

**UNIVERSIDADE DO VALE DO RIO DOS SINOS - UNISINOS**  
**UNIDADE ACADÊMICA DE PESQUISA E PÓS-GRADUAÇÃO**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ADMINISTRAÇÃO**  
**NÍVEL MESTRADO**

**BEATRICE ARANGUEZ**

**DECISÕES INTELIGENTES EM CIDADES COMPLEXAS: INTEGRAÇÃO DE**  
***MACHINE LEARNING* EM SISTEMAS DE SUPORTE À DECISÃO**

Dissertação apresentada como requisito para obtenção do título de Mestre em Administração, pelo Programa de Pós-Graduação em Administração da Universidade do Vale do Rio dos Sinos (UNISINOS).

Orientador(a): Prof. Dr. Jorge Verschoore

Co-Orientador(a): Prof. Dr. Bruno Anicet Bittencourt

**Porto Alegre**

**2025**

BEATRICE ARANGUEZ

**DECISÕES INTELIGENTES EM CIDADES COMPLEXAS: INTEGRAÇÃO DE  
*MACHINE LEARNING* EM SISTEMAS DE SUPORTE À DECISÃO**

Dissertação apresentada como requisito para obtenção do título de Mestre em Administração, pelo Programa de Pós-Graduação em Administração da Universidade do Vale do Rio dos Sinos (UNISINOS).

Orientador(a): Prof. Dr. Jorge Verschoore  
Co-Orientador(a): Prof. Dr. Bruno Anicet Bittencourt

Porto Alegre

2025

A662d

Aranguez, Beatrice.

Decisões inteligentes em cidades complexas: integração de Machine Learning em sistemas de suporte à decisão / Beatrice Aranguez. – 2025.

90 f. : il. ; 30 cm.

Dissertação (mestrado) – Universidade do Vale do Rio dos Sinos, Programa de Pós-Graduação em Administração, 2025.

“Orientador: Prof. Dr. Jorge Verschoore

Co-Orientador: Prof. Dr. Bruno Anicet Bittencourt”.

1. Logística urbana. 2. Aprendizado de máquina. 3. Sistemas de suporte à decisão. 4. Mobilidade urbana. I. Título.

CDU 658.7

Dados Internacionais de Catalogação na Publicação (CIP)  
(Bibliotecária: Amanda Schuster Ditbenner – CRB 10/2517)

BEATRICE ARANGUEZ

**DECISÕES INTELIGENTES EM CIDADES COMPLEXAS: INTEGRAÇÃO DE  
*MACHINE LEARNING* EM SISTEMAS DE SUPORTE À DECISÃO**

Dissertação apresentada como requisito para obtenção do título de Mestre em Administração, pelo Programa de Pós-Graduação em Administração da Universidade do Vale do Rio dos Sinos (UNISINOS).

Orientador(a): Prof. Dr. Jorge Verschoore

Co-Orientador(a): Prof. Dr. Bruno Anicet Bittencourt

Aprovado em 24/09/2025

**BANCA EXAMINADORA**

---

Prof. Dr. Jorge Verschoore – Unisinos

---

Prof. Dr. Bruno Anicet Bittencourt – Unisinos

---

Prof. Dr. Magnus dos Reis – Unisinos

---

Prof. Dra. Amorolinda Iara da Costa Zanela Klein – FGV

---

Prof. Dr. Rodrigo da Rosa Righi – Unisinos

## **AGRADECIMENTOS À CAPES**

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

## AGRADECIMENTOS

Agosto de 2025 marcou a entrega da minha dissertação, um dos momentos mais significativos da minha trajetória acadêmica e pessoal.

Agradeço ao meu marido, Diógenes, presença constante e parte essencial da minha força. Nos conhecemos em meio ao trabalho, entre desafios e olhares que não acreditavam em nós. Muitos apostaram contra, mas seguimos lado a lado, firmes, escolhendo permanecer. O caminho foi longo e exigente, mas cada passo nos trouxe até aqui.

À minha mãe, Ana Cristina, por ser minha maior fã, e a minha irmã, Bianca, por estar ao meu lado em tantas etapas da vida.

Ao meu pai Antônio, que mesmo após sua partida continua presente em minhas lembranças, trazendo à tona histórias engraçadas que até hoje me fazem sorrir.

Aos meus avós, Maria e Noé, que representam a base da minha história e cujos valores seguem como guia em minha vida.

À minha tia Ângela, por ter me acolhido quando mais precisei.

Aos meus sogros, Marilei e Tadeu, que me acolheram como uma filha e celebraram cada conquista dessa jornada.

Aos meus sobrinhos, por compreenderem que muitas vezes a tia estava cansada demais para brincar.

Ao meu orientador, professor Jorge Verschoore, pela orientação firme e ao mesmo tempo sensível, por me guiar com paciência e clareza em cada etapa da pesquisa.

Ao meu coorientador, professor Bruno Bittencourt, pela disponibilidade, atenção e pelas valiosas contribuições que enriqueceram este trabalho.

Aos participantes da pesquisa, que gentilmente dedicaram seu tempo e compartilharam suas percepções, contribuindo de forma fundamental para a construção deste trabalho.

À banca examinadora, pelo aceite em avaliar esta dissertação e pelas contribuições que certamente fortalecerão os resultados aqui apresentados.

Por fim, a todos que cruzaram meu caminho, agradeço também por despertarem em mim um cinismo peculiar, que se tornou parte da forma como enxergo o mundo.

“I disdained to argue, and entrenched my curiosity behind a rampart of pretended indifference.” (Christie, Poirot Investigates, 1924)

## RESUMO

Nas cidades contemporâneas, a logística urbana representa um desafio crítico diante da crescente demanda por entregas rápidas, do congestionamento viário e da pressão por práticas sustentáveis. Esse ambiente apresenta fragmentação de dados, ausência de padronização nas bases disponíveis e baixa maturidade digital das instituições públicas. Paralelamente, técnicas de *Machine Learning* (ML) oferecem novas possibilidades para transformar informações dispersas em conhecimento útil, embora ainda exista uma distância entre o potencial técnico e a prática cotidiana da gestão urbana. Com esse contexto, a pesquisa teve como propósito desenvolver um framework teórico voltado à integração de ML a Sistemas de Suporte à Decisão (SSD), com foco em apoiar gestores públicos em processos decisórios ligados à logística urbana. A investigação seguiu a metodologia *Design Science Research* (DSR), combinando revisão sistemática da literatura, entrevistas em profundidade, aplicação de questionário estruturado e entrevistas de validação. Dez especialistas das áreas de Inteligência Artificial, inovação e gestão pública participaram das etapas, o que possibilitou análise triangulada entre dados qualitativos e quantitativos. Os resultados demonstraram a viabilidade de um modelo cíclico composto por oito etapas, capaz de transformar dados urbanos em decisões fundamentadas. O estudo também identificou barreiras institucionais, critérios de maturidade digital e estratégias para aproximar dados, algoritmos e práticas de gestão, reforçando a aplicabilidade prática do modelo para o setor público. A contribuição central do framework está na articulação entre dimensões técnicas, institucionais e operacionais da logística urbana, oferecendo base conceitual consistente e adaptável a diferentes realidades. Do ponto de vista prático, o modelo apresenta diretrizes claras para gestores que enfrentam a fragmentação de dados e a urgência por decisões mais ágeis. Entre as limitações, destacam-se a ausência de testes em cenários reais e o número restrito de participantes, aspectos que abrem espaço para investigações futuras em outros contextos institucionais e territoriais.

**Palavras-chave:** Logística Urbana; Aprendizado de Máquina; Sistemas de Suporte à Decisão; Mobilidade Urbana.



## ABSTRACT

In contemporary cities, urban logistics represents a critical challenge due to the growing demand for rapid deliveries, traffic congestion, and increasing pressure for sustainable practices. This environment reveals fragmented data, lack of standardization across available databases, and limited digital maturity within public institutions. At the same time, *Machine Learning* (ML) techniques provide new possibilities for transforming dispersed information into actionable knowledge, although a considerable gap remains between technical potential and practical implementation in urban management. Within this context, the research aimed to develop a theoretical framework that integrates ML into Decision Support Systems (DSS), with the purpose of supporting public managers in decision-making processes related to urban logistics. The study adopted the Design Science Research (DSR) methodology, combining systematic literature review, in-depth interviews, a structured questionnaire, and validation interviews. Ten specialists from the fields of Artificial Intelligence, innovation, and public management participated in the research, enabling triangulated analysis between qualitative and quantitative data. The findings demonstrated the feasibility of an eight-stage cyclical model designed to transform urban data into well-founded decisions. The study also identified institutional barriers, digital maturity requirements, and strategies for bridging data, algorithms, and management practices, reinforcing the practical applicability of the model to the public sector. The framework contributes to the literature by articulating technical, institutional, and operational dimensions of urban logistics, offering a consistent and adaptable conceptual basis. From a practical perspective, it provides clear guidelines for public managers facing fragmented data and the urgency for more agile and evidence-based decisions. As limitations, the research highlights the absence of real-world testing and the restricted sample size, opening opportunities for further studies in different institutional and territorial contexts.

**Keywords:** Urban Logistics; Machine Learning; Decision Support Systems; Urban Mobility.

## LISTA DE FIGURAS

|                                                                                            |    |
|--------------------------------------------------------------------------------------------|----|
| Figura 1 - Relação entre Desafios, Tecnologias Emergentes e Inovações na Logística Urbana. | 24 |
| Figura 2 - Hierarquia Clássica de Aprendizado de Máquina.....                              | 27 |
| Figura 3 - Integração de ML e Sistemas de Suporte à Decisão na Logística Urbana. ....      | 31 |
| Figura 4 - Ciclo Iterativo da <i>Design Science Research</i> .....                         | 33 |
| Figura 5 – Percurso Metodológico. ....                                                     | 36 |
| Figura 6 - Framework após contribuições da etapa 1.....                                    | 63 |
| Figura 7 - Framework Ajustado após Etapa 2.....                                            | 67 |
| Figura 8 - Framework Final para Integração de ML em SSD na Logística Urbana. ....          | 73 |

