionários em pesquisa social. O questionário estruturado foi desenvolvido com o objetivo de identificar o nível de utilização de sistemas de informação gerencial, o grau de maturidade na gestão de dados e a percepção dos impactos da inteligência artificial na eficiência operacional e na tomada de decisão gerencial. A aplicação do instrumento foi realizada junto a um executivo responsável

pela área de tecnologia da informação da empresa Empresa Alfa e obter evidências práticas sobre a adoção de tecnologias analíticas no ambiente organizacional.

A terceira etapa consistiu na realização de uma entrevista semiestruturada, técnica recomendada por Flick (2009) para pesquisas qualitativas exploratórias, com um executivo da Empresa Beta (descrita na seção anterior). O objetivo foi captar a visão de um especialista do ecossistema tecnológico sobre o nível de maturidade digital das transportadoras brasileiras e as tendências de evolução tecnológica. A entrevista também permitiu identificar aplicações práticas da inteligência artificial em sistemas logísticos, como roteirização inteligente, precificação dinâmica e automação de processos decisórios.

Por fim, na quarta etapa da pesquisa, foi realizada a análise integrada das evidências coletadas. Nesse estágio, os dados obtidos por meio do questionário aplicado à transportadora e da entrevista com o especialista do setor tecnológico foram analisados comparativamente e articulados com os conceitos discutidos no referencial teórico. Esse processo permitiu realizar uma triangulação das informações e identificar convergências entre teoria e prática e para construir uma compreensão mais ampla sobre o papel da inteligência artificial nos sistemas de informação gerencial aplicados ao transporte rodoviário de cargas (Yin, 2015).

3.3 Procedimentos de Coleta de Dados

A coleta de dados combinou questionário estruturado e entrevista semiestruturada para reunir evidências sobre a adoção de IA em SIG no TRC. A utilização de múltiplas fontes fortalece a validade das conclusões (Yin, 2015).

O primeiro instrumento utilizado foi um questionário estruturado aplicado junto à Empresa Alfa, organização com atuação relevante no transporte rodoviário de cargas no Brasil. O questionário estruturado é adequado para a coleta de dados padronizados sobre práticas e percepções organizacionais, permitindo a comparação sistemática das respostas (Gil, 2002). O instrumento foi composto por questões fechadas e abertas, abrangendo temas relacionados à infraestrutura tecnológica, à utilização de sistemas de informação gerencial e à percepção sobre inteligência artificial.

O questionário foi elaborado com base na revisão da literatura. O instrumento foi estruturado em oito blocos temáticos, que cobrem desde a identificação organizacional até as expectativas futuras em relação à IA. Cada pergunta foi formulada a partir de conceitos e dimensões identificados no referencial teórico, assegurando a correspondência entre o instrumento de coleta e os objetivos da pesquisa (Gil, 2002). O Quadro 4 apresenta a relação

entre os blocos do questionário, suas respectivas bases teóricas e os objetivos específicos a que se vinculam. O instrumento completo, acompanhado do Termo de Consentimento Livre e Esclarecido (TCLE), encontra-se no Apêndice A. O roteiro da entrevista semiestruturada consta no Apêndice B.

Quadro 4 - Relação entre blocos do questionário, base teórica e objetivos

Bloco	Tema	Base Teórica	OE
1-2	Identificação organizacional e perfil do respondente	Gil (2002); Vergara (2016)	—
3	Contexto competitivo e processo decisório	Porter (1985); Laudon e Laudon (2020)	OE1
4	Uso de Sistemas de Informação Gerencial	Laudon e Laudon (2020); O'Brien e Marakas (2013)	OE1
5	Adoção de IA e analítica avançada	Davenport (2018); Brynjolfsson e McAfee (2017)	OE2
6	Impactos percebidos na tomada de decisão	Westerman, Bonnet e McAfee (2014)	OE2
7	Desafios, expectativas e futuro	Tornatzky e Fleischer (1990) — TOE	OE2, OE3
8	Considerações finais do respondente	Yin (2015) — triangulação	OE1–OE3

Fonte: elaborado pelo autor.

O questionário foi previamente submetido à avaliação de dois especialistas da área de Sistemas de Informação e Logística, que analisaram a clareza, a pertinência e a adequação das perguntas ao fenômeno investigado. Esse procedimento de validação de conteúdo é recomendado por Gil (2002) como etapa essencial para assegurar que o instrumento de coleta mensure efetivamente os constructos pretendidos.

Entre os temas investigados destacam-se a utilização de sistemas como ERP, TMS, ferramentas de *Business Intelligence* e tecnologias de telemetria, bem como a percepção do respondente sobre barreiras e benefícios da inteligência artificial. As categorias temáticas foram definidas primeiramente com base nos objetivos específicos da pesquisa e na revisão da literatura, seguindo o procedimento de análise de conteúdo categorial recomendado por Bardin (2011).

Além do questionário estruturado, a entrevista com o executivo da Empresa Beta buscou captar a percepção de um agente do setor tecnológico sobre a digitalização do TRC. A combinação de múltiplos instrumentos de coleta é recomendada por Yin (2015) como estratégia para aumentar a validade de construto em estudos de caso.

A entrevista foi conduzida remotamente, com duração aproximada de sessenta minutos, seguindo um roteiro previamente estruturado de perguntas abertas, conforme a técnica de entrevista semiestruturada descrita por Flick (2009). O roteiro abordou temas relacionados à maturidade tecnológica do setor, à aplicação de inteligência artificial em sistemas logísticos, às barreiras para adoção dessas tecnologias e às perspectivas de evolução do uso de algoritmos e

modelos analíticos no transporte rodoviário de cargas. A conversa foi registrada e posteriormente transcrita. A partir disso, realizou-se a análise qualitativa do conteúdo obtido.

Essa combinação de fontes proporcionou perspectivas complementares sobre o fenômeno, conforme preconizado por Yin (2015).

A seleção dos participantes seguiu critério intencional, também denominado amostragem por julgamento. Priorizaram-se informantes com visões complementares sobre o fenômeno investigado: de um lado, a perspectiva da demanda, representada pelo executivo de tecnologia da transportadora; de outro, a perspectiva da oferta, representada pelo gestor de empresa fornecedora de soluções de IA. Essa estratégia é coerente com a recomendação de Eisenhardt (1989) de selecionar casos e informantes que permitam captar variações teóricas relevantes para a construção de proposições.

3.4 Estratégia de Análise e Triangulação das Evidências

Após a etapa de coleta de dados, foi realizada a análise das informações obtidas a partir da integração das diferentes fontes de evidência utilizadas na pesquisa. A estratégia adotada baseou-se na técnica de triangulação de dados, procedimento metodológico amplamente utilizado em estudos qualitativos para aumentar a robustez analítica e a confiabilidade dos resultados (Yin, 2015).

A triangulação, conforme Yin (2015), consistiu na comparação e articulação das evidências provenientes de três fontes principais: o referencial teórico discutido na revisão da literatura, os dados obtidos por meio do questionário aplicado à empresa Empresa Alfa e as informações coletadas na entrevista semiestruturada com o executivo da empresa Empresa Beta. A análise integrada dessas fontes permitiu identificar convergências e complementaridades entre as diferentes perspectivas investigadas.

O procedimento de análise adotado seguiu os princípios da análise de conteúdo categorial (Bardin, 2011), com categorias definidas primeiramente a partir dos objetivos específicos da pesquisa. Foram estabelecidas três categorias analíticas: (a) infraestrutura tecnológica e maturidade digital, correspondente ao OE1; (b) benefícios percebidos, barreiras e estágio de adoção da IA, correspondente ao OE2; e (c) elementos para a proposição de um modelo de maturidade, correspondente ao OE3.

Os relatos dos entrevistados e as respostas do questionário foram organizados segundo essas categorias, o que permitiu a identificação de convergências e complementaridades entre as fontes. A interpretação foi conduzida à luz do referencial teórico, buscando articular os

achados empíricos com os conceitos discutidos na literatura (Bardin, 2011; Yin, 2015).

No caso da pesquisa aplicada na transportadora, a análise concentrou-se na identificação do nível de utilização de sistemas de informação gerencial, no grau de maturidade da gestão de dados e nas oportunidades de integração de IA. As categorias de análise foram derivadas dos objetivos específicos da pesquisa, seguindo a lógica de correspondência entre proposições teóricas e evidências empíricas preconizada por Yin (2015) para estudos de caso explanatórios.

A partir da comparação entre essas evidências, foi possível identificar padrões consistentes relacionados à maturidade tecnológica do setor, às condições necessárias para a adoção de IA e às barreiras percebidas pelos diferentes atores. Essa abordagem de análise cruzada entre fontes é consistente com a técnica de síntese cruzada de casos descrita por Yin (2015), que permite identificar convergências e divergências entre unidades de análise.

Assim, a integração entre revisão da literatura, pesquisa aplicada em empresa do setor e entrevista com especialista possibilitou estabelecer uma base empírica robusta. Essa estratégia de triangulação metodológica aumenta a confiabilidade dos resultados ao reduzir vieses de método único (Eisenhardt, 1989; Yin, 2015).

3.5 Procedimentos de Construção do Produto Técnico

A construção do Produto Técnico/Tecnológico (PTT) desta pesquisa, o Modelo de Maturidade IM-TRC, é o terceiro objetivo específico (OE3) e demandou procedimentos metodológicos próprios, articulando as evidências empíricas dos objetivos anteriores com o referencial teórico sobre modelos de maturidade. O desenvolvimento seguiu as diretrizes propostas por De Bruin et al. (2005) para a concepção de modelos de maturidade, que recomendam a definição de escopo, design, população, teste e implementação como fases estruturantes.

O processo de construção do IM-TRC seguiu quatro etapas. Na primeira, as evidências empíricas coletadas nos Capítulos 3 e 4, relativas à infraestrutura tecnológica (OE1) e aos benefícios e barreiras percebidos (OE2), foram sistematizadas para identificar os principais eixos de variação entre as organizações. Na segunda etapa, esses eixos foram confrontados com os modelos teóricos discutidos na seção 2.5, especialmente o CMM (Paulk et al., 1993), o *framework* TOE (Tornatzky; Fleischer, 1990) e as dimensões de maturidade digital de Westerman, Bonnet e McAfee (2014), para definir as dimensões do modelo.

Na terceira etapa, foram estabelecidos os níveis de maturidade e seus critérios descritivos, calibrados com base nas práticas observadas na empresa estudada e nas tendências

apontadas pelo especialista entrevistado. Na quarta etapa, o modelo foi aplicado ao caso da Empresa Alfa para verificar sua operacionalidade e gerar o diagnóstico apresentado no Capítulo 5 (Eisenhardt, 1989).

3.6 Limitações do Método de Pesquisa

Apesar do esforço metodológico empregado na condução desta pesquisa, algumas limitações devem ser consideradas na interpretação dos resultados obtidos. Tais limitações estão relacionadas principalmente ao desenho exploratório do estudo, ao recorte empírico adotado e à natureza qualitativa das evidências coletadas (Yin, 2015).

Uma primeira limitação refere-se à seleção das organizações participantes da pesquisa. O estudo empírico concentrou-se na análise de uma empresa do setor de transporte rodoviário de cargas, a Empresa Alfa, utilizada como estudo de caso para compreender a aplicação prática de sistemas de informação gerencial e tecnologias analíticas no ambiente organizacional. Embora a empresa possua porte relevante e operações representativas no setor, a análise baseada em um único caso limita a possibilidade de generalização dos resultados para o conjunto das empresas que atuam no transporte rodoviário de cargas no Brasil (Yin, 2015).

Outra limitação refere-se à entrevista com o executivo da Empresa Beta. Por se tratar de uma empresa fornecedora de soluções tecnológicas, as percepções apresentadas podem refletir um viés otimista em relação ao potencial da inteligência artificial. Yin (2015) alerta que informantes com interesses comerciais no fenômeno investigado podem enviesar os achados, recomendando que suas contribuições sejam trianguladas com outras fontes de evidência.