## LISTA DE QUADROS

|                                                                                           |    |
|-------------------------------------------------------------------------------------------|----|
| Quadro 1 – Lacunas identificadas na literatura .....                                      | 39 |
| Quadro 2 – Etapas de desenvolvimento do framework.....                                    | 41 |
| Quadro 3 – Perfil dos entrevistado .....                                                  | 43 |
| Quadro 4 – Perfil dos participantes das entrevistas de validação do framework.....        | 47 |
| Quadro 5 – Identificação de problemas urbanos .....                                       | 49 |
| Quadro 6 – Maturidade institucional.....                                                  | 49 |
| Quadro 7 – Compreensão e mapeamento de dados.....                                         | 50 |
| Quadro 8 – Preparação e organização dos dados .....                                       | 50 |
| Quadro 9 – Desenvolvimento do modelo preditivo .....                                      | 51 |
| Quadro 10 – Integração com SSD .....                                                      | 51 |
| Quadro 11 –Adoção, capacitação e ajustes .....                                            | 51 |
| Quadro 12 –Validação e retroalimentação .....                                             | 52 |
| Quadro 13 – Respostas por participante.....                                               | 52 |
| Quadro 14 – Bibliotecas Python utilizadas na análise estatística.....                     | 54 |
| Quadro 15 – Falas sobre início do ciclo e maturidade institucional .....                  | 57 |
| Quadro 16 – Falas sobre dados e infraestrutura .....                                      | 57 |
| Quadro 17 – Falas sobre modelagem preditivo.....                                          | 57 |
| Quadro 18 – Falas sobre visualização e SSD.....                                           | 58 |
| Quadro 19 – Falas sobre capacitação e engajamento .....                                   | 58 |
| Quadro 20 – Falas sobre impacto e revisão contínua.....                                   | 58 |
| Quadro 21 – Contribuições dos participantes por eixo temático do framework.....           | 62 |
| Quadro 22 – Modificações realizadas no framework a partir da análise do questionário..... | 66 |
| Quadro 23 – Síntese das etapas do framework com respectivas adaptações empíricas.....     | 69 |

## **LISTA DE TABELAS**

|                                                         |    |
|---------------------------------------------------------|----|
| Tabela 1 – Resultados consolidados do questionário..... | 55 |
|---------------------------------------------------------|----|

## LISTA DE SIGLAS

|         |                                                        |
|---------|--------------------------------------------------------|
| ML      | <i>Machine Learning</i>                                |
| SSD     | Sistemas de Suporte à decisão                          |
| DSR     | <i>Design Science Research</i>                         |
| DTS-GRU | <i>Dynamic Tabu Search-based Gated Recurrent Units</i> |
| SUTI    | <i>Sustainable Urban Transport Index</i>               |
| VRP     | <i>Vehicle Routing Problem</i>                         |
| IOT     | Internet das Coisas                                    |
| IA      | Inteligência Artificial                                |

## SUMÁRIO

|                                                                                           |           |
|-------------------------------------------------------------------------------------------|-----------|
| <b>1 INTRODUÇÃO .....</b>                                                                 | <b>16</b> |
| 1.1 OBJETIVOS.....                                                                        | 19        |
| 1.2 OBJETIVOS ESPECÍFICOS.....                                                            | 19        |
| 1.3 JUSTIFICATIVA.....                                                                    | 20        |
| 1.4 ESTRUTURA DA DISSERTAÇÃO .....                                                        | 21        |
| <b>2 FUNDAMENTAÇÃO TEÓRICA .....</b>                                                      | <b>22</b> |
| 2.1 LOGÍSTICA URBANA.....                                                                 | 22        |
| 2.2 <i>MACHINE LEARNING</i> NA LOGÍSTICA URBANA .....                                     | 26        |
| 2.3 SISTEMAS DE SUPORTE À DECISÃO NA LOGÍSTICA URBANA .....                               | 28        |
| <b>3 METODOLOGIA .....</b>                                                                | <b>33</b> |
| 3.1 FASE DE CONSCIENTIZAÇÃO DO PROBLEMA.....                                              | 37        |
| 3.2 FASE DE SUGESTÃO .....                                                                | 38        |
| 3.3 A FASE DE DESENVOLVIMENTO DO FRAMEWORK.....                                           | 40        |
| <b>3.3.1 Entrevistas em profundidade como suporte à construção do framework .....</b>     | <b>41</b> |
| <b>3.3.2 Questionário estruturado como mecanismo de validação parcial do framework...</b> | <b>44</b> |
| 3.4 FASE DE AVALIAÇÃO DO FRAMEWORK .....                                                  | 46        |
| <b>4 RESULTADOS.....</b>                                                                  | <b>48</b> |
| 4.1 RESULTADOS DAS ENTREVISTAS COMO SUPORTE À CONSTRUÇÃO DO FRAMEWORK.....                | 48        |
| 4.2 RESULTADOS DO QUESTIONÁRIO NA ETAPA DE AVALIAÇÃO DO FRAMEWORK.....                    | 53        |
| 4.3 RESULTADOS DAS ENTREVISTAS PARA A VALIDAÇÃO DO FRAMEWORK ...                          | 56        |
| <b>5 ANÁLISE DOS RESULTADOS.....</b>                                                      | <b>59</b> |
| 5.1 ANÁLISE DAS ENTREVISTAS COMO SUPORTE À CONSTRUÇÃO DO FRAMEWORK.....                   | 59        |
| 5.2 ANÁLISE DOS QUESTIONÁRIOS NA ETAPA DE AVALIAÇÃO DO FRAMEWORK .....                    | 63        |
| 5.3 ANÁLISE DAS ENTREVISTAS PARA VALIDAÇÃO DO FRAMEWORK.....                              | 67        |
| 5.4 FRAMEWORK FINAL .....                                                                 | 70        |
| <b>6 CONSIDERAÇÕES FINAIS .....</b>                                                       | <b>75</b> |

|                                       |           |
|---------------------------------------|-----------|
| 6.1 CONTRIBUIÇÕES GERENCIAIS .....    | 76        |
| 6.2 CONTRIBUIÇÕES TEÓRICAS .....      | 77        |
| 6.3 LIMITAÇÕES DA PESQUISA.....       | 78        |
| 6.4 SUGESTÕES DE ESTUDOS FUTUROS..... | 78        |
| <b>REFERÊNCIAS .....</b>              | <b>80</b> |
| <b>APÊNDICE A .....</b>               | <b>87</b> |
| <b>APÊNDICE B .....</b>               | <b>88</b> |
| <b>APÊNDICE C .....</b>               | <b>90</b> |
| <b>APÊNDICE D .....</b>               | <b>92</b> |

## 1 INTRODUÇÃO

A crescente complexidade das cidades, impulsionada pelo adensamento populacional, pela transformação digital e por demandas crescentes de sustentabilidade, tem pressionado gestores públicos a buscar soluções mais inteligentes e adaptáveis (Anthony Jnr, 2025; Albino, Berardi & Dangelico, 2015). Questões como a entrega de mercadorias, o fluxo intenso de veículos e a ocupação desordenada do espaço urbano revelam um cenário marcado por sobrecarga, ineficiência e impactos ambientais significativos (Herath & Mittal, 2022; Dong et al., 2021).

Diante desse panorama, a logística urbana demanda respostas cada vez mais rápidas e assertivas, baseadas no uso estratégico de tecnologias e dados para apoiar a tomada de decisão (Wang & Ren, 2025; Xu et al., 2025). Paralelamente, o avanço das tecnologias baseadas em dados tem redefinido os processos decisórios nas esferas pública e privada, ampliando a capacidade analítica de gestores urbanos (Chaudhary et al., 2025), entre essas tecnologias, se destacam as técnicas de *machine learning* (ML) aplicadas em conjunto com sistemas de suporte à decisão (SSD), que oferecem soluções promissoras para contextos logísticos complexos e voláteis, característicos dos grandes centros urbanos (Herath & Mittal, 2022). Apesar do avanço técnico, a incorporação dessas ferramentas no setor público ainda é incipiente, dificultada por obstáculos como a fragmentação de dados, a falta de interoperabilidade entre sistemas e a ausência de frameworks que orientem sua aplicação prática em diferentes níveis de governo (Anthony Jnr, 2025).

A integração de *machine learning* com sistemas de suporte à decisão tem se consolidado como uma abordagem eficaz para apoiar a tomada de decisão em ambientes urbanos, de acordo com Carvalho (2022), sistemas inteligentes voltados ao setor de transportes podem integrar informações em tempo real com algoritmos preditivos para otimizar o fluxo logístico.

Cheng & Pan (2021) também enfatizam que o uso de big data aliado a SSDs contribui significativamente para decisões mais ágeis e eficazes em cenários de alta complexidade, como a definição de localizações estratégicas e a alocação de recursos. No entanto, os desafios institucionais e técnicos ainda dificultam sua ampla adoção, sobretudo em contextos públicos (Reznichenko, Uglickich & Nagy, 2024).

Estudos recentes demonstram que modelos preditivos baseados em *machine learning* podem alcançar resultados promissores na gestão de tráfego urbano, Chaudhary et al. (2025),



por exemplo, propuseram o modelo *Dynamic Tabu Search-based Gated Recurrent Units* (DTS-GRU) para controle adaptativo de congestionamentos em cidades inteligentes, utilizando dados de vídeo em tempo real da cidade de Pune, na Índia.

A abordagem obteve resultados expressivos, evidenciando a eficácia dos algoritmos para mitigar congestionamentos e promover a mobilidade urbana, embora os autores ressaltem a necessidade de infraestrutura computacional robusta e a dificuldade de implementação em tempo real no setor público (Chaudhary et al., 2025).

No campo da previsão de demanda e otimização logística, Nampalli & Adusupalli (2024) realizaram um estudo empírico utilizando algoritmos supervisionados, como *random forest* e *gradient boosted trees*, aplicados a dados históricos de transporte, incluindo origem-destino, tempo de trânsito e volumes.

A pesquisa dos autores Nampalli & Adusupalli (2024), demonstrou a viabilidade da aplicação de modelos preditivos para antecipar a demanda de frete e sugerir rotas otimizadas, contudo, os autores identificaram limitações, uma vez que esses modelos dependem fortemente de bases de dados estruturadas e completas, o que representa um desafio recorrente em ambientes públicos com baixa maturidade digital.

Outras pesquisas também apontam que, embora modelos preditivos sejam capazes de indicar demandas futuras, rotas otimizadas e decisões estratégicas, ainda há lacunas quanto à sua incorporação prática em realidades urbanas e políticas, Herath & Mittal (2022) destacam a dificuldade de compatibilizar algoritmos de aprendizado de máquina com as infraestruturas de transporte existentes, enquanto abordagens híbridas requerem planejamento criterioso e alinhamento com os objetivos de gestão urbana para garantir aplicabilidade.

Diante desse cenário, a presente pesquisa partiu da seguinte pergunta central: como a integração de técnicas de *machine learning* em sistemas de suporte à decisão pode contribuir para aprimorar a tomada de decisão na gestão da logística urbana? Mais do que explorar a tecnologia em si, este estudo busca compreender como estruturar esse uso de forma acessível, coerente e útil à realidade das administrações públicas.

Para isso, foi proposto o desenvolvimento de um framework teórico, com base na metodologia *Design Science Research* (DSR). A escolha da DSR como metodologia se justificou pela sua capacidade de integrar aspectos teóricos e práticos, promovendo a colaboração entre pesquisadores e profissionais da área (Tasche, Bähring & Gerlach, 2023), aliás a DSR permite o desenvolvimento de modelos teóricos que podem ser iterativamente

refinados e ajustados, contribuindo tanto para o avanço do conhecimento quanto para a solução de problemas reais (Hevner et al., 2004; Vaishnavi & Kuechler, 2004).

A pesquisa foi conduzida por meio de três etapas complementares: (i) entrevistas em profundidade com cinco especialistas das áreas de tecnologia e gestão urbana, voltadas à construção do artefato inicial; (ii) aplicação de um questionário estruturado com foco na validação do framework proposto, dirigido a esses mesmos cinco participantes da etapa qualitativa; e (iii) realização de entrevistas estruturadas com outros cinco profissionais, atuantes em uma empresa de tecnologia especializada em mobilidade urbana, com o objetivo de refinar o modelo e verificar sua aplicabilidade prática. Assim, o campo empírico totalizou dez participantes, sendo cinco envolvidos nas etapas qualitativa e quantitativa iniciais, e cinco distintos na etapa final de validação prática, permitindo a triangulação entre evidências qualitativas e quantitativas em diferentes contextos de análise.

Os resultados da pesquisa evidenciaram a viabilidade de um modelo cíclico composto por oito etapas, que se inicia com a identificação do problema urbano e culmina na retroalimentação contínua das decisões, sustentado tecnicamente pela integração de algoritmos de ML a SSDs. O framework foi desenvolvido de forma iterativa e validado empiricamente, incorporando contribuições de especialistas das áreas de tecnologia e gestão urbana. Ao longo do processo, foram identificadas lacunas operacionais e institucionais, aprimoradas por meio de análises qualitativas e quantitativas. A versão final do modelo oferece diretrizes claras, critérios de maturidade digital e mecanismos de monitoramento contínuo, demonstrando aderência às necessidades práticas da gestão pública urbana.

O estudo, no campo teórico contribui ao propor um framework que integra técnicas de ML a sistemas de suporte à decisão aplicados à logística urbana, articulando dimensões técnicas, operacionais e institucionais de forma inédita. Essa proposta oferece uma base estruturada para pesquisas futuras sobre o uso de inteligência de dados na gestão urbana, ampliando a compreensão sobre os requisitos necessários à aplicação de soluções preditivas em contextos públicos.

Do ponto de vista prático, o modelo se mostra adaptável a diferentes realidades, oferecendo um guia funcional para gestores públicos que enfrentam desafios como escassez de dados padronizados, fragmentação institucional e pressão por decisões mais ágeis e fundamentadas. Ao apresentar etapas claras e indicadores de acompanhamento, o framework

oferece suporte concreto à adoção de tecnologias analíticas no setor público, promovendo decisões logísticas mais eficientes, sustentáveis e baseadas em evidências.

## 1.2 OBJETIVOS

Buscando suprir a lacuna existente na literatura sobre a aplicação de técnicas de *Machine Learning* na logística urbana, este estudo tem como objetivo principal desenvolver um framework teórico que ofereça suporte à aplicação de *machine learning* em sistemas de suporte à decisão para contribuir na gestão logística em ambientes urbanos complexos.

## 1.3 OBJETIVOS ESPECÍFICOS

Alinhados à abordagem da DSR, os objetivos específicos desta pesquisa são organizados conforme as etapas iterativas de construção, demonstração e avaliação do artefato, conforme descrito a seguir:

1. Compreender os desafios da logística urbana em cenários de alta complexidade, a partir de uma revisão da literatura e da coleta de dados com especialistas;
2. Estabelecer os requisitos e objetivos de um framework teórico, considerando a integração de técnicas de ML a SSD no contexto da gestão pública;
3. Desenvolver o artefato conceitual, representado por um framework estruturado em etapas que orientam o uso de ML e SSDs na tomada de decisão em logística urbana;
4. Demonstrar o artefato desenvolvido, por meio de sua apresentação a profissionais da área, utilizando estratégias de coleta como questionário e entrevistas estruturadas;
5. Avaliar a clareza, aplicabilidade, coerência e completude do artefato, com base na percepção dos participantes;

## 1.4 JUSTIFICATIVA

Dentro dos parâmetros desta pesquisa, a logística urbana é caracterizada como um campo de elevada complexidade, influenciado pelo crescimento populacional, pela intensificação da densidade das cidades e pela exigência de operações sustentáveis e eficientes (Albino; Berardi & Dangelico, 2015; Dong et al., 2021). Esses fatores intensificam os desafios da gestão dos fluxos de transporte e distribuição em contextos urbanos dinâmicos.

Embora os avanços recentes no uso de técnicas de *machine learning* no planejamento urbano sejam expressivos, ainda persiste uma lacuna significativa entre o desenvolvimento técnico e sua incorporação efetiva às práticas de gestão (Shajan et al., 2024). Estudos como os de Chaudhary et al. (2025) e Reznichenko et al. (2024) demonstram que, apesar do potencial dos modelos preditivos para qualificar decisões logísticas, subsistem limitações metodológicas relacionadas à disponibilidade de dados estruturados, à interoperabilidade entre sistemas e à ausência de diretrizes para a adoção de soluções inteligentes em políticas públicas.

Nesse cenário, a integração de técnicas de ML em SSDs representa uma estratégia promissora para ampliar a eficácia das operações logísticas, ao oferecer uma base estruturada para decisões mais informadas, ágeis e estratégicas. O ML, ao processar grandes volumes de dados e identificar padrões complexos, contribui de forma decisiva para a otimização de processos logísticos em ambientes urbanos.

A relevância deste estudo decorre da necessidade de inovações aplicáveis à logística urbana, que promovam ganhos de eficiência operacional e, simultaneamente, atendam às demandas sociais por serviços logísticos inteligentes e adaptativos. Nesse sentido, o framework proposto busca enfrentar tais desafios, fornecendo uma estrutura teórica voltada à integração de ML em SSDs, passível de adaptação a diferentes realidades urbanas.

Além da contribuição prática, a pesquisa avança no campo teórico ao explorar a aplicação de ML em SSDs na logística urbana. Ao propor e validar um modelo conceitual com especialistas, pretende-se oferecer um guia capaz de apoiar gestores na qualificação da gestão logística em suas cidades.

## 1.5 ESTRUTURA DA DISSERTAÇÃO

Esta dissertação está organizada em seis capítulos, articulados de acordo com os objetivos específicos da pesquisa e com a lógica metodológica da DSR, além deste Capítulo 1 introdutório, que apresenta o tema, a problemática, os objetivos e a justificativa do estudo.

O Capítulo 2 – Fundamentação Teórica reúne os aportes conceituais que sustentam a investigação. São discutidos os elementos centrais da logística urbana em cenários de alta complexidade, os fundamentos de ML e as características dos SSD. O capítulo evidencia a intersecção entre essas áreas, destacando as lacunas teóricas e práticas que justificam a proposição de um framework voltado à gestão pública urbana.

O Capítulo 3 – Metodologia descreve o percurso metodológico adotado, fundamentado na DSR. São detalhadas as fases do processo de pesquisa — conscientização do problema, definição dos objetivos da solução, sugestão, avaliação e comunicação —, bem como os procedimentos de coleta de dados. A investigação foi conduzida em três etapas: entrevistas em profundidade, aplicação de questionário estruturado e entrevistas estruturadas de validação do framework.

O Capítulo 4 – Resultados Empíricos apresenta os achados obtidos nas três etapas de coleta. Primeiramente, são apresentados os resultados das entrevistas em profundidade, que permitiram identificar desafios e requisitos da logística urbana; em seguida, os resultados do questionário estruturado, que viabilizaram a avaliação quantitativa do framework segundo critérios de funcionalidade, aplicabilidade, intuitividade, confiabilidade, coerência, completude e distinção; e, por fim, as contribuições advindas das entrevistas estruturadas com profissionais da área, conduzidas com o propósito de validar e refinar a proposta.

O Capítulo 5 – Análise dos Resultados integra os achados empíricos com o referencial teórico, interpretando-os à luz das contribuições da literatura. Nesse capítulo, é apresentado o framework final, estruturado em oito etapas cíclicas e em elementos externos que condicionam sua aplicação (insumos institucionais, indicadores, barreiras e resultados esperados).

O Capítulo 6 – Considerações Finais sintetiza os principais resultados, responde à questão norteadora da pesquisa e examina o alcance dos objetivos específicos. São discutidas as contribuições teóricas e gerenciais do framework, as limitações da investigação e as recomendações para estudos futuros.

## 2 FUNDAMENTAÇÃO TEÓRICA

A seção 2.1 aborda a necessidade de inovação na logística urbana, discutindo os principais desafios enfrentados pelas cidades contemporâneas e a relevância de práticas inovadoras para aprimorar a gestão e a distribuição de bens e serviços. Na sequência, a seção 2.2 explora a aplicação de técnicas de ML no contexto urbano, evidenciando como essa abordagem pode contribuir para o aprimoramento da gestão logística.

A seção 2.3 analisa o papel dos SSDs na logística urbana, examinando sua capacidade de apoiar decisões estratégicas em ambientes urbanos complexos e dinâmicos. Por fim, será discutida a convergência entre ML e SSDs, destacando como a integração dessas tecnologias pode fortalecer a eficiência e a assertividade na gestão da logística urbana.

### 2.1 LOGÍSTICA URBANA

A logística urbana é um elemento essencial para o funcionamento das cidades, especialmente diante do crescimento populacional acelerado e da expansão das atividades econômicas nos centros urbanos (Ferrari et al., 2023). Esse contexto impõe desafios cada vez mais complexos, exigindo soluções logísticas que não sejam apenas operacionais, mas também orientadas por dados e informações qualificadas (Albino; Berardi & Dangelico, 2015; Kiba-Janiak, 2017).

Para Gatta, Marcucci & Le Pira (2017) a gestão eficiente da logística urbana envolve múltiplos stakeholders que inclui governos, operadores logísticos e a sociedade civil, e requer coordenação de fluxos, otimização de rotas e integração de modais. Entretanto, problemas como congestionamento, limitações de espaço, aumento da demanda por entregas rápidas e crescentes exigências ambientais tornam a tomada de decisão mais desafiadora (Dong et al., 2021; Berberoglu; Kazancoglu & Sagnak, 2023).

Além dos aspectos operacionais, há uma crescente necessidade de resiliência, adaptabilidade e inteligência nas operações logísticas (Rose et al., 2017). Isso inclui a capacidade de responder rapidamente a eventos inesperados, prever demandas e reconfigurar operações com base em informações confiáveis (Ullah et al., 2020; Sharma et al., 2022).

Neste cenário, o uso de tecnologias deixa de ser uma opção e se torna uma necessidade estratégica. Essas ferramentas permitem enfrentar os desafios operacionais oferecendo suporte

analítico às decisões, com base em modelos preditivos, cenários simulados e indicadores acionáveis (Kalboussi; Ndhaeif & Rezg, 2023; Pilla; Pardo & Nam, 2022).

Assim, a logística urbana, nesta pesquisa, não é tratada apenas como um problema de operação, mas como um desafio de gestão de dados e de transformação da informação em decisões mais qualificadas, alinhando-se às práticas contemporâneas de gestão pública orientada por evidências (Kubek & Więcek, 2019).

É possível observar na Figura 1 como as tecnologias emergentes estão posicionadas para enfrentar os desafios da logística urbana. O congestionamento de tráfego, por exemplo, pode ser mitigado pelo ML, que otimiza rotas em tempo real, reduzindo os tempos de entrega e os custos operacionais (Neumann; Guirguis & Steiner, 2024). Já as limitações de espaço para armazenagem podem ser abordadas com o uso da Internet das Coisas (IoT), que permite o monitoramento e a gestão eficiente dos recursos disponíveis, facilitando o armazenamento temporário em áreas urbanas densas (Parsaei & Afshari, 2022).