Outra limitação diz respeito ao caráter exploratório da pesquisa (Gil, 2017). O estudo buscou compreender tendências, percepções e práticas relacionadas à adoção de inteligência artificial em sistemas de informação gerencial no setor de transporte rodoviário de cargas. Por essa razão, os resultados devem ser interpretados como evidências iniciais sobre o fenômeno investigado, e não como conclusões definitivas ou generalizáveis para todo o setor logístico.

Cabe registrar, ainda, que o Modelo de Maturidade IM-TRC, produto técnico desta pesquisa, foi desenvolvido a partir das mesmas evidências empíricas que serviram de base para a análise dos resultados. Essa opção metodológica é coerente com a abordagem de construção teórica a partir de estudos de caso proposta por Eisenhardt (1989), na qual as evidências empíricas fundamentam a elaboração de *frameworks* e modelos conceituais.

Por fim, deve-se considerar que o setor de transporte rodoviário de cargas encontra-se em processo contínuo de transformação digital, marcado pela rápida evolução das tecnologias

disponíveis. Essa dinâmica impõe uma limitação temporal aos achados, dado que diagnósticos de maturidade tendem a se desatualizar à medida que novas tecnologias são incorporadas (Schuh et al., 2017). Pesquisas futuras devem, portanto, revisitar os achados deste estudo à luz de eventuais avanços tecnológicos no setor.

Apesar dessas limitações, a triangulação entre literatura, questionário e entrevista contribui para mitigar parcialmente os vieses de cada fonte individual (Eisenhardt, 1989), conferindo maior consistência aos achados. Definidos os procedimentos metodológicos, o capítulo a seguir apresenta os resultados obtidos e sua análise com base no referencial teórico.

4 APRESENTAÇÃO E ANÁLISE DOS RESULTADOS

Este capítulo apresenta os resultados obtidos na pesquisa de campo e sua análise com base no referencial teórico, organizados segundo os três objetivos específicos da pesquisa. A primeira parte caracteriza o perfil tecnológico e o grau de maturidade digital da empresa estudada (OE1). Em seguida, são identificados os benefícios percebidos e as barreiras para a adoção de inteligência artificial integrada aos SIG (OE2). Por fim, os achados fornecem as evidências empíricas que fundamentam a sugestão do Modelo de Maturidade IM-TRC (OE3), detalhado no Capítulo 5. Os dados foram analisados por meio de triangulação de fontes, integrando as perspectivas operacional e tecnológica para fortalecer a validade dos achados.

4.1 Caracterização dos respondentes

Os dados desta pesquisa foram obtidos a partir de dois perfis complementares, visando as perspectivas operacional e tecnológica do setor. A empresa selecionada, Empresa Alfa, conta com aproximadamente 2.000 colaboradores, mais de 800 caminhões pesados e 60 filiais em operação, enquadrando-se nesse critério. A Empresa Beta, por sua vez, é uma organização, líder e referência no mercado, especializada no desenvolvimento de soluções de sistemas gerenciais, serviços de apoio a atividade de transporte e logística e desenvolvimento de agentes de inteligência artificial para o setor logístico, cuja inclusão visa captar a perspectiva do fornecedor de tecnologia sobre os desafios e oportunidades da IA no TRC. A combinação de uma transportadora de grande porte com um fornecedor de tecnologia permite a triangulação de fontes recomendada por Yin (2015), confrontando a prática operacional com a visão do mercado de soluções.

O primeiro respondente é o executivo responsável pela área de tecnologia da transportadora pesquisada (Empresa Alfa), que atua com gestão de processos e transformação digital há mais de dez anos. Esse perfil corresponde ao informante-chave recomendado pela literatura de estudo de caso, dado que deve possuir conhecimento aprofundado do fenômeno investigado (Yin, 2015).

O segundo respondente é o CTO de empresa especializada em soluções de inteligência artificial para o setor logístico (Empresa Beta), com experiência em projetos de IA aplicada ao transporte. A inclusão de um informante externo à organização estudada segue a recomendação de triangulação de fontes proposta por Eisenhardt (1989), permitindo confrontar a perspectiva

interna com a visão do mercado fornecedor de tecnologia.

4.2 Perspectiva do Fornecedor de Tecnologia

Com o objetivo de complementar as evidências relativas à infraestrutura tecnológica (OE1) e às barreiras e benefícios da IA (OE2) no setor de transporte rodoviário de cargas (TRC) no Brasil, foi realizada uma entrevista semiestruturada com um executivo de empresa especializada em tecnologia logística. O entrevistado atua como principal executivo na área de tecnologia da informação dentro da empresa e esta é o principal fornecedor de sistemas e serviço tecnológicos de gestão no segmento logístico e de transporte. A entrevista buscou captar a percepção de um especialista do setor sobre o nível atual de digitalização das transportadoras, os principais desafios tecnológicos enfrentados pelas empresas e as tendências relacionadas ao uso de inteligência artificial em sistemas de informação gerencial.

O setor de transporte rodoviário de cargas encontra-se em um estágio intermediário de transformação digital. Embora diversas empresas já utilizem sistemas de informação gerencial, como ERP e TMS, a incorporação de soluções baseadas em inteligência artificial permanece restrita a organizações de maior porte ou com investimentos específicos em inovação. Esse cenário é consistente com a literatura sobre difusão tecnológica no TRC, que aponta defasagem entre a disponibilidade de soluções e sua adoção efetiva (Pereira e Simonetto, 2018). Winkelhaus e Grosse (2020) reforçam que a transição para a logística inteligente exige não apenas investimento em tecnologia, mas transformação nos processos e na cultura organizacional.

Entre os principais obstáculos para a adoção mais ampla da inteligência artificial, destacam-se fatores relacionados à cultura organizacional, à capacidade de investimento em inovação e à dificuldade de integração com sistemas legados. Esses achados convergem com o framework TOE (Tornatzky; Fleischer, 1990), que identifica contextos tecnológico, organizacional e ambiental como determinantes da adoção de inovações. A resistência cultural e a limitação de recursos, em particular, são barreiras recorrentes na literatura sobre transformação digital no setor logístico (Hennelly et al., 2020).

Entretanto, o fator considerado mais crítico refere-se à organização e à qualidade dos dados disponíveis, uma vez que grande parte das transportadoras ainda apresenta bases de dados fragmentadas e sem padronização. Davenport (2018) argumenta que a eficácia de qualquer iniciativa de IA depende fundamentalmente da maturidade na gestão de dados, dado que algoritmos de aprendizado de máquina exigem volumes consistentes e confiáveis de

informação. No setor de TRC, essa fragilidade é agravada pela heterogeneidade dos sistemas utilizados (Laudon; Laudon, 2020).

Outro aspecto identificado na entrevista refere-se à assimetria de maturidade tecnológica existente entre empresas de diferentes portes. Enquanto grandes transportadoras já começam a experimentar soluções de IA, empresas de menor porte permanecem em estágios básicos de digitalização. Essa disparidade é coerente com os estágios de transformação descritos por Venkatraman (1994), segundo os quais organizações em níveis iniciais ainda se concentram na automação localizada, ao passo que empresas mais maduras avançam para a integração de processos de negócio. Westerman, Bonnet e McAfee (2014) denominam esse fenômeno de lacuna digital, na qual a distância entre líderes e retardatários tende a se ampliar ao longo do tempo.

Ainda assim, a entrevista também indicou que algumas aplicações de inteligência artificial já começam a gerar resultados concretos no setor logístico. Entre as principais aplicações destacam-se sistemas de roteirização inteligente, otimização operacional em plataformas de gestão de transporte (TMS), algoritmos de precificação e mecanismos de matching entre oferta de carga e disponibilidade de transporte. Essas soluções têm demonstrado potencial para gerar ganhos relevantes de eficiência operacional, redução de custos logísticos, e melhoria na qualidade das decisões gerenciais.

Sobre tendências futuras, o entrevistado apontou que a inteligência artificial tende a ganhar mais espaço no ecossistema logístico (McKinsey; Company, 2021). Segundo ele, “áreas com 15–20 pessoas vão deixar de existir”. Decisões operacionais simples, atualmente realizadas por operadores humanos, tendem a ser gradualmente automatizadas por sistemas inteligentes (Davenport, 2018).

Portanto, decisões mais complexas, por sua vez, deverão contar com suporte analítico avançado fornecido por ferramentas baseadas em inteligência artificial. Nessa leitura, tecnologias como torres de controle logístico inteligentes, modelos de precificação dinâmica, assistentes digitais para operadores logísticos e modelos de orquestração algorítmica despontam como tendências relevantes para os próximos anos (Winkelhaus; Grosse, 2020).

Por fim, a análise da entrevista sugere que a inteligência artificial tende a assumir inicialmente um papel de diferencial competitivo para empresas que conseguirem implementar essas soluções com efetividade. Essa percepção alinha-se com a visão de Davenport (2018), segundo a qual a IA configura uma vantagem competitiva temporária enquanto sua adoção permanece restrita a poucos players do setor. À medida que a tecnologia se difunde, ela se torna requisito de sobrevivência, não mais diferencial (Westerman; Bonnet; McAfee, 2014).

Essas evidências da entrevista complementam os dados obtidos por meio do questionário aplicado à empresa alfa e pela revisão da literatura, construindo uma visão mais ampla sobre o fenômeno. A convergência entre fontes distintas reforça a credibilidade dos achados, conforme preconizado pela lógica de triangulação em estudos de caso (Yin, 2015; Eisenhardt, 1989).

4.3 Infraestrutura Tecnológica e Maturidade Digital

Esta seção responde ao primeiro objetivo específico (OE1), ao caracterizar a infraestrutura tecnológica e o estágio de maturidade digital da empresa estudada, para em seguida abordar os benefícios percebidos e as barreiras à adoção de IA (OE2).

Em termos de infraestrutura, a empresa utiliza sistemas fundamentais como ERP (Enterprise Resource Planning) e TMS (Transportation Management System), além de ferramentas de Business Intelligence e sistemas de telemetria. Essa configuração corresponde ao ecossistema tecnológico típico descrito na literatura sobre SIG no transporte rodoviário (Laudon; Laudon, 2020; Bowersox; Closs; Cooper, 2014).

Segundo o especialista em IA entrevistado, o setor de TRC ainda está em um estágio inicial de maturidade tecnológica no Brasil, mas já apresenta tendências de evolução. Conforme relatou o entrevistado da empresa Beta, "o setor de transporte ainda está em um estágio muito inicial no uso de inteligência artificial, a maior parte das empresas ainda está organizando seus dados". As principais aplicações práticas de IA identificadas incluem roteirização inteligente, otimização operacional, precificação dinâmica e automação de processos decisórios (Venkatraman, 1994).

A empresa pesquisada está investindo tanto no desenvolvimento de ferramentas de integração quanto na capacitação dos colaboradores, como estratégia central de potencialização do uso da IA nos sistemas atuais, incentivando por meio de cursos rápidos a utilização de modelos de linguagem no dia a dia "há Copilot disponível para toda a empresa, contudo com baixa utilização" (entrevistado empresa alfa, 2026). Esse diagnóstico é coerente com o estágio de automação localizada descrito por Venkatraman (1994) e com os níveis iniciais de maturidade digital propostos por Westerman, Bonnet e McAfee (2014).

O respondente da transportadora destacou que o uso de tecnologias baseadas em dados gera impactos positivos na eficiência operacional e na qualidade das decisões gerenciais destacando os seguintes aspectos: No campo da otimização de rotas e operações, a IA é utilizada para roteirização dinâmica e melhoria da eficiência operacional. As soluções avançadas

baseadas em algoritmos são oferecidas por fornecedores especializados, porém sua adoção pela empresa estudada ainda é parcial. Bowersox, Closs e Cooper (2014) destacam que a otimização logística constitui uma das aplicações mais consolidadas de tecnologias analíticas no setor de transporte, ao passo que Winkelhaus e Grosse (2020) argumentam que a roteirização inteligente é um dos primeiros estágios da logística 4.0.