Entre os desafios centrais da logística urbana, se destaca a crescente demanda por entregas rápidas, que exige respostas ágeis e planejamento eficiente. Técnicas de ML permitem prever a demanda com maior precisão, possibilitando ajustes proativos nas operações e melhor alocação de recursos (Dong et al., 2021).

Essa capacidade de antecipação integra um conjunto mais amplo de inovações na logística urbana, as quais, conforme representado na base da Figura 1, resultam na adoção de práticas mais eficientes, adaptáveis e resilientes, capazes de responder de forma integrada às demandas dinâmicas das cidades e de apoiar decisões estratégicas na gestão pública urbana (Savin, 2020).

Os autores Nikitas et al. (2020) e Pan et al. (2021), defendem que as soluções para a logística urbana devem ser centradas nos usuários e alinhadas a princípios de sustentabilidade e governança digital integrada, de modo a promover cidades mais eficientes e resilientes. Nesse contexto, o uso de técnicas de ML assume papel estratégico na transformação do setor, viabilizando a automação de processos, a otimização de rotas e a previsão de demanda com elevado grau de precisão. Tais capacidades tornam as operações logísticas mais eficientes e adaptáveis, permitindo respostas ágeis aos desafios enfrentados em ambientes urbanos (Kalboussi; Ndhaeif & Rezg, 2023; Woschank; Rauch & Zsifkovits, 2020; Pilla; Pardo & Nam, 2022).

A logística urbana, entretanto, continua a enfrentar um conjunto de desafios complexos que afetam diretamente a eficiência e a eficácia das operações nas cidades. Com o avanço da urbanização, gestores e operadores logísticos precisam lidar com problemas que vão desde o congestionamento de tráfego até a fragmentação das operações (Janjevic; Knoppen; Winkenbach, 2019). Quando não são devidamente enfrentados, esses entraves resultam em tempos de entrega mais longos, custos operacionais mais elevados e maiores dificuldades na integração de diferentes modos de transporte (Reim; Åström; Eriksson, 2020).

Figura 1 – Relação entre desafios, tecnologias emergentes e inovações na logística urbana.



Fonte: Parsaee & Afshari (2022) e Berberoglu et al. (2023).

O Apêndice A resume os principais desafios enfrentados pela logística urbana, categorizando de acordo com suas características e priorizando com base no impacto que têm sobre as operações logísticas.

Após a análise dos desafios, é possível observar como cada um deles impacta diretamente as operações logísticas urbanas, criando um ambiente altamente complexo e desafiador. O congestionamento de tráfego é amplamente reconhecido como uma das principais barreiras para a eficiência logística nas áreas urbanas, gerando aumentos nos tempos de entrega e nos custos operacionais. Como destacado por Parsaee & Afshari (2022), esse fator obriga instituições a adotar soluções mais dinâmicas de roteamento para minimizar os atrasos, o que acaba resultando em maiores despesas e uma gestão logística mais complexa. Além disso, a



falta de infraestrutura adequada nas cidades agrava o problema, já que muitas rotas alternativas acabam sendo igualmente congestionadas, dificultando ainda mais a fluidez no transporte de mercadorias.

Um desafio enfrentado pelas operações logísticas é a limitação de espaço para armazenagem nas áreas urbanas. Conforme apontado por Berberoglu et al. (2023), a escassez de áreas adequadas para o armazenamento de mercadorias nas proximidades dos centros urbanos força as instituições a utilizarem instalações mais distantes, o que aumenta o tempo e o custo de deslocamento entre os armazéns e os consumidores finais. Esse desafio se torna ainda mais crítico em um contexto em que a demanda por entregas rápidas cresce exponencialmente.

Outro ponto que merece atenção é a fragmentação das operações logísticas, que se refere à dificuldade de integrar diferentes modais de transporte, o que gera ineficiências e eleva os custos operacionais (Zhang; Wei & Li, 2020). Ullah et al. (2020) argumentam que a falta de coordenação entre modais resulta em transferências desorganizadas de mercadorias, contribuindo para atrasos e aumentando os custos relacionados à movimentação e à armazenagem. Esses desafios exigem uma gestão coordenada e bem estruturada, especialmente nas áreas urbanas, onde as operações são mais complexas e fragmentadas devido à diversidade de meios de transporte disponíveis (Al-Surmi et al., 2022).

Adicionalmente, as operações logísticas urbanas enfrentam uma crescente pressão ambiental, exigindo que as instituições reduzam suas emissões de carbono e adotem práticas mais sustentáveis. Ridaoui et al. (2024) enfatizam a necessidade de modernizar as operações logísticas, alinhando-as às regulamentações ambientais cada vez mais rigorosas. Para isso, é fundamental investir em tecnologias e processos que não apenas melhorem a eficiência operacional, mas que também minimizem os impactos ambientais, garantindo a conformidade com as regulamentações locais e internacionais (Berberoglu et al., 2023).

Além disso, os custos elevados de infraestrutura representam um obstáculo para a modernização das operações logísticas urbanas (Moufad et al., 2024). Conforme discutido por Ren & Salleh (2024), modernizar a infraestrutura logística e implementar tecnologias emergentes requer investimentos significativos.

Esses desafios se tornam ainda mais evidentes nas operações de logística de última milha, onde a entrega em áreas urbanas densamente povoadas é particularmente complexa e cara (Keirstead & Shah, 2013). Enquanto isso, a segurança e o monitoramento das mercadorias

continuam sendo questões prioritárias, pois é necessário garantir que as entregas sejam rastreadas e monitoradas adequadamente durante todo o processo logístico (Wang et al., 2018).

A identificação dos desafios da logística urbana será a primeira fase do artefato, a qual é fundamental para a construção de soluções eficazes. Ao categorizar e priorizar os desafios, o framework poderá garantir que as soluções propostas sejam direcionadas às áreas mais críticas. A partir da análise dos desafios identificados, a próxima etapa será a seleção de ferramentas de ML, que abordará diretamente as questões levantadas, por meio de tecnologias integradas aos SSD.

## 2.2 *MACHINE LEARNING* NA LOGÍSTICA URBANA

A aplicação de ML na logística urbana se configura como uma abordagem relevante e estratégica para o enfrentamento dos desafios operacionais e estruturais das cidades contemporâneas (Shajan et al., 2024; Anthony Jnr, 2025).

ML é um subcampo da inteligência artificial que permite o desenvolvimento de modelos capazes de identificar padrões a partir de dados históricos, viabilizando processos de previsão, classificação e detecção de padrões, com base em dados previamente analisados (Faceli et al., 2021; Nampalli & Adusupalli, 2024).


Diferentemente dos sistemas baseados em regras fixas, os modelos de ML operam por meio da identificação de estruturas e relações latentes nos dados, o que permite uma adaptação dinâmica a ambientes complexos e de alta variabilidade, como é o caso das operações logísticas em áreas urbanas (Gutierrez-Franco; Mejia-Argueta & Rabelo, 2021; Chaudhary et al., 2025). Nesse contexto, o ML proporciona suporte à tomada de decisão orientada por dados, contribuindo para maior eficiência, previsibilidade e gestão de incertezas (Reznychenko; Uglickich & Nagy, 2024; Shajan et al., 2024).

De forma geral, o ML pode ser organizado em duas abordagens principais: aprendizado supervisionado e não supervisionado (Faceli et al., 2021). O aprendizado supervisionado é fundamentado em dados rotulados, ou seja, em conjuntos de dados que possuem saídas conhecidas, o que permite ao modelo aprender relações entre variáveis e gerar previsões direcionadas (Youn et al., 2024).

No contexto da logística urbana, essa abordagem tem sido aplicada em tarefas como previsão de demanda, classificação de zonas críticas, identificação de gargalos operacionais e otimização de rotas (Reznychenko; Uglickich & Nagy, 2024; Nampalli & Adusupalli, 2024).

Por sua vez, Li et al. (2023) adicionam que o aprendizado não supervisionado opera sem dados rotulados, sendo utilizado para identificar padrões ocultos, agrupamentos ou anomalias nos dados. Embora não constitua o foco central deste estudo, essa abordagem possui aplicações relevantes na logística urbana, especialmente em atividades como segmentação de territórios logísticos, agrupamento de perfis operacionais e detecção de falhas ou anomalias em processos (Büyüközkan & Ilıcak, 2022; Cheng & Pan, 2021; Eichenseer, Hans & Winkler, 2025). A Figura 2 apresenta a hierarquia clássica dos tipos de aprendizado de máquina, evidenciando as subdivisões e metodologias associadas às abordagens supervisionadas e não supervisionadas.

Figura 2 – Hierarquia clássica de aprendizado



Fonte: Adaptado de Faceli et al. (2021).

Para esta pesquisa, será adotada a abordagem de aprendizado supervisionado, com foco específico em classificação na subárea de identificação de eventos ou rotas logísticas (Liu, 2024), considerando sua aplicabilidade em contextos com dados rotulados, nos quais a relação entre variáveis pode ser explorada para prever categorias operacionais relevantes (Ang et al., 2022).

Zhang, Sun & Zhang (2022) apontam a relevância da governança de dados como base para decisões logísticas inteligentes e sustentáveis, especialmente quando a pesquisa envolve coleta, modelagem e integração de dados urbanos. Essa abordagem é particularmente eficaz em problemas de categorização, como a identificação de entregas críticas, rotas com maior incidência de atrasos ou zonas logísticas de alta complexidade, contribuindo diretamente para decisões baseadas em evidências no ambiente urbano (Bouhana et al., 2015). Além disso, a classificação supervisionada tem sido adotada com sucesso em sistemas de suporte à decisão

para logística urbana, promovendo maior previsibilidade e racionalização de fluxos logísticos na última milha (Cardenas et al., 2017).

Rismanto & Judijanto (2025) apresentam uma revisão abrangente dos algoritmos de roteirização dinâmica aplicados à logística urbana, enfatizando suas implicações operacionais e ambientais. Esse tipo de análise contribui para compreender como diferentes métodos de otimização podem apoiar gestores na busca por maior eficiência no uso da infraestrutura urbana e na redução de impactos ambientais.

Nesse contexto, o algoritmo *Random Forest* tem sido reconhecido como uma alternativa eficiente para lidar com conjuntos de dados complexos, ruidosos e compostos por múltiplas variáveis (Tekouabou et al., 2024). Sua estrutura, baseada na combinação de diversas <sup>1</sup>árvores de decisão, confere maior robustez e estabilidade às previsões, tornando-o adequado para cenários caracterizados por alta incerteza e múltiplos fatores de influência (Reznynchenko; Uglickich & Nagy, 2024).