Quanto à previsão de demanda, a empresa encontra-se em estágio inicial de utilização de soluções baseadas em inteligência artificial, ainda com predominância de análises estruturadas em planilhas e relatórios de sistemas tradicionais. Esse cenário reflete o que Davenport (2018) classifica como *analytics* descritivo, etapa na qual as organizações se limitam a reportar o que aconteceu, sem capacidade preditiva. A transição para modelos preditivos requer maturidade na gestão de dados e integração entre sistemas (Laudon; Laudon, 2020).

As informações disponíveis em sistemas como TMS, ERP e ferramentas de Business Intelligence permitem a análise de volumes transportados, sazonalidades e padrões operacionais. Contudo, esses dados ainda são utilizados predominantemente para análise retrospectiva, sem integração com algoritmos preditivos, o que limita o potencial analítico descrito por Davenport (2018) como *analytics* prescritivo.

A ausência de modelos preditivos mais avançados limita a capacidade da organização de antecipar variações na demanda com maior precisão. A evolução para esse patamar depende, conforme Venkatraman (1994), de um nível de integração interna de processos de negócio que precede a reconfiguração das redes de negócio viabilizada pela tecnologia.

A base estruturada de dados e sistemas existente constitui um pré-requisito importante para a adoção de modelos preditivos mais avançados. Como ressalta o entrevistado da Empresa Beta, "o maior desafio não é a tecnologia, é a qualidade do dado". Essa percepção converge com Davenport (2018), que argumenta que a governança de dados é o fator crítico para a escalabilidade de iniciativas de IA nas organizações.

Quanto à gestão de riscos, há utilização de sistemas e práticas voltadas aos riscos operacionais, especialmente relacionados à segurança logística e ao monitoramento das operações de transporte. A empresa dispõe de telemetria embarcada, rastreamento e protocolos de segurança que geram dados passíveis de análise avançada. Segundo Richey et al. (2023), a gestão de riscos na cadeia de suprimentos é uma das áreas com maior potencial de transformação por meio da IA, dado que algoritmos podem identificar padrões de risco antes invisíveis à análise humana.

A aplicação de inteligência artificial nesse domínio, contudo, ainda se encontra em estágio inicial, com predominância de abordagens baseadas em regras e monitoramento reativo.

Conforme destacado pelo entrevistado da empresa alfa, "as transportadoras ainda atuam de forma reativa na gestão de riscos; a IA pode mudar isso com predição de sinistros". Essa transição do reativo para o preditivo corresponde ao que Schuh et al. (2017) descrevem como a passagem do nível de visibilidade para o de capacidade preditiva no modelo de maturidade *acatech*. O *acatech* é a Academia Nacional de Ciência e Engenharia da Alemanha (*Deutsche Akademie der Technikwissenschaften*). É a principal instituição científica consultiva do governo alemão para temas de tecnologia e inovação industrial.

No caso da empresa analisada, a infraestrutura tecnológica existente, especialmente os sistemas de telemetria e gestão de risco, constitui uma base para a evolução para modelos mais avançados de análise preditiva. A passagem de monitoramento reativo para predição de eventos é, segundo o *framework acatech*, um dos marcos de evolução na maturidade digital de organizações industriais (Schuh et al., 2017).

A gestão de riscos no contexto da empresa ainda se encontra predominantemente orientada por monitoramento e controle, mas apresenta potencial significativo de evolução para abordagens preditivas. Essa lacuna representa uma oportunidade de inovação, dado que a literatura aponta a predição de riscos como um dos benefícios mais tangíveis da IA na logística (Winkelhaus; Grosse, 2020).

No que diz respeito à automação, a organização encontra-se em estágio intermediário na automação de decisões operacionais, com a utilização de sistemas de informação gerencial que suportam processos como emissão de CT-e (Conhecimento de Transporte Eletrônico), rastreamento e programação de entregas. Esse nível de automação corresponde ao que Venkatraman (1994) denomina exploração localizada, estágio em que a tecnologia apoia processos individuais sem ainda promover integração organizacional mais ampla.

Os SIG contribuem para a estruturação do processo decisório, especialmente ao disponibilizar dados organizados e indicadores de desempenho que subsidiam decisões relacionadas à alocação de veículos, roteirização e gestão de custos. Laudon e Laudon (2020) classificam esse papel como suporte à decisão estruturada, na qual os sistemas fornecem informações padronizadas para problemas recorrentes e bem definidos.

A incorporação de recursos de inteligência artificial tem potencial para ampliar esse nível de automação. Os sistemas poderiam evoluir de uma lógica de apoio à decisão para modelos de decisão autônoma ou semi-autônoma, conforme proposto por Davenport (2018) ao descrever a progressão de analytics descritivo para prescritivo. Essa transição permitiria que decisões operacionais rotineiras fossem delegadas a algoritmos, liberando gestores para questões estratégicas (Westerman; Bonnet; McAfee, 2014).

No caso da empresa analisada, a evolução para níveis mais avançados de automação dependerá, sobretudo, da maior integração entre sistemas, da estruturação das bases de dados e do desenvolvimento de competências internas em ciência de dados. Esses requisitos são consistentes com os pilares de maturidade digital propostos por Westerman, Bonnet e McAfee (2014), que enfatizam a interdependência entre capacidade digital e capacidade de liderança transformadora.

Sobre o uso de dados e analytics, a análise indica que a maturidade nessas capacidades condiciona diretamente a adoção bem-sucedida de soluções de inteligência artificial no setor de TRC. Davenport (2018) argumenta que organizações com baixa maturidade analítica tendem a subutilizar ferramentas de IA, dado que a qualidade das saídas depende diretamente da qualidade e da governança dos dados de entrada.

No caso da empresa pesquisada, já existe uma base estruturada de sistemas de informação gerencial, composta por ERP, TMS, ferramentas de Business Intelligence e sistemas de telemetria. Essa infraestrutura, segundo os critérios de Laudon e Laudon (2020), corresponde a um nível intermediário de maturidade em sistemas de informação, no qual os dados são coletados e armazenados, mas ainda carecem de integração e tratamento para alimentar modelos analíticos avançados.

Por outro lado, a perspectiva apresentada pelo fornecedor de tecnologia aponta um nível mais avançado de maturidade analítica, no qual os dados são tratados como ativos de alto valor estratégico. Essa visão converge com o conceito de organização orientada por dados proposto por Davenport (2018), em que a tomada de decisão é sistematicamente baseada em evidências quantitativas processadas por algoritmos.

A comparação entre as duas perspectivas reforça a ideia de que a evolução da inteligência artificial nas organizações depende diretamente da maturidade na gestão de dados. A ausência de integração entre fontes, a falta de padronização e a baixa qualidade dos dados representam barreiras estruturais à adoção de IA, conforme evidenciado tanto pela literatura (Davenport, 2018; Hennelly et al., 2020) quanto pelos dados empíricos desta pesquisa.

Embora a empresa já possua base tecnológica sólida, a evolução para níveis mais avançados de inteligência artificial está condicionada ao fortalecimento de sua capacidade analítica. Schuh et al. (2017) descrevem essa progressão como a passagem da conectividade para a visibilidade e, posteriormente, para a capacidade preditiva, cada etapa exigindo maior integração e qualidade de dados.

Descritos os principais achados empíricos, a seção seguinte discute esses resultados com base no referencial teórico.

4.4 Discussões dos resultados

Esta seção discute os resultados à luz do referencial teórico, retomando os objetivos da pesquisa. A discussão aborda, na sequência, a caracterização da maturidade digital (OE1), os benefícios percebidos e as barreiras (OE2) e as implicações para a construção do modelo IM-TRC (OE3).

4.4.1 Maturidade Tecnológica

O setor de Transporte Rodoviário de Cargas no Brasil se encontra em um processo contínuo de transformação digital, caracterizado, conforme Westerman, Bonnet e McAfee (2014), pela crescente incorporação de tecnologias avançadas nos processos operacionais e gerenciais. No entanto, a adoção plena da Inteligência Artificial ainda enfrenta barreiras estruturais relevantes, como a baixa integração de dados, limitações na infraestrutura tecnológica, escassez de competências analíticas e desafios culturais relacionados à confiança e ao uso de sistemas automatizados. Essa condição indica que, embora a digitalização esteja avançando, a maturidade tecnológica do setor ainda é heterogênea, com empresas em diferentes estágios de evolução.

A Inteligência Artificial, quando integrada aos Sistemas de Informação Gerencial (SIG), é percebida, no caso estudado, como uma tecnologia com impacto amplo, conforme antecipado por Davenport e Harris (2007). Essa integração amplia a capacidade de análise, previsão e tomada de decisão das organizações. Nessa lógica, os SIG deixam de desempenhar um papel predominantemente operacional e reativo, passando a assumir uma função analítica, orientada por dados e suportada por modelos preditivos e prescritivos. Essa evolução permite maior eficiência operacional, redução de custos, melhor alocação de recursos e aumento do nível de serviço, fatores críticos para a competitividade no setor logístico.

Na perspectiva das estratégias competitivas de Porter (1996), a adoção da IA nos SIG é uma fonte de diferenciação e liderança em custos. A capacidade de otimizar rotas, prever demandas com maior precisão e reduzir desperdícios operacionais contribui diretamente para ganhos de eficiência, ao mesmo tempo em que permite oferecer um serviço mais confiável e personalizado ao cliente. Nessa lógica, a IA melhora a operação e fortalece o posicionamento competitivo das empresas no mercado.

Complementarmente, à luz da visão baseada em recursos (RBV), conforme Barney


(1991), a Inteligência Artificial pode ser compreendida como um recurso valioso, raro, difícil de imitar e organizado (VRIO), especialmente quando combinada com ativos intangíveis como dados proprietários, conhecimento organizacional e capacidades analíticas. Empresas que conseguem estruturar essas capacidades integradamente tendem a desenvolver vantagens competitivas sustentáveis, uma vez que a simples adoção tecnológica não é suficiente, é a capacidade de internalizar e explorar esses recursos que gera valor de longo prazo.

Entretanto, os resultados também indicam a existência de um gap entre o potencial teórico da IA e sua efetiva aplicação no TRC brasileiro. Essa lacuna pode ser compreendida segundo o *framework* TOE de Tornatzky e Fleischer (1990), que identifica fatores tecnológicos, organizacionais e ambientais como determinantes da adoção de inovações. Enquanto fornecedores de tecnologia, demonstram elevado grau de maturidade e capacidade de desenvolvimento de soluções avançadas, muitas empresas operacionais ainda enfrentam dificuldades na implementação e escalabilidade dessas tecnologias. Esse desalinhamento mostra que a maturidade tecnológica não depende apenas da disponibilidade de soluções, mas da capacidade organizacional de absorvê-las, integrá-las e utilizá-las estrategicamente.

A maturidade tecnológica no TRC deve ser compreendida como um processo evolutivo, em linha com os estágios de transformação propostos por Venkatraman (1994), no qual a Inteligência Artificial contribui para central, mas cuja efetividade depende da combinação entre tecnologia, dados, processos e cultura organizacional. As empresas que conseguirem avançar nessa jornada, alinhando seus sistemas de informação com estratégias orientadas por dados e inteligência analítica, estarão mais bem posicionadas para capturar valor e sustentar vantagens competitivas em um ambiente cada vez mais dinâmico e digital.

A triangulação dessas fontes permitiu identificar padrões de convergência relevantes entre teoria e prática (Figura 5). Observou-se, por exemplo, que tanto a empresa analisada quanto o fornecedor de tecnologia apontam a qualidade dos dados como principal gargalo para a adoção de IA, achado convergente com Davenport (2018). De modo análogo, ambos reconhecem que a transformação digital exige mudanças culturais e organizacionais, corroborando o *framework* TOE (Tornatzky; Fleischer, 1990) e a perspectiva de Westerman, Bonnet e McAfee (2014) sobre a complementaridade entre capacidade digital e liderança transformadora.

Figura 5 - Benefícios percebidos da IA nos SIG



Fonte: elaborado pelo autor com base nos dados da pesquisa.

De modo complementar, o Quadro 5 sintetiza as principais barreiras identificadas para a adoção da IA no TRC. A triangulação das evidências, conforme Yin (2015), permitiu identificar com consistência que o principal motivador para a adoção da Inteligência Artificial no setor de Transporte Rodoviário de Cargas é a busca por ganhos de eficiência operacional e redução de custos. Essa convergência entre a perspectiva do fornecedor de tecnologia e do operador logístico reforça a robustez do achado. Esse resultado indica que a adoção da IA não se dá apenas por tendência tecnológica, mas por uma necessidade concreta de otimização dos processos e aumento da competitividade.

Quadro 5 - Triangulação das Evidências sobre Maturidade Digital no TRC

Categoria de Análise	Evidência Transportadora (Operação)	Evidência Emp de Software (Tecnologia)	Evidência – Literatura	Síntese Analítica
Maturidade digital	Uso de ERP, TMS, BI e telemetria	Ecossistema em evolução, com baixa maturidade média	Laudon; Davenport	Setor em estágio intermediário
Uso de IA	Aplicações iniciais (automação e apoio)	IA ainda incipiente na maioria das empresas	Brynjolfsson	Adoção ainda limitada
Gestão de dados	Dados existentes, porém, pouco estruturados	Dados como pré-requisito crítico para IA	Davenport & Harris	Dados são fator habilitador
Integração de sistemas	Integração parcial entre sistemas	Necessidade de arquiteturas integradas	Laudon	Limitação estrutural relevante
Capacitação	Falta de skills analíticas	Déficit de profissionais no setor	Fleury et al.	Pessoas são fator crítico
Aplicações de IA	Uso administrativo predominante	Tendência para operações logísticas	Literatura de logística	Gap entre potencial e prática
Mercado Geral	Baixa capacidade interna	Dependência de soluções prontas	Estudos de transformação digital	IA como serviço (LLMs/SaaS)

Fonte: elaboração própria.

A IA pode possibilitar avanços expressivos na gestão logística ao superar limitações inerentes aos SIG tradicionais, cujas restrições analíticas foram apontadas por Laudon e Laudon (2020). Esses sistemas operam predominantemente de forma reativa, com base em dados históricos e baixa capacidade de antecipação. A incorporação de algoritmos de aprendizado de máquina e modelos preditivos permite às organizações migrar para um modelo mais proativo, no qual decisões são baseadas em previsões, simulações e análise de múltiplas variáveis em tempo real (Davenport, 2018).

Essa mudança de paradigma contribui diretamente para a redução de custos operacionais, especialmente em áreas críticas como consumo de combustível, ociosidade de ativos, falhas operacionais e retrabalho. Nesse sentido, a IA configura-se como driver econômico para o setor de TRC, cujas margens historicamente reduzidas demandam ganhos incrementais de eficiência (Pereira; Simonetto, 2018).

A eficiência operacional foi operacionalizada a partir de indicadores proxy, considerando a limitação de acesso a dados quantitativos detalhados. Assim, foram adotadas as seguintes dimensões de análise:

- i. Eficiência no uso de recursos: evidenciada pela otimização de rotas, redução do consumo de combustível e melhor alocação de ativos;
- ii. Eficiência de processos: relacionada à automação de atividades, redução de retrabalho e tempo de ciclo operacional;
- iii. Eficiência decisória: associada ao uso de dados e IA para suporte à tomada de decisão, aumentando precisão e reduzindo incertezas;
- iv. Eficiência econômica percebida: baseada na percepção dos gestores quanto à redução de custos operacionais e aumento de produtividade.

Esses indicadores foram avaliados qualitativamente a partir das entrevistas e questionários, sendo posteriormente relacionados aos níveis de maturidade do modelo IM-TRC.

No caso estudado, os benefícios percebidos vão além da eficiência operacional, incluindo melhorias na qualidade da tomada de decisão, aumento da confiabilidade das operações e maior capacidade de resposta a variações de demanda. Esses achados convergem com Richey et al. (2023), que identificam a IA como catalisadora de melhorias multidimensionais na cadeia de suprimentos, abrangendo eficiência, resiliência e capacidade preditiva.

A inteligência artificial é, assim, um mecanismo de ampliação da racionalidade limitada dos gestores, fornecendo suporte avançado à decisão e reduzindo a dependência de julgamentos puramente intuitivos. Laudon e Laudon (2020) descrevem essa evolução como a transição de

sistemas de suporte à decisão para sistemas inteligentes, nos quais algoritmos de aprendizado de máquina complementam a capacidade cognitiva humana.

A percepção de valor da IA está fortemente associada à sua capacidade de gerar retornos. Os benefícios tangíveis no curto prazo, especialmente por meio da redução de custos e aumento da eficiência, favorecem a adoção de IA em um setor historicamente pressionado por margens reduzidas, como aponta o entrevistado da empresa alfa: “apesar de não termos ainda uma redução expressiva dos custos atuais, já constatamos um ganho de 30% na produtividade, há crescimento do negócio sem aumento de custos”. Pereira e Simonetto (2018) argumentam que o retorno rápido sobre o investimento em tecnologia é determinante para a adesão de empresas de transporte, dado que a competitividade do setor exige resultados mensuráveis em prazos curtos.

Por fim, os dados sugerem que os benefícios percebidos da IA no TRC justificam sua adoção e reforçam seu papel na evolução dos Sistemas de Informação Gerencial, ao permitir a transição de sistemas descritivos para sistemas com capacidade preditiva e prescritiva (Davenport, 2018). Essa progressão é condição necessária para que o setor atinja níveis mais elevados de maturidade digital (Westerman; Bonnet; McAfee, 2014). Como pontua o entrevistado da empresa beta: “Nos próximos anos, quem conseguir estruturar dados e integrar sistemas vai ter uma vantagem competitiva muito grande”.

4.4.2 Barreiras e Desafios

Apesar do avanço da Inteligência Artificial no setor de Transporte Rodoviário de Cargas, sua adoção ainda enfrenta barreiras estruturais relevantes, especialmente relacionadas à necessidade de uma infraestrutura de dados robusta e à natureza ainda emergente dessa tecnologia no contexto brasileiro. A triangulação das evidências empíricas, conforme abordagem de Yin (2015), evidenciou que tanto a perspectiva do fornecedor de tecnologia (Empresa Beta) quanto a do operador logístico (Empresa Alfa) convergem para o entendimento de que a base de dados é o principal elemento habilitador, e, simultaneamente, uma das maiores limitações, para a efetiva implementação da IA.

A ausência de dados integrados, estruturados e confiáveis compromete a capacidade dos algoritmos de gerar previsões precisas e recomendações relevantes. Isso reduz o potencial de captura de valor da Inteligência Artificial. Esse achado reforça a tese de Westerman, Bonnet e McAfee (2014), segundo a qual a intensidade digital sem governança adequada não gera valor.

Essa limitação é particularmente crítica em empresas que ainda operam com sistemas fragmentados ou com baixa maturidade em governança de dados, o que reforça a dependência de uma arquitetura informacional sólida como pré-requisito para a evolução tecnológica.

O caráter ainda incipiente da IA no Brasil contribui para a existência de incertezas relacionadas ao retorno sobre investimento, à escalabilidade das soluções e à maturidade das aplicações disponíveis no mercado. Hennelly et al. (2020) argumentam que a incerteza tecnológica é uma das barreiras mais significativas à transformação digital em setores tradicionais, dado que a falta de casos de sucesso documentados dificulta a justificativa de investimentos perante a gestão.

Contudo, cabe notar uma nuance, pois enquanto a literatura normativa, especialmente Davenport (2018) e Brynjolfsson e McAfee (2017), sugere que a IA já produz resultados tangíveis e mensuráveis, os dados empíricos desta pesquisa indicam que, na realidade operacional do TRC brasileiro, a maior parte das aplicações ainda se encontra na fase descritiva e de Business Intelligence, com uso predominantemente reativo dos dados. Essa defasagem entre o discurso da literatura e a prática setorial sugere que os modelos de adoção tecnológica podem estar superestimando a velocidade de difusão da IA em setores com características estruturais específicas, como a fragmentação operacional e a heterogeneidade de maturidade digital que caracterizam o transporte de cargas no Brasil.

A complementaridade entre as percepções dos dois respondentes foi decisiva para a consistência dos achados, reduzindo vieses inerentes à análise de uma única fonte. Essa estratégia de triangulação é recomendada por Yin (2015) como mecanismo de aumento da validade de construto em estudos de caso, ao confrontar múltiplas perspectivas sobre o mesmo fenômeno.

Esses desafios indicam que a adoção da Inteligência Artificial no TRC não deve ser compreendida apenas como um processo tecnológico, mas como uma transformação sistêmica, conforme os estágios de Venkatraman (1994) que envolve dados, processos, pessoas e cultura organizacional. A superação dessas barreiras requer investimentos tanto em tecnologia quanto em governança de dados, integração de sistemas e desenvolvimento de competências analíticas, sendo esta última bastante destacada na entrevista com a empresa alfa.

Por fim, os resultados aqui discutidos fornecem a base empírica para o terceiro objetivo específico (OE3): a proposição do Modelo de Maturidade IM-TRC, apresentado no Capítulo 5. A heterogeneidade de estágios de maturidade observada entre as organizações reforça a necessidade de um instrumento de diagnóstico que permita classificar e orientar a evolução tecnológica no TRC. Apesar das limitações identificadas, a pesquisa demonstra que a IA possui

potencial para impulsionar a competitividade no transporte rodoviário de cargas, desde que acompanhada de investimentos em qualificação profissional, integração de dados e governança tecnológica.

5 PRODUTO TÉCNICO/TECNOLÓGICO

Este capítulo apresenta o Produto Técnico/Tecnológico (PTT) resultante desta pesquisa, que materializa o terceiro objetivo específico (OE3) que é propor um modelo de maturidade de inteligência artificial aplicável a empresas de grande porte do TRC. O produto consiste na sugestão de um Modelo de Maturidade de IA para o Transporte Rodoviário de Cargas (IM-TRC), acompanhado de um relatório executivo com recomendações.

A necessidade do IM-TRC decorre de uma lacuna identificada tanto na literatura quanto na prática do setor. Os resultados do Capítulo 4, ao atender os objetivos OE1 (caracterização da maturidade digital) e OE2 (identificação de benefícios e barreiras), evidenciaram que as empresas de TRC encontram-se em diferentes estágios de maturidade digital, sem dispor de um instrumento padronizado para avaliar seu posicionamento e orientar a evolução tecnológica. Os modelos de maturidade existentes, como o CMM (Paulk et al., 1993) e o framework de Westerman, Bonnet e McAfee (2014), abordam a maturidade digital de forma genérica, sem considerar as especificidades do transporte rodoviário de cargas.

O IM-TRC baseia-se em quatro dimensões de análise: Dados, Tecnologia, Processos e Organização. Essa arquitetura resulta da convergência entre o referencial teórico e as evidências empíricas coletadas nos capítulos anteriores, seguindo a lógica multidimensional adotada pelos principais modelos de maturidade da literatura (De Bruin et al., 2005; Schumacher et al., 2016).

O *acatech Industrie 4.0 Maturity Index* organiza a avaliação em quatro *design fields* análogos (Schuh et al., 2017), enquanto Schumacher, Erol e Sihn (2016) identificam, entre nove dimensões de maturidade industrial, os mesmos eixos centrais de tecnologia, operações, cultura e governança. No campo específico de IA, Jöhnk et al. (2021) propõem cinco fatores de AI Readiness que recobrem dados, recursos tecnológicos, conhecimento, cultura e alinhamento estratégico. Essa recorrência reforça a validade de conteúdo das dimensões adotadas no IM-TRC.