Estudos recentes comprovam a eficácia do *random forest* em aplicações de logística urbana. Reznynchenko, Uglickich & Nagy (2024) demonstraram sua superioridade na classificação de dados reais de mobilidade urbana. Shajan, Suresh Kumar & Elavarasan (2024) aplicaram *random forest* em sistemas de recomendação logística e na predição da gravidade de acidentes em tempo real, reforçando sua aplicabilidade em contextos urbanos.

Yucesan et al. (2024) propõem uma abordagem para a avaliação da sustentabilidade da mobilidade urbana em cidades asiáticas, utilizando métodos de apoio à decisão sob condições de incerteza, permitindo incorporar tanto julgamentos de especialistas quanto dados imprecisos na construção do *Sustainable Urban Transport Index* (SUTI). Os resultados demonstram que essa combinação metodológica aprimora a precisão na avaliação comparativa de sistemas de mobilidade urbana, considerando critérios como eficiência energética, acessibilidade, impacto ambiental e resiliência operacional.

## 2.3 SISTEMAS DE SUPORTE À DECISÃO NA LOGÍSTICA URBANA

Os SSDs são ambientes computacionais desenvolvidos para fornecer suporte analítico à tomada de decisão, organizando, estruturando e apresentando dados processados de forma

---

<sup>1</sup>Árvores de decisão são modelos preditivos que utilizam uma estrutura hierárquica de nós e ramos para representar escolhas e resultados, permitindo a classificação ou a regressão de dados de forma intuitiva e interpretável (Facelli et al., 2021).

compreensível e acionável para os gestores (Carvalho, 2022). Historicamente, esses sistemas surgiram na década de 1960, em resposta ao aumento da complexidade dos ambientes organizacionais e à crescente necessidade de ferramentas capazes de auxiliar na análise de grandes volumes de dados e variáveis, superando as limitações cognitivas humanas (Simon, 1977).

Com os avanços tecnológicos e o aumento da capacidade de processamento computacional, os SSDs evoluíram significativamente. De ferramentas voltadas à consulta e ao armazenamento de dados, passaram a incorporar métodos avançados, como simulação, otimização e, mais recentemente, modelos preditivos baseados em ML (Al Mamlouk, 2024).

Essa transformação ampliou o papel dos SSDs, permitindo que sejam utilizados como interfaces analíticas inteligentes, capazes de organizar grandes volumes de dados, simular diferentes cenários e apresentar visualizações que facilitam a análise de alternativas e a tomada de decisões complexas (Carvalho, 2022; Martinez-Plumed et al., 2019).

Na logística urbana, os SSDs assumem um papel estratégico como interfaces de apoio à decisão, especialmente em ambientes caracterizados por alta variabilidade, como planejamento de rotas, alocação de recursos e gestão de estoques (Iwan & Kijewska, 2014). A principal função desses sistemas não está no processamento preditivo em si, mas na tradução dos resultados dos modelos de ML em informações acessíveis, interpretáveis e diretamente aplicáveis à gestão operacional e estratégica (Heumann et al., 2021).

A operação desses sistemas em tempo real é particularmente relevante, uma vez que as condições urbanas estão sujeitas a mudanças constantes — como alterações no tráfego, eventos climáticos e flutuações na demanda (Dossou & Vermersch, 2021; Chu; Cheng & Yu, 2022). Ao consolidar os dados provenientes de múltiplas fontes, os SSDs permitem que os gestores visualizem cenários, explorem alternativas e tomem decisões baseadas em evidências, promovendo maior agilidade e eficiência nas operações logísticas.

Leyerer et al. (2019) abordam o *Vehicle Routing Problem* (VRP) com uma proposta inovadora: um sistema de suporte à decisão flexível e personalizável projetado especificamente para transporte rodoviário comercial urbano. O modelo integra múltiplos atributos de roteirização (como janelas de tempo e tipos de veículos), permitindo adaptar-se a diferentes contextos operacionais reais. Utilizando a metodologia *design science research*, os autores testaram o DSS por meio de simulações e benchmarks computacionais, comparando-o com algoritmos direcionados a problemas específicos. Os resultados indicam que o sistema alcança

desempenho competitivo, com capacidade de minimizar distâncias percorridas e reduzir emissões de CO<sub>2</sub>. Aplicações práticas demonstram que esse DSS pode apoiar o planejamento eficiente de rotas no contexto da última milha urbana, conciliando sustentabilidade econômica e ambiental (Leyerer et al., 2019)

Nas seções anteriores, foi enfatizado que a modernização da logística urbana exige melhorias operacionais acompanhados da adoção de ferramentas capazes de transformar dados em insights acionáveis. Nesse contexto, a integração entre modelos preditivos de ML e SSDs surge como uma abordagem, na qual o SSD atua como a camada de interface que traduz resultados analíticos em suporte efetivo à tomada de decisão (Herath & Mittal, 2022; Heumann et al., 2021; Valkenburgh, 2024).

O uso de técnicas de ML desempenha um papel estratégico na transformação de dados urbanos em insights acionáveis, ao possibilitar a previsão de demandas, a análise de padrões de tráfego e a sugestão de rotas mais eficientes (Savin, 2020). Quando incorporados aos sistemas de suporte à decisão, esses resultados são organizados em formatos acessíveis, como <sup>2</sup>*dashboards* interativos, relatórios gerenciais e painéis analíticos, facilitando a interpretação por parte dos gestores e permitindo respostas mais ágeis e fundamentadas (Goodfellow; Bengio & Courville, 2016; Reim; Åström & Eriksson, 2020).

A integração entre ML e SSDs contribui significativamente para aprimorar a eficácia das decisões logísticas, fortalecendo a capacidade de resposta das cidades frente a desafios contemporâneos, como congestionamentos crônicos, limitações estruturais e demandas crescentes por sustentabilidade e eficiência operacional (Berberoğlu; Kazancoglu & Sagnak, 2023; Dossou & Vermersch, 2021).

Entretanto, conforme apontado por Rismanto & Judijanto (2025), persistem entraves institucionais e técnicos que dificultam a plena adoção dessas soluções, incluindo desigualdades no acesso à infraestrutura, ausência de interoperabilidade entre sistemas e carência de políticas públicas adequadas. Nesse contexto, destacam-se a importância de marcos regulatórios e da colaboração entre diferentes agentes públicos e privados como fatores determinantes para superar essas barreiras e consolidar um ambiente propício à inovação baseada em dados.

A Figura 3 ilustra esse fluxo, demonstrando como os dados coletados — como informações de tráfego, estoque, demanda e fatores externos — são processados por modelos

---

<sup>2</sup> *Dashboards* interativos, conforme descritos por Van Der Voort (2024), consistem em painéis que combinam visualizações dinâmicas apoiadas em inteligência artificial (IA), capazes de converter dados complexos em narrativas interpretativas que potencializam a tomada de decisões em ambientes gerenciais.


de ML, cujos resultados são então apresentados no SSD em formato compreensível. A partir desse ambiente, os gestores podem realizar análises de cenários, explorar alternativas e implementar ajustes operacionais em tempo real.

No diagrama de *input* e *output* desta etapa, as entradas incluem informações críticas como dados de tráfego (identificação de congestionamentos e sugestões de rotas alternativas), informações de estoque e demanda (níveis disponíveis, pedidos e flutuações), além de dados externos como condições climáticas e eventos urbanos (Ullah et al., 2020; Dong et al., 2021; Berberoglu et al., 2023).

O processamento realizado pelos modelos de ML envolve a otimização de rotas, previsão de demanda e análise de padrões operacionais, gerando saídas que são consolidadas no SSD em formatos como dashboards, relatórios analíticos e painéis de monitoramento (Liyanage & Bagloee, 2019; Herath; & Mittal, 2022).

As saídas incluem recomendações de rotas otimizadas, previsões de demanda ajustadas, sugestões para redistribuição de veículos e alocação de recursos, além de alertas operacionais baseados nas condições em tempo real (Dong et al., 2021; Reim; Åström & Eriksson, 2020).

Figura 3 – Integração de ML e Sistemas de Suporte à Decisão na Logística Urbana



Fonte: Adaptado de Herath & Mittal (2022); Heumann et al. (2021).

A logística urbana enfrenta desafios cada vez mais complexos nas cidades contemporâneas, que envolvem dimensões operacionais, ambientais e sociais (Gonzalez-Feliu et al., 2020; Taniguchi et al., 2016). A literatura destaca que a fragmentação e a baixa padronização dos dados públicos comprometem significativamente a qualidade da tomada de

decisão (Zhang et al., 2022; Herath & Mittal, 2022). Nesse cenário, a aplicação de técnicas de ML pode contribuir para superar essas limitações, oferecendo análises preditivas e apoio à definição de prioridades (Gatta et al., 2017; Shajan et al., 2024). No entanto, é essencial que essas soluções tecnológicas estejam integradas aos sistemas institucionais existentes, de forma a garantir sua aplicabilidade (Heumann et al., 2021; Al Mamlouk, 2024). Para tanto, a pesquisa adotou a DSR como metodologia, articulando revisão sistemática da literatura e investigação empírica em múltiplas etapas — entrevistas em profundidade, aplicação de questionário estruturado e entrevistas para validação do framework. Na próxima seção, são apresentados os procedimentos metodológicos que orientaram o desenvolvimento e a validação da proposta, estabelecendo a conexão entre fundamentos teóricos e aplicação prática (Vaishnavi & Kuechler, 2004; Peffers et al., 2007).



### 3 METODOLOGIA

Esta seção descreve os procedimentos metodológicos empregados na pesquisa. A abordagem adotada caracteriza-se como qualitativa, de natureza exploratório-descritiva, considerando a relevância de aprofundar a compreensão de um fenômeno ainda incipientemente estruturado: a integração de técnicas de ML em sistemas de suporte à decisão aplicados à logística urbana.

Segundo Klein et al. (2015), pesquisas exploratórias são apropriadas quando o objetivo é proporcionar uma visão geral e inicial sobre determinado tema, especialmente quando este ainda é recente ou carece de estudos consolidados. Já a pesquisa descritiva tem como finalidade caracterizar e organizar informações sobre determinado fenômeno, permitindo traçar um retrato mais preciso de suas dimensões e atributos (Gil, 2010).

Assim, a combinação dessas duas abordagens permite à presente investigação tanto compreender e mapear o problema (exploratória), quanto detalhar os elementos que compõem o artefato proposto (descritiva), a partir da coleta de dados empíricos com especialistas e da análise interpretativa dos resultados. De acordo com Lakatos & Marconi (2009), a pesquisa descritiva é indicada quando o problema está bem definido e exige informações mais estruturadas, o que se alinha à proposta desta etapa da pesquisa.

A presente pesquisa foi conduzida com base na metodologia DSR, a qual, segundo Hevner et al. (2013), tem como objetivo principal a construção de soluções inovadoras para problemas complexos, aliando o desenvolvimento de artefatos à sua avaliação sistemática.

A DSR é uma abordagem metodológica relevante para a pesquisa em administração, promovendo uma mudança paradigmática ao integrar a criação de artefatos com a geração de conhecimento científico aplicável. Essa metodologia se destaca por sua orientação à resolução de problemas práticos, proporcionando resultados que dialogam tanto com as exigências da prática organizacional quanto com as contribuições teóricas da academia (Vaishnavi & Kuechler, 2004; Hevner et al., 2007).