O modelo IM-TRC inclui um sistema de scoring que integra análise qualitativa e mensuração objetiva, o que permite a comparação entre empresas, áreas ou períodos distintos. Essa característica confere ao instrumento maior aplicabilidade no contexto organizacional, alinhando-se aos princípios das organizações analíticas descritos por Davenport e Harris (2017). As seções seguintes detalham cada dimensão e suas subdimensões.

]

5.1 Dimensão 1 — Dados

A Dimensão Dados constitui o alicerce do modelo IM-TRC e recebe peso de 25% na composição do índice final, em distribuição equitativa entre as quatro dimensões. A centralidade dos dados para a maturidade digital é consenso na literatura, Davenport e Harris (2007) argumentam que organizações *data-driven* superam as demais em desempenho financeiro. Jöhnk et al. (2021) corroboram ao incluir dados como fator independente de Prontidão para a IA, pois sem dados estruturados e governados não há treinamento confiável de algoritmos.

As três subdimensões do Quadro 6, qualidade, integração e disponibilidade, traduzem os requisitos mínimos para que algoritmos de IA gerem resultados confiáveis. A ausência de padrões em qualquer uma delas compromete a confiabilidade dos modelos preditivos (Davenport; Harris, 2017). Na empresa estudada, a principal lacuna identificada reside na integração entre plataformas, o que limita a capacidade analítica mesmo diante de dados individualmente consistentes.

Quadro 6 - Subdimensões da Dimensão Dados

Código	Subdimensão	Descrição	Score (0–5)*
D1	Qualidade dos dados	Dados confiáveis, sem erros, padronizados	—
D2	Integração de dados	Integração entre ERP, TMS, WMS, telemetria	—
D3	Disponibilidade de dados	Dados acessíveis em tempo real ou near real time	—

Fonte: elaborado pelo autor. *Nota: A coluna Score (0–5) representa o campo de preenchimento do instrumento de avaliação. Os valores são atribuídos pelo avaliador durante a aplicação do modelo, conforme os critérios descritos na Seção 5.5.

A relação entre qualidade dos dados e confiabilidade dos algoritmos de IA merece aprofundamento. Davenport e Harris (2007) distinguem três estágios de capacidade analítica, nos quais a progressão de análise descritiva para preditiva depende, antes de tudo, da padronização e da governança dos dados de entrada. No caso da Empresa Alfa, o entrevistado relatou que os dados existem em volume adequado, porém distribuídos em plataformas distintas, sem dicionário de dados unificado.

Essa fragmentação, que Jöhnk et al. (2021) classificam como barreira de *data readiness*, impede a construção de *datasets* integrados para treinamento de modelos de *machine learning*. Na prática do TRC, isso se manifesta quando dados de telemetria veicular, registrados em plataformas de rastreamento, não se comunicam com dados de faturamento no ERP ou com

indicadores de desempenho no BI, o que reduz a capacidade de análises preditivas como antecipação de avarias ou otimização dinâmica de rotas. A subdimensão D2 (integração) captura precisamente essa lacuna, ao passo que D3 (disponibilidade) avalia se os dados estão acessíveis em tempo real para alimentar decisões operacionais, requisito que o *acatech* Industrie 4.0 Maturity Index (Schuh et al., 2017) associa ao nível de visibilidade.

5.2 Dimensão 2 — Tecnologia

A Dimensão Tecnologia avalia a infraestrutura disponível para suportar tanto a operação logística quanto as capacidades analíticas da organização, correspondendo a 25% do índice IM-TRC, peso igual ao das demais dimensões. Essa dimensão abrange desde sistemas já consolidados no setor, como ERP, TMS, WMS e plataformas de *Business Intelligence*, até tecnologias emergentes de machine learning e IoT (Schuh et al., 2017).

O TOE framework (Tornatzky; Fleischer, 1990) já situava a tecnologia como contexto determinante para a adoção de inovações, e o *acatech* Industrie 4.0 Maturity Index (Schuh et al., 2017) posiciona Information Systems como um dos quatro campos de avaliação obrigatórios. No TRC, a infraestrutura tecnológica condiciona a capacidade de coletar dados em tempo real e de alimentar modelos preditivos, como demonstrado nos achados do Capítulo 4.

As subdimensões do Quadro 7 permitem diferenciar organizações que apenas digitalizaram processos daquelas que já utilizam IA para apoiar decisões. Venkatraman (1994) descreve essa progressão como uma escalada de cinco níveis de transformação habilitada por TI, na qual a passagem de automação localizada para redesenho de processos representa um salto qualitativo que o modelo busca capturar. Contudo, a disponibilidade tecnológica por si só não garante maturidade; é necessário que essas ferramentas estejam integradas às rotinas da organização, aspecto avaliado na dimensão seguinte.

Quadro 7 -Subdimensões da Dimensão Tecnologia

Código	Subdimensão	Descrição	Score (0–5)*
T1	Sistemas de gestão	Uso de ERP, TMS, BI integrados	—
T2	Uso de IA	Grau de uso (automação → preditivo → prescritivo)	—
T3	Infraestrutura tecnológica	Cloud, data lake, capacidade de processamento	—

Fonte: elaborado pelo autor. *Nota: A coluna Score (0–5) representa o campo de preenchimento do instrumento de avaliação. Os valores são atribuídos pelo avaliador durante a aplicação do modelo, conforme os critérios descritos na Seção 5.5.

Os achados do Capítulo 4 evidenciaram que a Empresa Alfa opera com um ecossistema tecnológico fragmentado: ERP, TMS e BI coexistem, porém com baixa integração entre si. Tornatzky e Fleischer (1990), no *framework* TOE, argumentam que o contexto tecnológico condiciona não apenas a adoção inicial, mas a velocidade de difusão da inovação na organização.

No TRC, essa difusão enfrenta uma barreira adicional: a coexistência de sistemas legados com diferentes arquiteturas e fornecedores, o que Laudon e Laudon (2020) denominam silos tecnológicos. A subdimensão T1 (sistemas de gestão) captura esse cenário ao avaliar o grau de consolidação dos sistemas, enquanto T2 (uso de IA) diferencia empresas que empregam IA de forma pontual, como *chatbots* ou automação de tarefas, daquelas que a integram aos fluxos decisórios dos SIG, atingindo o que Davenport (2018) denomina *analytics-driven management*.

A subdimensão T3 (infraestrutura), por sua vez, reflete a constatação empírica de que a ausência de recursos computacionais em nuvem ou de *data lakes* estruturados inviabiliza a implementação de modelos preditivos em escala operacional, mesmo quando a organização dispõe de dados e sistemas adequados.

5.3 Dimensão 3 — Processos

A Dimensão Processos, igualmente com peso de 25%, avalia como dados e tecnologias são incorporados às rotinas operacionais e aos fluxos de decisão. A literatura sustenta que a mera existência de infraestrutura tecnológica não garante maturidade, é preciso que as ferramentas estejam integradas aos processos de trabalho (Dijkman; Lammers; De Jong, 2015). Schumacher, Erol e Sihm (2016) incluem operações como dimensão distinta justamente porque a digitalização de processos demanda redesenho organizacional, não apenas implantação de *software*. No contexto do TRC, isso se traduz em automatização de roteirização, rastreamento preditivo e integração ponta a ponta entre embarcador, transportador e destinatário.

O Quadro 8 evidencia que a maturidade em processos depende de três eixos complementares, o uso de dados na operação diária, o nível de automação e a integração ponta a ponta. Na empresa estudada, a automação concentra-se em atividades transacionais, ao passo que decisões táticas ainda dependem de intervenção manual, padrão que Laudon e Laudon (2020) associam a estágios intermediários de maturidade em SIG. Para que esses processos

evoluam, a organização precisa reunir condições humanas e gerenciais adequadas.

Quadro 8 - Subdimensões da Dimensão Processos

Código	Subdimensão	Descrição	Score (0–5)*
P1	Uso de dados na operação	Decisões operacionais baseadas em dados	—
P2	Automação de processos	Nível de automação operacional/logística	—
P3	Integração ponta a ponta	Integração entre áreas e cadeia logística	—

Fonte: elaborado pelo autor. *Nota: A coluna Score (0–5) representa o campo de preenchimento do instrumento de avaliação. Os valores são atribuídos pelo avaliador durante a aplicação do modelo, conforme os critérios descritos na Seção 5.5.

A distância entre automação transacional e automação decisória, identificada na empresa estudada, é consistente com a tipologia de Venkatraman (1994), segundo a qual os dois primeiros níveis de transformação por TI, exploração localizada e integração interna, geram ganhos incrementais, ao passo que os níveis superiores, redesenho de processos e redefinição de escopo, exigem mudanças na lógica operacional.

No TRC, a automação de roteirização, por exemplo, representa uma conquista no nível de integração interna, porém a otimização dinâmica de rotas em tempo real, com base em dados de trânsito, clima e demanda, corresponde ao redesenho de processos, patamar que a maioria das empresas do setor ainda não alcançou.

A subdimensão P1 (uso de dados na operação) diferencia esses dois patamares, sendo que P2 pretende medir o grau de processos automatizados na cadeia. Já P3 (integração ponta a ponta) avalia se a cadeia logística opera de forma coordenada entre embarcador, transportador e destinatário, aspecto que Dijkman, Lammers e De Jong (2015) associam à maturidade em processos de negócio. Os dados do Capítulo 4 indicaram que a empresa estudada apresenta integração parcial com seus clientes, porém limitada a trocas de informação via EDI, sem retroalimentação analítica, o que posiciona a organização no nível intermediário dessa subdimensão.

5.4 Dimensão 4 — Organização

A Dimensão Organização, com peso de 25%, equivalente ao das demais dimensões, contempla os aspectos humanos e gerenciais da adoção de IA. Inclui cultura organizacional orientada a dados, governança de dados, capacitação analítica das equipes e alinhamento entre

tecnologia e estratégia de negócio. Westerman, Bonnet e McAfee (2014) demonstram que empresas com alta capacidade digital, porém baixa capacidade de liderança, obtêm resultados inferiores às que equilibram ambas as dimensões. Jöhnk et al. (2021) reforçam essa perspectiva ao identificar cultura e alinhamento estratégico como fatores críticos de prontidão para uso da IA, o que indica que a transformação digital exige mudanças organizacionais tão profundas quanto as tecnológicas.

As subdimensões do Quadro 9 reconhecem que a tecnologia isolada não sustenta a maturidade em IA. Cultura, governança e capacitação formam o substrato organizacional sem o qual os investimentos em infraestrutura geram retorno aquém do esperado (Westerman; Bonnet; McAfee, 2014), como indicam os achados do Capítulo 4.

Quadro 9 - Subdimensões da Dimensão Organização

Código	Subdimensão	Descrição	Score (0–5)*
O1	Cultura data-driven	Uso de dados na tomada de decisão	—
O2	Governança de dados	Políticas, segurança, LGPD, gestão de dados	—
O3	Capacitação analítica	Equipe com habilidades em dados/IA	—

Fonte: elaborado pelo autor. *Nota: A coluna Score (0–5) representa o campo de preenchimento do instrumento de avaliação. Os valores são atribuídos pelo avaliador durante a aplicação do modelo, conforme os critérios descritos na Seção 5.5.

Os resultados do Capítulo 4 revelaram um padrão que merece atenção pois embora os gestores entrevistados reconheçam o potencial da IA algumas barreiras ainda devem ser vencidas, como a preparação da base de dados, treinamento das pessoas e patrocínio da direção para a implantação de cultura organizacional voltada para IA. Westerman, Bonnet e McAfee (2014) classificam esse perfil como digital beginners, organizações com investimentos digitais dispersos.. A subdimensão O1 (cultura *data-driven*) captura a disposição da organização para fundamentar decisões em dados, ao passo que O2 (governança de dados) avalia a existência de políticas formais de qualidade, segurança e conformidade com a LGPD, aspectos que os entrevistados indicaram estar em estágio inicial.