O princípio fundamental da DSR está na construção de conhecimento por meio do desenvolvimento e aplicação de artefatos em contextos reais (Baskerville *et al.*, 2018). Esses artefatos, concebidos com base em conhecimento pré-existente, são submetidos a processos rigorosos de avaliação, permitindo que os aprendizados obtidos retroalimentem o arcabouço

teórico da área (Vaishnavi & Kuechler, 2004). Nesse sentido, o artefato é mecanismo central para a produção de conhecimento aplicado e contextualizado (March & Smith, 1995).

Importante ressaltar que os artefatos desenvolvidos na DSR podem assumir diversas formas como: modelos, métodos, frameworks ou sistemas. Sua relevância está vinculada à capacidade de oferecer soluções efetivas a problemas identificados, ao mesmo tempo em que ampliam a compreensão teórica sobre o fenômeno estudado (Hevner et al., 2004; March & Smith, 1995). Assim, a DSR contribui de forma significativa para o avanço do conhecimento científico, ao equilibrar inovação prática e fundamentação teórica.

Essa metodologia compreende um ciclo contínuo de etapas que impulsionam o avanço do conhecimento e o desenvolvimento de soluções inovadoras, como ilustrado na Figura 4. Com base no modelo proposto por Takeda et al. (1990), Vaishnavi & Kuechler (2004) e Manson (2006), o processo de DSR segue um fluxo lógico e sequencial.

A Figura 4 apresenta o ciclo iterativo do método DSR, com as principais fases do desenvolvimento de soluções e artefatos. O ciclo inicia com a identificação de problemas e com a motivação; nessa etapa, o pesquisador reconhece um desafio prático relevante e estabelece a necessidade de uma solução inovadora. Em seguida, o pesquisador define os objetivos da solução, especificando o que deve ser alcançado e quais critérios orientarão a avaliação de êxito (Hevner et al., 2007).

Na fase de design e desenvolvimento, é onde o artefato é criado. Esse artefato pode assumir diversas formas, como um modelo, método ou sistema, e tem como propósito resolver o problema identificado de maneira eficaz (Peffer et al., 2007). Na etapa de demonstração, envolve a aplicação do artefato em um contexto prático para verificar se ele atende aos objetivos estabelecidos e funciona como esperado em cenários reais (Takeda et al., 1990).


Após a demonstração, o processo segue para a avaliação, onde são aplicadas métricas e análises rigorosas para medir a eficácia e a eficiência do artefato buscando identificar o impacto do artefato, suas limitações, e as possíveis melhorias (Baskerville et al., 2018). caso o artefato não alcance os resultados esperados, o ciclo itera, retornando às fases anteriores para ajustes e refinamentos (Vaishnavi & Kuechler, 2004).

Finalmente, a fase de comunicação assegura a disseminação do conhecimento gerado ao longo do processo (Takeda et al., 1990). Os resultados, as contribuições teóricas e práticas, assim como o próprio framework, são apresentados à comunidade acadêmica e aos *stakeholders*

envolvidos, promovendo a transferência de conhecimento e possibilitando a aplicação do artefato em outros contextos (Takeda et al., 1990).

Ao longo de todo o ciclo, diferentes pontos de entrada para a pesquisa são destacados, como uma abordagem centrada no problema, no design ou nos objetivos, mostrando a flexibilidade do método DSR em diferentes contextos de pesquisa (HEVNER *et al.*, 2007).

Figura 4 – Ciclo iterativo da DSR




Fonte: Adaptado de Takeda et al. (1990) e Peffers et al. (2007)

Essas etapas formam um ciclo iterativo que permite o aperfeiçoamento contínuo do framework, garantindo que as soluções propostas atendam de forma eficaz aos desafios práticos e teóricos identificados ao longo do processo (Hevner et al., 2013).

Após a apresentação do ciclo geral da DSR, é relevante explicitar a forma como essa metodologia foi operacionalizada nesta pesquisa. A Figura 5 apresenta a sequência de atividades realizadas em cada etapa, evidenciando a progressão metodológica da investigação. O esquema integra os procedimentos de análise teórica e coleta de dados empíricos, além de demonstrar a articulação entre resultados e construção do framework final.

Figura 5 – Percurso metodológico



Fonte: Elaborado pela autora

Cada seção do capítulo a seguir corresponde a um momento específico desse percurso, garantindo coerência entre a fundamentação teórica, a construção do framework e os procedimentos de validação adotados.

A Seção 3.1 descreve a conscientização do problema, destacando os desafios da logística urbana que justificam a investigação. A Seção 3.2 trata da definição dos objetivos da solução, consolidando os requisitos que orientaram a formulação do framework. A Seção 3.3 contempla a sugestão da proposta preliminar, estruturada a partir da literatura e das evidências coletadas. A Seção 3.4 se refere à avaliação, realizada por meio de entrevistas, questionário e validação junto a especialistas. O capítulo seguinte (Capítulo 4) concentra a fase de comunicação dos resultados, enfatizando a contribuição científica e prática do estudo.

### 3.1 FASE DE CONSCIENTIZAÇÃO DO PROBLEMA

A DSR começa pela fase de conscientização do problema, cujo objetivo é identificar uma lacuna relevante na prática ou na teoria que justifique o desenvolvimento de um artefato inovador (Vaishnavi & Kuechler, 2004; Manson, 2006). Essa etapa pode ser motivada por observações empíricas, vivência profissional ou análise de literatura, e culmina na formulação de uma proposta formal ou informal que fundamenta o início de um novo esforço de pesquisa (Thuan; Drechsler & Antunes, 2019).

Neste estudo, a conscientização do problema decorreu da convergência entre três elementos principais: (i) a afinidade da pesquisadora com temas relacionados à gestão urbana, tecnologias analíticas e tomada de decisão pública; (ii) experiências profissionais em ambientes que demandam o uso estratégico de dados para decisões operacionais; e (iii) uma revisão sistemática da literatura sobre logística urbana, ML e sistemas de suporte à decisão SSDs.

A literatura analisada evidenciou avanços técnicos significativos na aplicação de modelos preditivos baseados em ML para problemas urbanos específicos, como previsão de demanda, otimização de rotas e análise de tráfego (Reznychenko et al., 2024; Shajan et al., 2024). No entanto, observou-se que tais soluções permanecem, em sua maioria, desconectadas das estruturas institucionais e decisórias do setor público. Em especial, notou-se a ausência de frameworks que orientem de forma prática a adoção dessas tecnologias em contextos públicos com baixa maturidade digital, dados fragmentados e limitações operacionais.

Além disso, autores como Ferrari et al. (2023) e Zhang, Sun & Zhang (2022) destacam barreiras estruturais, como a falta de padronização dos dados urbanos e a carência de governança da informação, que comprometem a utilização estratégica desses dados na gestão logística.

Com base nessa análise, foi formulada a seguinte pergunta de pesquisa: Como a integração de técnicas de *machine learning* em sistemas de suporte à decisão pode contribuir para aprimorar a tomada de decisão na gestão da logística urbana?

Essa questão norteou o desenvolvimento de um framework teórico, que se propôs a estruturar o uso combinado de ML e SSDs, considerando as particularidades da gestão pública urbana. A motivação para essa pesquisa não está na tecnologia em si, mas na carência de orientações práticas para sua adoção em ambientes reais, especialmente nos municípios brasileiros.

Por se tratar de um problema aplicado, que demanda não apenas análise teórica, mas também proposição e validação de uma solução viável, a pesquisa seguiu pela linha da DSR como abordagem metodológica. A DSR permite integrar construção e avaliação de artefatos com base em ciclos iterativos, promovendo um equilíbrio entre relevância prática e rigor científico (Hevner et al., 2004; Peffers et al., 2007).

### 3.2 FASE DE SUGESTÃO

Com base na revisão teórica e na delimitação do problema, esta fase apresenta a proposta conceitual inicial do artefato da pesquisa. A fase de sugestão, conforme March & Smith (1995) e Hevner et al. (2004), corresponde ao momento em que se estrutura uma solução teórica fundamentada, capaz de responder aos objetivos definidos na fase anterior. Ainda que em estágio preliminar, o artefato proposto deve refletir uma lógica coerente entre os conhecimentos existentes e os requisitos empíricos observados.

Neste estudo, a sugestão consiste em um framework teórico para orientar a integração de técnicas de ML a SSDs, com foco na gestão da logística urbana. O objetivo é estruturar, de maneira clara e replicável, um modelo que apoie a tomada de decisão pública com base em dados, considerando os entraves institucionais e operacionais identificados na literatura. A proposta do artefato resulta da combinação entre fundamentos teóricos consolidados e lacunas práticas mapeadas na fase de conscientização do problema.

A revisão sistemática que embasou esta proposta foi conduzida nas bases Scopus e Web of Science, a partir da combinação dos descritores: “*urban logistics*” AND “*machine learning*” AND “*decision support systems*” AND “*urban mobility*”. O recorte abrangeu o período de 2010 a 2024, com ênfase em estudos aplicados a contextos urbanos e voltados à gestão pública. Após a triagem dos registros, leitura crítica e extração dos dados, foram selecionados os trabalhos mais relevantes, os quais permitiram identificar tendências emergentes, abordagens metodológicas recorrentes e lacunas ainda não supridas na literatura.

Além da revisão sistemática formal, também foram incorporadas leituras complementares, selecionadas por sua relevância teórica e prática no campo da inovação em políticas públicas, inteligência artificial aplicada à mobilidade e metodologias de apoio à decisão. Essa abordagem ampliada possibilitou uma fundamentação mais sólida e abrangente do framework, contemplando tanto evidências empíricas recentes quanto reflexões teóricas consolidadas.

As lacunas identificadas nesse processo são apresentadas no Quadro 1 a seguir, e serviram como base para a formulação da proposta do artefato conceitual.

Quadro 1 – Lacunas identificadas na literatura

| Lacuna Identificada                                                   | Autores            | Ano  |
|-----------------------------------------------------------------------|--------------------|------|
| Fragmentação e baixa padronização dos dados urbanos públicos          | Zhang, Sun & Zhang | 2022 |
| Dificuldade de uso estratégico dos dados por ausência de governança   | Ferrari et al.     | 2023 |
| Aplicações de ML urbanas ainda desconectadas dos processos decisórios | Reznychenko et al. | 2024 |
| Falta de frameworks voltados à realidade institucional pública        | Shajan et al.      | 2024 |
| Subutilização dos SSDs na gestão pública urbana                       | Al Mamlouk         | 2024 |

Fonte: Elaborado pela autora

Diante disso, a proposta inicial de framework é concebida como uma resposta estruturada e funcional a essas limitações. O modelo parte da identificação dos desafios urbanos relacionados à logística, passando por etapas de análise de maturidade institucional, tratamento e integração de dados, aplicação de algoritmos de ML e tradução dos resultados em painéis analíticos via SSD. Embora ainda em fase conceitual, a estrutura do framework reflete uma visão sistematizada do processo decisório orientado por dados em ambientes públicos urbanos.

A construção da solução se apoia na recombinação de conhecimentos existentes: os fundamentos da logística urbana como campo estratégico da administração pública (Gatta et al., 2017), as aplicações de ML em problemas urbanos com alta variabilidade (Reznychenko et al., 2024; Chaudhary et al., 2025) e o papel dos SSD como interfaces de tradução entre dados e decisão (Heumann et al., 2021; Carvalho, 2022). A articulação entre essas dimensões permitiu conceber um artefato composto por etapas interdependentes, capazes de orientar gestores públicos na formulação de estratégias logísticas mais inteligentes, preditivas e adaptáveis.

A sugestão do framework não se encerra em uma estrutura técnica, mas assume também uma dimensão estratégica: oferecer uma base teórica adaptável às realidades institucionais, permitindo que municípios com diferentes níveis de maturidade digital possam aplicar, ajustar ou expandir o modelo. A representação preliminar da proposta (em formato de diagrama ou quadro explicativo) será construída ao final da próxima seção, com base nos achados das fases seguintes da pesquisa.

### 3.3 A FASE DE DESENVOLVIMENTO DO FRAMEWORK

A fase de desenvolvimento corresponde à materialização da proposta teórica delineada na etapa de sugestão, consolidando-o em um artefato estruturado de acordo com os princípios da DSR. Esse momento é caracterizado pela transição do plano conceitual para uma solução organizada, fundamentada nas evidências extraídas da literatura e nas diretrizes estabelecidas nos objetivos da pesquisa. Conforme sugerido por Peffers et al. (2007), essa fase envolve a construção iterativa de uma solução que, embora ainda não validada, deve ser clara, funcional e alinhada ao problema originalmente definido.

Neste estudo, o artefato concebido é um framework teórico para integração de técnicas de ML a SSD aplicados à logística urbana no contexto da gestão pública. A proposta configura uma solução teórica voltada à orientação de processos decisórios com base em dados, destinada a apoiar instituições públicas na análise e priorização de ações logísticas em ambientes urbanos complexos e dinâmicos.

A construção do framework partiu da consolidação dos fundamentos teóricos obtidos na revisão sistemática da literatura, apresentada no Capítulo 2, bem como da síntese das lacunas mapeadas e dos requisitos derivados dos objetivos específicos da pesquisa. Com base nesses insumos, foi elaborada uma estrutura inicial, composta por etapas organizadas de forma lógica e sequencial, refletindo a jornada decisória esperada em um processo de análise urbana baseado em dados.

Conforme proposto por Hevner et al. (2004), a construção do artefato conceitual foi orientada por três princípios fundamentais. O primeiro princípio, buscou garantir coerência conceitual, fundamentando cada etapa do framework em conceitos consolidados nos campos da ciência de dados, da logística urbana e da gestão pública, o que assegura consistência teórica à proposta.

Em segundo lugar, foi priorizado a aderência institucional, estruturando o modelo de forma compatível com a realidade de instituições públicas brasileiras, levando em conta as limitações técnicas, operacionais e orçamentárias que caracterizam esse contexto.

Por fim, a pesquisa adotou uma lógica de iteratividade, organizando o framework em formato cíclico, de modo a incorporar a noção de melhoria contínua e retroalimentação, aspecto essencial em sistemas inteligentes de apoio à decisão, o Quadro 2 apresenta a síntese do processo de desenvolvimento do framework, com a descrição das principais etapas envolvidas.



Quadro 2 – Etapas de desenvolvimento do framework

| <b>Etapas</b>                   | <b>Descrição</b>                                                                               |
|---------------------------------|------------------------------------------------------------------------------------------------|
| Revisão teórica                 | Levantamento de fundamentos sobre ML, SSD e logística urbana para compor o modelo conceitual.  |
| Delimitação das lacunas         | Identificação de problemas recorrentes na literatura, sistematizados no Quadro 1 da seção 3.2. |
| Construção da estrutura inicial | Formulação da primeira versão do framework com base nos objetivos e na literatura.             |
| Análise qualitativa             | Refinamento da estrutura a partir das entrevistas em profundidade com especialistas (Etapa 1). |
| Análise quantitativa            | Verificação estatística da clareza e coerência do modelo a partir do questionário (Etapa 2).   |
| Ajustes estruturais             | Inclusão de novos elementos e reorganização de etapas com base nas evidências empíricas.       |
| Versão consolidada              | Finalização do artefato com oito etapas e quatro elementos complementares.                     |

Fonte: Elaborado pela autora

O processo de desenvolvimento ocorreu de maneira incremental, sendo continuamente refinado ao longo da pesquisa. A primeira versão do framework foi posteriormente revista e aprimorada com base nos dados coletados nas etapas qualitativa (entrevistas em profundidade com especialistas da área) e a segunda versão foi atualizada na etapa quantitativa (aplicação de questionário estruturado), sempre com o objetivo de assegurar clareza, aplicabilidade e alinhamento prático da proposta.

### 3.3.1 Entrevistas em profundidade como suporte à construção do framework

A entrevista é compreendida como uma técnica de coleta de dados caracterizada pela interação direta entre pesquisador e participante, na qual são formuladas perguntas com o objetivo de obter informações pertinentes aos objetivos da investigação (Gil, 2010). Para esta pesquisa, foi adotada a entrevista estruturada, definida por Hair et al. (2005) como aquela que utiliza um roteiro com perguntas previamente elaboradas, formuladas de forma padronizada e aplicadas de maneira idêntica a todos os participantes.

A etapa inicial da coleta de dados consistiu na realização de entrevistas estruturadas com cinco participantes, selecionados intencionalmente com base em sua experiência prática e conhecimento técnico sobre o uso de dados, tecnologias digitais e soluções inteligentes aplicadas à gestão pública. Para preservar o anonimato, os entrevistados foram codificados por letras gregas: Alfa ( $\alpha$ ), Beta ( $\beta$ ), Gama ( $\gamma$ ), Delta ( $\delta$ ) e Épsilon ( $\epsilon$ ). A amostra foi estruturada para contemplar diferentes perspectivas, sendo composta por três profissionais da área de Inteligência Artificial (IA), um da área de Inovação em cidades e um da área de administração pública.

No grupo técnico de inteligência artificial, o participante Alfa (36 anos) é doutor em computação aplicada, com trajetória acadêmica e profissional voltada ao desenvolvimento de soluções baseadas em aprendizado de máquina. Atua como *head* de *data science* em uma empresa de tecnologia e como professor universitário, com experiência em projetos de classificação de documentos, predição de comportamento e automatização de decisões com base em dados. O participante  $\beta$  (54 anos) é tecnólogo em processamento de dados, com mais de 30 anos de experiência em projetos de tecnologia da informação aplicados à saúde pública, atuando em hospitais públicos e privados, com foco em análise de dados, indicadores operacionais e controle de custos hospitalares. Já o participante Gama (34 anos) possui formação em comunicação digital e ciência da computação, além de mestrado em computação aplicada. Atuou em empresas de grande porte, como a Dell Technologies, e atualmente coordena uma equipe de ciência de dados em uma instituição financeira cooperativa. Sua experiência inclui participação em iniciativas públicas voltadas à acessibilidade urbana com uso de realidade aumentada.

Na área de administração pública, o participante Delta (34 anos) é bacharel em administração com especialização em gestão pública e cidades inteligentes. Atua como diretor de planejamento urbano em uma prefeitura, com ampla experiência em políticas públicas voltadas à mobilidade urbana, infraestrutura e adoção de tecnologias digitais na gestão territorial.

Por fim, o participante Épsilon (41 anos), representante da área de inovação em cidades, é economista, mestre e doutor em desenvolvimento econômico, atua no Instituto Agregar, com vivência em contratos com órgãos governamentais, gestão de sistemas sob demanda e articulação entre os setores público e privado para implementação de soluções digitais em cidades, o Quadro 3 apresenta os perfis dos participantes de forma sintética.

Quadro 3 – Perfil dos entrevistados

| <i>Participante</i>                    | <i>Idade</i> | <i>Área de Atuação</i>        | <i>Formação</i>                                      | <i>Experiência</i>                                                 |
|----------------------------------------|--------------|-------------------------------|------------------------------------------------------|--------------------------------------------------------------------|
| <i>Alfa (<math>\alpha</math>)</i>      | 36           | IA                            | Doutor em Computação Aplicada                        | Head de Data Science, professor universitário.                     |
| <i>Beta (<math>\beta</math>)</i>       | 54           | IA                            | Tecnólogo em Processamento de Dados                  | Responsável pelo desenvolvimento de tecnologias baseada em IA      |
| <i>Gama (<math>\gamma</math>)</i>      | 34           | IA                            | Mestre em Computação Aplicada                        | Coordenador de ciência de dados, experiência com projetos públicos |
| <i>Delta (<math>\delta</math>)</i>     | 34           | Gestão Pública                | Bacharel em Administração com esp. em Gestão Pública | Diretor de planejamento estratégico na área pública.               |
| <i>Épsilon (<math>\epsilon</math>)</i> | 41           | Gestão de Inovação em cidades | Mestre em Desenvolvimento econômico                  | Gestor executivo na área de inovação                               |

Fonte: Elaborado pela autora.

As entrevistas foram conduzidas de forma remota, utilizando a plataforma Microsoft Teams. O convite à participação foi feito diretamente por meio da rede LinkedIn, respeitando o perfil profissional e a aderência temática dos convidados à proposta da pesquisa. As conversas ocorreram individualmente, com duração média de 40 minutos a uma hora. Todas foram gravadas com o consentimento formal dos participantes e, posteriormente, transcritas integralmente para análise qualitativa.

O roteiro de entrevistas foi construído com base em categorias derivadas da literatura e em tópicos-chave relacionados ao artefato teórico proposto. Foram elaboradas versões diferenciadas do roteiro (ver Apêndice B), adaptadas conforme o perfil dos participantes. Essa distinção visou garantir maior profundidade e pertinência nas respostas, respeitando as especificidades de formação e atuação de cada entrevistado.

Essa composição da amostra permitiu captar visões complementares, tanto sob a perspectiva técnica quanto institucional, enriquecendo a análise das condições, barreiras e oportunidades para o uso de dados e modelos preditivos no apoio à tomada de decisão em contextos urbanos.

### 3.3.2 Questionário estruturado como mecanismo de validação parcial do framework

Segundo Lakatos & Marconi (2009), o questionário é um instrumento de coleta de dados constituído por uma série ordenada de perguntas, que devem ser respondidas por escrito e sem a presença do entrevistador. De modo geral, o pesquisador envia o questionário ao respondente por correio convencional ou eletrônico, via site ou por meio de um portador, sendo devolvido após o preenchimento. Esse instrumento costuma ser acompanhado de uma comunicação explicando os objetivos da pesquisa, ressaltando sua importância e garantindo a confidencialidade das informações, que são analisadas de forma agregada, sem identificação nominal dos participantes.