A subdimensão O3 (capacitação analítica) reflete a constatação de que o déficit de profissionais com competências em ciência de dados é uma das principais barreiras identificadas, tanto na perspectiva do operador logístico quanto na do fornecedor de tecnologia. Schumacher, Erol e Sihni (2016) incluem People como dimensão separada em seu modelo, justamente por considerar que a disponibilidade de capital humano qualificado condiciona o avanço em todas as demais dimensões. No TRC brasileiro, esse déficit é agravado pela concentração de profissionais de dados nos grandes centros urbanos e nos setores de tecnologia

e financeiro, o que limita a atração de talentos para o setor logístico.

5.5 Operacionalização do Cálculo do IM-TRC

A etapa final de operacionalização do IM-TRC sugerido, consiste na consolidação dos *scores* das quatro dimensões em um índice sintético de maturidade. Como já dito, o índice procura sugerir um modelo de maturidade de inteligência artificial aplicável a empresas de grande porte do TRC. O cálculo utiliza média aritmética simples, atribuindo peso igual (25%) a cada dimensão. A escolha de pesos equitativos segue a prática dominante em modelos de maturidade, nos quais, na ausência de calibração empírica por métodos como AHP ou *Delphi*, a equiponderação é a opção metodologicamente mais defensável (De Bruin et al., 2005; Schumacher; Erol; Sihn, 2016).

A adoção de pesos iguais fundamenta-se em três argumentos. Primeiro, os modelos de maturidade mais citados na literatura, como o CMM (Paulk et al., 1993), o *Industrie 4.0 Maturity Index* (Schuh et al., 2017) e o *Smart Manufacturing Maturity Model* (Mittal et al., 2018), utilizam dimensões equiponderadas em sua formulação padrão. Segundo De Bruin et al. (2005) recomendam, a diferenciação de pesos deve ser introduzida após validação empírica robusta, pois pesos arbitrários podem distorcer o índice sem ganho interpretativo.

Terceiro, como o IM-TRC é um modelo propositivo aplicado a um número restrito de casos, a calibração estatística dos pesos, por exemplo, via *Analytic Hierarchy Process* (Saaty, 1980) ou painel *Delphi*, constitui agenda de pesquisa futura, a ser conduzida quando houver amostra suficiente para análise de sensibilidade.

O cálculo do índice geral é realizado pela média aritmética simples dos *scores* das quatro dimensões, conforme a fórmula a seguir:

$$\text{IM-TRC} = (\text{Dados} + \text{Tecnologia} + \text{Processos} + \text{Organização}) / 4$$

5.6 Classificação das empresas no modelo

A consolidação dos scores por dimensão transforma a avaliação qualitativa das subdimensões em indicadores quantitativos de maturidade, seguindo a lógica de agregação proposta por De Bruin et al. (2005). A partir do cálculo das médias em cada uma das quatro dimensões, obtém-se uma visão estruturada do nível de desenvolvimento da organização em relação à adoção de IA no TRC.

O valor obtido, contudo, não deve ser interpretado isoladamente. O quadro de

classificação de maturidade organiza os resultados em cinco níveis progressivos, do estágio inicial ao de liderança digital, permitindo contextualizar o desempenho da organização. Essa lógica segue a tradição dos modelos de maturidade por estágios (Paulk et al., 1993; De Bruin et al., 2005), nos quais cada nível descreve um conjunto coerente de capacidades. Desse modo, o IM-TRC funcionaria como um instrumento de avaliação e, simultaneamente, como ferramenta de gestão estratégica.

O Quadro 10 detalha os cinco níveis de maturidade do IM-TRC, traduzindo o conceito de maturidade em critérios operacionais que orientam o diagnóstico e a elaboração de planos de ação.

Quadro 10 - Detalhamento das dimensões e níveis do Modelo IM-TRC

Nível	Infraestrutura Tecnológica	Capacidade Analítica e Uso de IA	Governança de Dados e Gestão da Mudança	Maturidade Estratégica
<u>1 Inicial</u>	Processos manuais; sistemas isolados; sem integração entre plataformas.	Nenhum uso de IA; decisões baseadas em experiência e intuição.	Dados dispersos; sem políticas de qualidade; resistência à mudança.	Exploração localizada; tecnologia vista como custo operacional.
<u>2 Gerenciado</u>	Sistemas básicos (ERP, TMS) implantados; integração parcial.	Relatórios descritivos e BI básico; dados utilizados relativamente.	Início de estruturação de dados; DW em construção; sensibilização das equipes.	Reconhecimento do valor estratégico; iniciativas isoladas de digitalização.
<u>3 Definido</u>	Integração entre principais sistemas; telemetria e IoT operacionais.	Analytics estruturado; modelos descritivos e diagnósticos; primeiros pilotos de IA.	Governança de dados formalizada; capacitação analítica em andamento.	Estratégia digital documentada; alinhamento entre TI e operação.
<u>4 Avançado</u>	Plataformas integradas; APIs abertas; fluxo de dados em tempo real.	IA integrada aos SIGs; modelos preditivos em uso; automação de tarefas repetitivas.	Dados confiáveis e integrados; equipes capacitadas; cultura data-driven consolidada.	IA como alavanca competitiva; investimentos orientados por ROI mensurável.
<u>5 Otimizado</u>	Ecossistema digital completo; interoperabilidade plena.	Automação de decisões; IA prescritiva; orquestração algorítmica de operações.	Governança madura; experimentação contínua; aprendizado organizacional.	Modelo de negócios redesenhado pela IA; inovação sistêmica e contínua.

Fonte: elaborado pelo autor.

Na prática, a aplicação do IM-TRC segue três etapas. Na primeira, um gestor ou consultor avalia a organização em cada uma das quatro dimensões, atribuindo o nível que melhor descreve a situação atual. O diagnóstico pode ser feito por meio de entrevistas internas, análise documental ou autoavaliação da equipe de TI, seguindo a lógica de assessment proposta por De Bruin et al. (2005).

Na segunda etapa, comparam-se os níveis diagnosticados com o patamar desejado pela organização, o que permite identificar as dimensões com maior defasagem, procedimento

análogo ao *gap analysis* de Schumacher, Erol e Sihm (2016). Na terceira etapa, elabora-se um plano de ação com iniciativas prioritárias para cada dimensão, direcionando investimentos e esforços de capacitação de forma proporcional às lacunas identificadas.

A aplicação do IM-TRC à empresa estudada permitiu classificá-la predominantemente entre os Níveis 2 e 3, o que indica digitalização em estágio intermediário. A organização demonstrou solidez na infraestrutura de sistemas (ERP, TMS, telemetria), porém apresentou lacunas na integração de dados entre plataformas e na utilização de recursos analíticos avançados, padrão que Westerman, Bonnet e McAfee (2014) classificam como digital beginners. Esse diagnóstico é coerente com os resultados do OE1 (Capítulo 4) e com as barreiras identificadas no OE2.

A classificação entre os Níveis 2 e 3 merece análise desagregada por dimensão. Na dimensão Dados, a empresa obteve pontuação mais elevada em qualidade (D1), dada a consistência individual dos registros nos sistemas, porém mais baixa em integração (D2), confirmando a fragmentação entre plataformas identificada nas entrevistas.

Na dimensão Tecnologia, a presença de ERP, TMS e BI consolidados elevou o score de T1 (sistemas de gestão), ao passo que T2 (uso de IA) ficou no nível mais baixo, refletindo a ausência de ferramentas preditivas integradas aos SIG. Na dimensão Processos, a automação de rotinas transacionais sustentou P2 (automação), enquanto P3 (integração ponta a ponta) evidenciou a limitação da troca de informações com parceiros da cadeia logística.

Na dimensão Organização, O1 (cultura) e O3 (capacitação) apresentaram os menores scores, o que é coerente com a constatação de Westerman, Bonnet e McAfee (2014) de que a transformação digital bem-sucedida exige a combinação de capacidade digital e liderança, não adianta somente a vontade de fazer, é fundamental que a capacitação interna esteja preparada para apoiar e realizar as transformações. Essa análise desagregada demonstra que o IM-TRC cumpre sua função diagnóstica ao identificar assimetrias entre dimensões, permitindo que o plano de ação priorize as lacunas mais críticas.

Cabe registrar que as dimensões e os níveis do modelo foram derivados e ilustrados a partir das mesmas evidências empíricas, dado o delineamento de caso único. Essa limitação metodológica é inerente a modelos propositivos (De Bruin et al., 2005) e requer que a validação externa seja conduzida em contextos organizacionais distintos. O IM-TRC deve, portanto, ser compreendido como artefato propositivo cuja estrutura diagnóstica é replicável, mas cujos parâmetros demandam calibração futura.

Do ponto de vista prático, o IM-TRC pretende se constituir em um resultado aplicável que poderá ser utilizado por gestores e consultores do setor de TRC como instrumento de

diagnóstico e *benchmarking*. Recomenda-se que pesquisas futuras submetam o modelo a validação empírica ampliada, envolvendo: (i) aplicação em amostra diversificada de empresas de diferentes portes e regiões; e (ii) calibração dos pesos das dimensões por meio de métodos sistemáticos, como o *Analytic Hierarchy Process* (Saaty, 1980) ou painel *Delphi* (técnica estruturada para obter consenso entre especialistas sobre temas complexos ou previsões futuras), com especialistas do setor.

Adicionalmente, análises de confiabilidade interna e de validade de construto dos itens de avaliação devem integrar essa agenda de pesquisa. O conjunto dessas validações permitirá transformar o modelo sugerido em um instrumento validado, ampliando sua contribuição tanto para a academia quanto para a prática gerencial no TRC (De Bruin et al., 2005).

6 CONSIDERAÇÕES FINAIS

Esta pesquisa teve como objetivo geral analisar como a inteligência artificial pode ser integrada aos sistemas de informação gerencial no setor de transporte rodoviário de cargas. Os resultados obtidos permitiram responder à questão de pesquisa e oferecer uma visão estruturada sobre o estágio atual de maturidade tecnológica do setor, alinhando-se ao diagnóstico de que o TRC brasileiro se encontra em fase inicial de adoção de IA (Pereira; Simonetto, 2018).

Em relação aos objetivos específicos estabelecidos, os três foram plenamente atendidos ao longo do desenvolvimento da pesquisa.

O primeiro objetivo (OE1), de caracterizar a infraestrutura tecnológica e o estágio de maturidade digital, foi alcançado por meio da análise do contexto operacional da organização. Os dados revelaram que, embora a empresa possua sistemas como TMS, ERP e ferramentas de *Business Intelligence*, a maturidade digital ainda se encontra em estágio intermediário, contudo estão se preparando de forma consistente para evoluir para sistemas preditivos e com expectativa de substituir os dashboards e relatórios por consultas dinâmicas por meio de agentes de IA desenvolvidos internamente.

O segundo objetivo (OE2), de identificar benefícios percebidos e barreiras para a adoção de IA integrada aos SIG, foi atendido por meio da triangulação entre questionário e entrevista (Yin, 2015). Os principais benefícios incluem a otimização de rotas, a redução de custos logísticos e a melhoria na tomada de decisão. As barreiras abrangem a qualidade dos dados, a resistência organizacional à mudança e a incerteza quanto ao retorno sobre investimento, achados convergentes com a literatura sobre adoção de IA em logística (Richey et al., 2023).

O terceiro objetivo (OE3), de sugerir um modelo de maturidade de IA aplicável ao TRC, materializou-se no Modelo IM-TRC (Capítulo 5). O modelo organiza-se em quatro dimensões (Dados, Tecnologia, Processos e Organização), derivadas da convergência entre referencial teórico e evidências empíricas, e adota pesos iguais conforme recomendado por De Bruin et al. (2005) para modelos em fase propositiva. A aplicação ao caso estudado classificou a empresa entre os Níveis 2 e 3, diagnóstico coerente com os achados do OE1 e OE2.

Com base nos resultados, recomenda-se que empresas do setor priorizem a estruturação e governança dos dados como pré-requisito para qualquer iniciativa de IA. Na

prática, sugere-se que gestores apliquem o IM-TRC como diagnóstico inicial, identifiquem a dimensão com menor *score* e definam metas de evolução por nível ao longo de ciclos semestrais. A adoção de uma abordagem faseada, iniciando por aplicações de menor complexidade como otimização de rotas e manutenção preditiva, pode reduzir riscos e gerar resultados tangíveis que justifiquem investimentos subsequentes (Davenport, 2018). Paralelamente, o investimento em capacitação de pessoas e em cultura *data-driven* é tão relevante quanto a aquisição de tecnologia (Westerman; Bonnet; McAfee, 2014).

A principal limitação refere-se à adoção de estudo de caso único, o que restringe a generalização dos resultados (Yin, 2015). A coleta de dados baseou-se na percepção de um número limitado de respondentes, e o estágio inicial de adoção de IA na empresa limita a observação de aplicações mais avançadas. Além disso, a análise qualitativa não empregou *software* de apoio à codificação, e a entrevista com o executivo da Empresa Beta pode conter viés comercial, embora a triangulação com as demais fontes mitigue parcialmente esse risco (Eisenhardt, 1989).

Diante dessas limitações, sugere-se que pesquisas futuras ampliem o número de empresas analisadas, incorporando estudos comparativos entre organizações de diferentes portes e níveis de maturidade tecnológica. Também se recomenda a validação empírica do modelo sugerido do IM-TRC, em amostra representativa do setor, com teste de confiabilidade dos itens, análise fatorial das dimensões e calibração dos pesos por AHP ou *Delphi* (Saaty, 1980; De Bruin et al., 2005). Estudos quantitativos que mensurem com maior objetividade os impactos da IA sobre indicadores operacionais do TRC, como custo por quilômetro, lead time e índice de avarias, contribuiriam para fundamentar decisões de investimento no setor.

Em síntese, a inteligência artificial é um dos vetores de transformação das operações logísticas no TRC (Winkelhaus; Grosse, 2020). Sua adoção depende tanto de novas tecnologias quanto de capacidades internas de gestão de dados, integração de sistemas e cultura organizacional (Westerman; Bonnet; McAfee, 2014). A contribuição desta pesquisa reside na aproximação entre teoria e prática e na sugestão do Modelo IM-TRC como base para futuras iniciativas de transformação digital no setor.

Por fim, ao confrontar os achados empíricos com o discurso dominante sobre IA no TRC, observa-se uma distância significativa entre a promessa tecnológica e a realidade operacional das empresas do setor. Enquanto a literatura e o mercado destacam ganhos expressivos de eficiência e redução de custos (McKinsey, 2021), a prática revela que grande parte das transportadoras ainda enfrentam desafios básicos de integração de dados e de cultura organizacional.

Essa constatação reforça que o modelo sugerido do IM-TRC como instrumento que pretende reconhecer a multidimensionalidade da maturidade em IA: não basta investir em tecnologia se as dimensões de dados, processos e organização não acompanham a evolução (Schuh et al., 2017). O modelo sugerido oferece um caminho estruturado para que as empresas do TRC avaliem seu ponto de partida e planejem sua trajetória de forma realista, reconhecendo que a transformação digital é um processo gradual e interdependente (Venkatraman, 1994). Recomenda-se que o IM-TRC sugerido, seja testado em amostras ampliadas como passo necessário para sua validação como instrumento gerencial aplicável ao setor.

7 REFERÊNCIAS

AGÊNCIA NACIONAL DE TRANSPORTES TERRESTRES (ANTT). RNTRC em números. Brasília, 2024. Disponível em: <https://portal.antt.gov.br>. Acesso em: 15 mar. 2025.

BALLOU, Ronald H. Logística empresarial: transportes, administração de materiais e distribuição física. 5. ed. Porto Alegre: Bookman, 2006.

BARDIN, Laurence. Análise de conteúdo. São Paulo: Edições 70, 2011.

BARNEY, Jay B. Firm resources and sustained competitive advantage. *Journal of Management*, v. 17, n. 1, p. 99–120, 1991.

BECKER, Jörg; KNACKSTEDT, Ralf; PÖPPELBUSS, Jens. Developing maturity models for IT management: a procedure model and its application. *Business & Information Systems Engineering*, v. 1, n. 3, p. 213-222, 2009.

BOWERSOX, Donald J.; CLOSS, David J.; COOPER, M. Bixby. Supply chain logistics management. 4. ed. New York: McGraw-Hill, 2014.

BRODBECK, Ângela F.; HOPPEN, Norberto. Alinhamento estratégico entre os planos de negócio e de tecnologia da informação. *Revista de Administração Contemporânea*, v. 6, n. 3, p. 9–31, 2002.

BRYNJOLFSSON, Erik; MCAFEE, Andrew. Machine, platform, crowd: harnessing our digital future. New York: W. W. Norton; Company, 2017.

BRYNJOLFSSON, Erik; MCAFEE, Andrew. The second machine age: work, progress, and prosperity in a time of brilliant technologies. New York: W. W. Norton, 2014.

CAIXETA-FILHO, José Vicente; MARTINS, Ricardo S. (Org.). Gestão logística do transporte de cargas. São Paulo: Atlas, 2001.

CASTELLS, Manuel. A sociedade em rede. São Paulo: Paz e Terra, 1999.

CETIC.br. Pesquisa sobre o uso das tecnologias de informação e comunicação no Brasil: TIC Empresas 2023. São Paulo: CETIC.br, 2024. Disponível em: <https://cetic.br>. Acesso em: 10 mar. 2025.

CHRISTOPHER, Martin. Logistics & supply chain management. 5. ed. London: Pearson, 2016.

COUNCIL OF SUPPLY CHAIN MANAGEMENT PROFESSIONALS (CSCMP). CSCMP supply chain management: definitions and glossary of terms. Lombard, IL: CSCMP, 2013.

CRESWELL, John W.; CRESWELL, J. David. Research design: qualitative, quantitative, and mixed methods approaches. 5. ed. Thousand Oaks: Sage, 2018.

CULOT, Giovanna et al. Artificial intelligence in supply chain management: a systematic literature review. *Computers in Industry*, v. 162, 2024.

DAVENPORT, Thomas H. The AI advantage: how to put the artificial intelligence revolution to work. Cambridge: MIT Press, 2018.

DAVENPORT, Thomas H.; GUHA, Abhijit; GREWAL, Dhruv; BRESSGOTT, Timna. How artificial intelligence will change the future of marketing. *Journal of the Academy of Marketing Science*, v. 48, 2020.

DAVENPORT, Thomas H.; HARRIS, Jeanne G. Competing on analytics: the new science of winning. Boston: Harvard Business School Press, 2007.

DAVENPORT, Thomas H.; HARRIS, Jeanne G. Competing on analytics: updated, with a new introduction. Boston: Harvard Business Review Press, 2017.

DE BRUIN, Tonia; FREEZE, Ronald; KULKARNI, Uday; ROSEMAN, Michael. Understanding the main phases of developing a maturity assessment model. In: AUSTRALASIAN CONFERENCE ON INFORMATION SYSTEMS (ACIS), 16., 2005, Sydney. Proceedings [...]. Sydney: ACIS, 2005.

DIJKMAN, Remco; LAMMERS, Sanne; DE JONG, Ad. Properties that influence business process management maturity. *Information Systems Frontiers*, v. 18, n. 4, p. 717–734, 2015.

EISENHARDT, Kathleen M. Building theories from case study research. *Academy of Management Review*, v. 14, n. 4, p. 532–550, 1989.

FLEURY, Paulo F.; WANKE, Peter; FIGUEIREDO, Kleber F. Logística empresarial: a perspectiva brasileira. São Paulo: Atlas, 2000.

FLICK, Uwe. Introdução à pesquisa qualitativa. 3. ed. Porto Alegre: Artmed, 2009.

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. Deep learning. Cam-

GIL, Antonio Carlos. Como elaborar projetos de pesquisa. 4. ed. São Paulo: Atlas, 2002.

GRAND VIEW RESEARCH. Artificial intelligence market size, share & trends analysis report by solution, by technology, by end-use, by region, and segment forecasts, 2023–2030. San Francisco: Grand View Research, 2023.

HARARI, Yuval Noah. Sapiens: uma breve história da humanidade. Porto Alegre: L&PM, 2015.

HENNELLY, Paul et al. Rethinking supply chains in the age of digitalization. *Production Planning & Control*, v. 31, n. 2-3, p. 104–117, 2020.

JÖHNK, Jan; WESSEL, Malte; VOLKMAR, Patrick; BENLIAN, Alexander. Ready or not, AI comes: an interview study of organizational AI readiness factors. *Business & Information Systems Engineering*, v. 63, n. 1, p. 5-20, 2021.

LAUDON, Kenneth C.; LAUDON, Jane P. Sistemas de informação gerencial. 16. ed. São Paulo: Pearson, 2020.

MARINAGI, Catherine et al. The impact of Industry 4.0 technologies on key performance indicators for a resilient supply chain 4.0. *Sustainability*, v. 15, n. 6, p. 5185, 2023.

MCKINSEY & COMPANY. Artificial intelligence in supply chain. McKinsey Global Institute, 2019.

MCKINSEY & COMPANY. Succeeding in the AI supply-chain revolution. McKinsey Global Institute, 2021.

MITTAL, Sameer; KHAN, Muztoba Ahmad; ROMERO, David; WUEST, Thorsten. A critical review of *smart* manufacturing & Industry 4.0 maturity models: implications for small and medium-sized enterprises (SMEs). *Journal of Manufacturing Systems*, v. 49, p. 194-214, 2018.

NOLAN, Richard L. Managing the computer resource: a stage hypothesis. *Communications of the ACM*, v. 16, n. 7, p. 399–405, 1973.

NOVAES, Antonio Galvão. Logística e gerenciamento da cadeia de distribuição: estratégia, operação e avaliação. 3. ed. Rio de Janeiro: Elsevier, 2007.

O'BRIEN, James A.; MARAKAS, George M. Administração de sistemas de informação. 15. ed. Porto Alegre: AMGH, 2013.

PAULK, Mark C. et al. Capability Maturity Model for Software, Version 1.1. Pittsburgh: Software Engineering Institute, Carnegie Mellon University, 1993.

Pearson, 2021.

PEREIRA, Adriana S.; SIMONETTO, Eugênio O. Logística 4.0: desafios e oportunidades no contexto da Indústria 4.0. *Revista de Administração da UFSM*, Santa Maria, v. 11, n. 5, p. 1378-1394, 2018.

PORTER, Michael E. *Competitive advantage: creating and sustaining superior performance*. New York: Free Press, 1985.

PORTER, Michael E. What is strategy? *Harvard Business Review*, v. 74, n. 6, p. 61-78, 1996.

RADIOVOJEVIĆ, Goran; MILOSAVLJEVIĆ, Srdjan. *The stages of logistics development*. Proceedings of the International Conference on Logistics & Industrial Engineering (LOGIC), Belgrade, p. 284–292, 2019.

REUTERS. Microsoft to invest in AI infrastructure in Brazil. Reuters, 2024.

RICHEY, Robert G. et al. Artificial intelligence in logistics and supply chain management: a primer and *roadmap* for research. *Journal of Business Logistics*, v. 44, n. 4, p. 532–549, 2023.

RUSSELL, Stuart; NORVIG, Peter. *Artificial intelligence: a modern approach*. 4. ed.

SAATY, Thomas L. *The analytic hierarchy process: planning, priority setting, resource allocation*. New York: McGraw-Hill, 1980.

SCHUH, Günther; ANDERL, Reiner; GAUSEMEIER, Jürgen; TEN HOMPEL, Michael; WAHLSTER, Wolfgang. *Industrie 4.0 maturity index: managing the digital transformation of companies*. Munich: *acatech*, 2017.

SCHUMACHER, Andreas; EROL, Selim; SIHN, Wilfried. A maturity model for assessing Industry 4.0 readiness and maturity of manufacturing enterprises. *Procedia CIRP*, v. 52, p. 161-166, 2016.

SCHWAB, Klaus. A quarta revolução industrial. São Paulo: Edipro, 2016. SENADO FEDERAL (BRASIL). Projeto de Lei nº 2238/2023. Brasília, 2023.

SYED, Rehan et al. Digital transformation and business process management: trends and *insights* from a systematic literature review. In: BUSINESS PROCESS MANAGEMENT WORKSHOPS, 2020. Proceedings [. . .]. Cham: Springer, 2020. p. 3-17.

TORNATZKY, Louis G.; FLEISCHER, Mitchell. The processes of technological innovation. Lexington: Lexington Books, 1990.

TSOLAKIS, Naoum et al. Artificial intelligence and blockchain implementation in supply chains: a pathway to sustainability and data monetisation? *Annals of Operations Research*, v. 327, p. 1–42, 2023.

TURBAN, Efraim; VOLONINO, Linda; WOOD, Gregory. Information technology for management: digital strategies for *insight*, action, and sustainable performance. 10. ed. Hoboken: Wiley, 2015.

VENKATRAMAN, N. IT-enabled business transformation: from automation to business scope redefinition. *Sloan Management Review*, v. 35, n. 2, p. 73-87, 1994.

VERGARA, Sylvia Constant. Projetos e relatórios de pesquisa em administração. 16. ed. São Paulo: Atlas, 2016.

WEBSTER, Jane; WATSON, Richard T. Analyzing the past to prepare for the future: writing a literature review. *MIS Quarterly*, v. 26, n. 2, p. xiii-xxiii, 2002.

WESTERMAN, George; BONNET, Didier; MCAFEE, Andrew. Leading digital: turning technology into business transformation. Boston: Harvard Business Review Press, 2014.

WINKELHAUS, Sven; GROSSE, Eric H. Logistics 4.0: a systematic review towards a new logistics system. *International Journal of Production Research*, v. 58, n. 1, p. 18–43, 2020.

YIN, Robert K. Estudo de caso: planejamento e métodos. 5. ed. Porto Alegre: Bookman, 2015.

8 APÊNDICE A – QUESTIONÁRIO DE PESQUISA E TCLE

TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO (TCLE)

Você está sendo convidado(a) a participar de uma pesquisa acadêmica vinculada ao Programa de Mestrado Profissional em Gestão de Negócios da Fundação Instituto de Administração (FIA). O objetivo é analisar como a adoção de recursos de Inteligência Artificial em Sistemas de Informação Gerencial impacta a eficiência operacional e a tomada de decisão no transporte rodoviário de cargas. Sua participação é voluntária e suas respostas serão utilizadas exclusivamente para fins acadêmicos, sendo garantido o anonimato da empresa e do respondente. Você pode desistir a qualquer momento sem prejuízo. Ao responder este questionário, você declara estar ciente e de acordo com os termos acima.

Questionário de Pesquisa - “Como a adoção de recursos de Inteligência Artificial em Sistemas de Informação Gerencial impacta a eficiência operacional e a tomada de decisão gerencial em uma empresa do Transporte Rodoviário de Cargas?”

QUESTIONÁRIO DE PESQUISA



MESTRADO
PROFISSIONAL

Questionário de Pesquisa - "Como a adoção de recursos de Inteligência

Artificial em Sistemas de Informação Gerencial impacta a eficiência operacional e a tomada de decisão gerencial em uma empresa do Transporte Rodoviário de Cargas?"

BLOCO 1 - IDENTIFICAÇÃO ORGANIZACIONAL

1.1 Razão Social: _____

1.2 Nome Fantasia: _____

1.3 Cidade / UF: _____

1.4 Segmento de atuação no transporte: _____

1.5 Principais tipos de carga transportada: _____

1.6 Número aproximado de colaboradores: _____

1.7 Número de filiais: _____

BLOCO 2 – PERFIL DO RESPONDENTE

2.1 Cargo: _____

2.2 Área de atuação: _____

2.3 Nível de atuação:

() Estratégico ☒ Tático ☒ Operacional

2.4 Tempo de atuação na empresa:

() Até 2 anos ☒ 3–5 anos ☒ 6–10 anos ☒ Mais de 10 anos

BLOCO 3 – CONTEXTO COMPETITIVO E PROCESSO DECISÓRIO

3.1 O mercado em que a empresa atua pode ser considerado altamente competitivo?

() Discordo totalmente

() Discordo parcialmente

() Neutro

() Concordo parcialmente

() Concordo totalmente



MESTRADO
PROFISSIONAL

3.2 As decisões estratégicas da empresa são formalizadas e baseadas em informações estruturadas?

- ☐ Nunca
☐ Raramente
☐ Às vezes
☐ Frequentemente
☐ Sempre

3.3 Como ocorre o processo de tomada de decisão estratégica na empresa?

3.4 Quais são hoje os principais desafios gerenciais enfrentados pela empresa?

BLOCO 4 – USO DE SISTEMAS DE INFORMAÇÃO GERENCIAL (SIG)
4.1 Indique os principais sistemas utilizados pela empresa:

Sistema	Utiliza
ERP	☐ Sim ☐ Não
TMS	☐ Sim ☐ Não
WMS	☐ Sim ☐ Não
BI / Analytics	☐ Sim ☐ Não
Telemetria / Rastreamento	☐ Sim ☐ Não
CRM	☒ Sim ☐ Não
Outros	_____

4.2 Os sistemas atuais atendem às necessidades gerenciais da empresa?

- ☐ Discordo totalmente
☐ Discordo parcialmente
☐ Neutro
☐ Concordo parcialmente
☐ Concordo totalmente

4.3 As informações geradas pelos sistemas são confiáveis para a tomada de decisão?

- ☐ Nunca
☐ Raramente
☐ Às vezes
☐ Frequentemente
☐ Sempre



MESTRADO
PROFISSIONAL

5.4 A empresa já realizou investimentos em soluções de IA ou analítica avançada?

☐ Sim

☐ Não

5.5 A adoção de IA tem potencial para melhorar a qualidade das decisões gerenciais?

☐ Discordo totalmente

☐ Discordo parcialmente

☐ Neutro

☐ Concordo parcialmente

☐ Concordo totalmente

BLOCO 6 – IMPACTOS PERCEBIDOS NA TOMADA DE DECISÃO

6.1 O uso de sistemas com recursos analíticos avançados contribui para maior agilidade nas decisões?

☐ Nunca

☐ Raramente

☐ Às vezes

☐ Frequentemente

☐ Sempre

6.2 Houve melhoria perceptível na eficiência operacional após a adoção dessas tecnologias?

☐ Não houve

☐ Houve pouca melhoria

☐ Houve melhoria moderada

☐ Houve melhoria significativa

6.3 Já foram observados resultados práticos mensuráveis?

☐ Sim

☐ Não

Se sim, quais?



MESTRADO
PROFISSIONAL

BLOCO 7 – DESAFIOS, EXPECTATIVAS E FUTURO

7.1 Quais são os principais desafios para a adoção de IA na empresa?

(resposta aberta)

7.2 Quais benefícios estratégicos a empresa espera alcançar com o uso de IA?

7.3 Como você enxerga o impacto da IA no futuro do transporte rodoviário de cargas?

BLOCO 8 – CONSIDERAÇÕES FINAIS

9 APÊNDICE B – ROTEIRO DE ENTREVISTA SEMIESTRUTURADA EMPRESA BETA



MESTRADO
PROFISSIONAL

ROTEIRO DE ENTREVISTA – empresa Beta

Pesquisa de Mestrado – FIA

Tema: Tendências de Inteligência Artificial no Transporte Rodoviário de Cargas

Entrevistado: Diretor – empresa Beta

Duração sugerida: 60-90 minutos

1 BLOCO – CONTEXTO E VISÃO SETORIAL

Objetivo: entender a leitura estratégica da empresa sobre o TRC

1. Como a empresa enxerga o estágio atual de digitalização do TRC brasileiro?
2. O setor ainda está em fase descritiva (BI) ou já avançou para preditiva e prescritiva?
3. Quais são hoje os principais gargalos tecnológicos das transportadoras?
4. Existe diferença clara de maturidade entre grandes, médias e pequenas empresas?
5. O que mais impede o avanço da IA no setor: cultura, custo, dados ou liderança?

2 BLOCO – APLICAÇÕES ATUAIS DE IA NO ECOSISTEMA LOGÍSTICO

Objetivo: mapear aplicações reais

1. Quais soluções da empresa já utilizam IA embarcada?
2. A IA é usada mais em:
 - o Roteirização?
 - o Gestão de risco?
 - o Precificação?
 - o Matching carga-motorista?
 - o Torre de controle?
3. Há uso de IA generativa integrada aos TMS?
4. Como os clientes reagem ao uso de modelos automatizados?
5. Quais aplicações têm gerado ROI mais rápido?

3 BLOCO – DADOS, INFRAESTRUTURA E ARQUITETURA

Objetivo: entender o “pré-requisito” para IA

1. Qual o maior desafio técnico para IA funcionar bem no TRC?
2. A qualidade dos dados das transportadoras é suficiente?



MESTRADO
PROFISSIONAL

3. O setor já trabalha com Data Lakes estruturados?
4. Existe integração efetiva entre:
 - o TMS
 - o ERP
 - o Telemetria
 - o Gerenciadoras de risco
 - o SEFAZ
5. O TRC brasileiro está preparado para IA prescritiva?

4 BLOCO – TENDÊNCIAS DE IA NOS PRÓXIMOS 5 ANOS

Objetivo: enriquecer sua seção "Perspectivas Futuras"

1. Quais tecnologias vão dominar o TRC até 2030?
2. Acredita em:
 - o Torres de controle autônomas?
 - o Pricing dinâmico massivo?
 - o Manutenção 100% preditiva?
 - o Copilotos digitais para operadores?
3. IA substituirá decisões humanas ou atuará como suporte?
4. O TRC caminhará para modelo de "orquestração algorítmica"?

5 BLOCO – MODELO DE MATURIDADE DO SETOR

Aqui você conecta com seu produto técnico.

1. Como você classificaria a maturidade média do TRC em IA (0 a 5)?
2. Quais dimensões definem maturidade:
 - o Dados?
 - o Cultura?
 - o Integração?
 - o Liderança?
3. Quais empresas são referência?
4. Pequenas transportadoras conseguirão acessar IA via modelo SaaS?

MESTRADO
PROFISSIONAL**6 BLOCO – IMPACTO COMPETITIVO E ESTRATÉGICO****Conexão com Porter e RBV**

1. A IA será diferencial competitivo ou commodity?
2. Empresas que não adotarem IA perderão mercado?
3. A IA pode criar barreiras de entrada no TRC?
4. Plataformas integradoras tendem a concentrar inteligência do setor?
5. Existe risco de dependência tecnológica?

7 BLOCO – REGULAÇÃO, ÉTICA E RISCOS

1. Como a IA impacta compliance no TRC?
2. Há riscos de viés em modelos de risco/roteirização?
3. Como lidar com LGPD e dados sensíveis?
4. O Brasil está preparado no que se refere a leis e regulações?

8 BLOCO – IA GENERATIVA E COPILOTOS DIGITAIS

1. Vocês já integram LLMs aos sistemas logísticos?
2. É possível um operador conversar com o TMS?
3. A IA pode gerar automaticamente:
 - o Relatórios gerenciais?
 - o Análises de performance?
 - o Simulações de cenário?
4. A IA generativa é hype ou transformação estrutural?

9 BLOCO – VISÃO EXECUTIVA FINAL**Perguntas abertas estratégicas:**

1. Se você tivesse que aconselhar uma transportadora hoje, qual seria o primeiro passo em IA?
2. Qual será o maior erro das empresas nos próximos 3 anos?
3. O que diferencia líderes digitais no TRC?
4. Qual o futuro do TRC na era da IA?