A utilização de escalas em pesquisas quantitativas tem por finalidade mensurar percepções, atitudes e opiniões de maneira padronizada e objetiva. Segundo Gil (2008), as escalas são elaboradas para captar a intensidade das opiniões dos respondentes, permitindo ao pesquisador compreender como determinados temas são percebidos. Dentre as alternativas disponíveis, a escala Likert se destaca por sua simplicidade e eficácia na mensuração de níveis de concordância. Conforme Lakatos & Marconi (2009), essa escala pode ser compreendida como um instrumento científico de observação e mensuração de fenômenos sociais, sendo composta por proposições cujas respostas representam diferentes intensidades de posicionamento. Os valores atribuídos pelos respondentes permitem quantificar percepções, facilitando a análise estatística. Além disso, as escalas Likert são frequentemente estruturadas por meio de questões fechadas, que contribuem para reduzir ambiguidades e favorecem a sistematização da análise.

Para a presente pesquisa, foi utilizada a escala Likert na construção do questionário por ser uma abordagem apropriada para mensurar percepções subjetivas de forma objetiva e comparável. Considerando que o foco do estudo está em compreender o grau de concordância dos respondentes em relação à aplicação de técnicas de ML em sistemas de suporte à decisão no contexto da logística urbana, a escala Likert se mostrou adequada, já que sua estrutura graduada permite captar nuances nas opiniões, facilitando a análise quantitativa dos dados e contribuindo para a clareza dos resultados.

A segunda etapa da coleta de dados teve como objetivo complementar os achados qualitativos obtidos nas entrevistas em profundidade, por meio de uma abordagem quantitativa e padronizada. Essa fase, essencial dentro do ciclo metodológico da DSR, contribuiu para a

validação preliminar dos elementos do artefato teórico proposto, ampliando o número de participantes e permitindo identificar padrões de percepção sobre o uso de dados e *machine learning* na logística urbana. Especificamente, buscou-se testar o grau de concordância com os princípios e componentes do framework, identificar pontos de convergência entre diferentes perfis profissionais e reunir subsídios quantitativos para o aprimoramento das diretrizes propostas.

O questionário foi estruturado a partir dos temas emergentes na Etapa 1, bem como dos tópicos-chave do framework teórico em construção. Foram consideradas categorias como: (i) experiência prévia com dados urbanos; (ii) barreiras técnicas e institucionais; (iii) viabilidade de implementação de ML no setor público; (iv) relevância dos SSD; e (v) avaliação da importância de diferentes diretrizes do framework.

O instrumento foi composto por afirmações avaliadas em escala de cinco pontos, variando de 1 para “discordo totalmente” a 5 para “concordo totalmente”. A aplicação ocorreu de forma remota, utilizando a plataforma Microsoft Forms. Os convites foram enviados diretamente a profissionais com perfil semelhante ao da Etapa 1, incluindo gestores públicos, cientistas de dados e profissionais de tecnologia com experiência em cidades inteligentes. A amostra foi não probabilística e intencional, com o objetivo de manter a coerência com os perfis estratégicos definidos previamente.

Após a realização das entrevistas em profundidade e da aplicação do questionário estruturado, o framework passou por um processo iterativo de ajustes, que envolveu tanto o refinamento conceitual quanto a reorganização estrutural de suas etapas. Os dados qualitativos e quantitativos obtidos foram fundamentais para aprimorar a aderência do modelo às demandas institucionais e técnicas observadas no contexto urbano. A versão consolidada do framework foi, então, submetida à etapa de validação final junto aos especialistas envolvidos na pesquisa, conforme será detalhado na próxima seção.

### 3.4 FASE DE AVALIAÇÃO DO FRAMEWORK

A fase final da pesquisa consistiu na avaliação do framework desenvolvido por meio de entrevistas estruturadas com cinco especialistas atuantes em uma startup brasileira voltada à gestão de transporte urbano e monitoramento de frotas. A empresa é reconhecida por sua atuação no ecossistema de inovação urbana, oferecendo plataformas que integram dados operacionais e algoritmos preditivos para apoiar a tomada de decisão em contextos públicos e privados.

Os participantes foram selecionados intencionalmente, considerando seus perfis técnicos e estratégicos, com experiências em ciência de dados, engenharia de sistemas, desenvolvimento de algoritmos e infraestrutura tecnológica. O convite foi realizado por meio da rede LinkedIn, e as entrevistas ocorreram de forma remota, via Microsoft Teams.

O principal objetivo desta etapa foi validar a versão consolidada do framework teórico, voltado à integração de modelos de ML em SSD no âmbito da logística urbana. As entrevistas seguiram um roteiro estruturado, abordando critérios como clareza, relevância, aplicabilidade e completude, além de coletar sugestões técnicas para seu aprimoramento.

A amostra foi composta por cinco profissionais com diferentes formações e áreas de atuação dentro do campo da tecnologia. O primeiro participante (P1), de 38 anos, é mestre em ciência da computação e atua com modelagem de algoritmos preditivos, com foco na integração prática entre ciência de dados e operação urbana. O segundo participante (P2), de 35 anos, é engenheiro de computação e trabalha com desenvolvimento, implementação e monitoramento de modelos preditivos.

O terceiro participante (P3), de 26 anos, é bacharel em sistemas de informação e atua em pré-processamento de dados, testes de modelos e documentação técnica, oferecendo uma perspectiva voltada à usabilidade do framework por profissionais em início de carreira. O quarto participante (P4), de 41 anos, possui graduação em análise de sistemas e MBA em arquitetura de soluções, atuando na integração entre infraestrutura tecnológica e suporte a sistemas, com foco na viabilidade organizacional da implementação. Por fim, o quinto participante (P5), de 37 anos, é bacharel em engenharia da computação e atua no desenvolvimento de pipelines de dados e integração de modelos com plataformas web, com contribuições voltadas à eficiência computacional e desempenho técnico.

A diversidade dos perfis contribuiu para uma avaliação abrangente do framework, permitindo validar tanto seus fundamentos conceituais quanto sua aplicabilidade prática em contextos reais de tecnologia urbana. O Quadro 4, apresenta a síntese do perfil dos participantes dessa etapa:

Quadro 4 – Perfil dos participantes das entrevistas de validação do framework

| <i>Participante</i> | <i>Idade</i> | <i>Formação</i>                                                 | <i>Atuação</i>                                                                                 | <i>Experiência</i>                                                                           |
|---------------------|--------------|-----------------------------------------------------------------|------------------------------------------------------------------------------------------------|----------------------------------------------------------------------------------------------|
| <i>P1</i>           | 38           | Mestre em Ciência da computação                                 | Modelagem de algoritmos preditivos.                                                            | Integração prática entre ciência de dados e operação urbana.                                 |
| <i>P2</i>           | 35           | Engenheiro de Computação                                        | Desenvolvimento, implementação e monitoramento de modelos preditivos em ambiente produtivo.    | Ênfase em ML, versionamento e validação contínua dos modelos.                                |
| <i>P3</i>           | 26           | Bacharel em Sistemas de Informação                              | Pré-processamento de dados, testes de modelos e documentação técnica.                          | Avaliação da clareza e aplicabilidade do framework para profissionais em início de carreira. |
| <i>P4</i>           | 41           | Graduado em Análise de Sistemas, MBA em Arquitetura de Soluções | Integração entre infraestrutura tecnológica, desenvolvimento de soluções e suporte a sistemas. | Análise da viabilidade organizacional e técnica da implementação do framework.               |
| <i>P5</i>           | 37           | Bacharel em engenharia da computação                            | Desenvolvimento de pipelines de dados, integração de modelos de ML com plataformas web.        | Contribuições voltadas à eficiência computacional, de modelos preditivos.                    |

Fonte: Elaborado pela autora.

Com base nas contribuições dos especialistas, foi validado de forma conceitual e operacionalmente os elementos do framework. O modelo apresentou coerência interna e aderência às condições técnicas da logística urbana inteligente, ao mesmo tempo em que as falas destacaram sua viabilidade de aplicação e os pontos críticos para adoção institucional. Essa etapa encerrou a fase de avaliação, com a incorporação dos ajustes ao framework final. O capítulo seguinte apresenta os resultados das três etapas empíricas, reunindo entrevistas, análises estatísticas e interpretações integradas à construção do modelo.

## 4 RESULTADOS

No contexto da DSR, este capítulo corresponde à fase de comunicação, na qual os resultados da pesquisa são apresentados de forma estruturada, tornando explícito o percurso metodológico e os achados obtidos. O objetivo desta etapa é transmitir, de maneira clara e fundamentada, as evidências empíricas que sustentaram a construção, o refinamento e a validação do framework proposto, assegurando sua compreensão por parte da comunidade acadêmica e de profissionais da área.

Este capítulo apresenta, de forma sistematizada, os resultados obtidos nas três etapas empíricas da pesquisa: entrevistas em profundidade (Etapa 1), aplicação de questionário estruturado (Etapa 2) e entrevistas para validação do framework (Etapa 3). O objetivo foi organizar os achados de maneira clara e objetiva, preservando sua integridade empírica, sem ainda adentrar a análise crítica ou comparação com a literatura, o que será desenvolvido no capítulo seguinte.

A comunicação dos resultados segue a ordem cronológica da coleta de dados, iniciando com a síntese das entrevistas qualitativas, passando pela sistematização das respostas do questionário e finalizando com os apontamentos advindos da validação do framework. As falas dos participantes da Etapa 1 são destacadas entre aspas, acompanhadas de suas identificações codificadas, conforme o protocolo de anonimato adotado nesta pesquisa.

### 4.1 RESULTADOS DAS ENTREVISTAS COMO SUPORTE À CONSTRUÇÃO DO FRAMEWORK

A estratégia analítica adotada nesta etapa da pesquisa compreende três fases principais: redução dos dados, apresentação dos dados e formulação de conclusões e verificações. Segundo Yin (2010), os dados qualitativos tendem a ser volumosos. Neste estudo, foram realizadas cinco entrevistas estruturadas, com duração entre trinta minutos e uma hora, o que resultou em diversas páginas de transcrições. Assim, a primeira etapa consistiu na redução dos dados, com o objetivo de extrair a essência das informações coletadas.

A primeira etapa da análise consistiu na redução dos dados brutos obtidos nas entrevistas em profundidade, conforme sugerido por Miles & Huberman (1994) e Yin (2010). Esse processo envolveu uma série de operações sistemáticas voltadas à organização, abstração e



síntese das informações narrativas, com o objetivo de tornar os dados mais manejáveis e analiticamente úteis.

Inicialmente, foi realizada a delimitação dos dados relevantes, por meio da leitura flutuante e posterior leitura intensiva das transcrições. Trechos repetitivos, inconclusivos ou periféricos ao problema de pesquisa foram eliminados, a fim de focar nas falas que apresentavam relação direta com os objetivos do estudo. Em seguida, os conteúdos foram codificados e categorizados, com base nos blocos temáticos dos roteiros (uso de dados, experiência com aprendizado de máquina, barreiras percebidas, papel dos SSDs e diretrizes para o framework). Essa categorização foi tanto dedutiva (a partir da literatura) quanto indutiva (emergente das contribuições dos participantes).

O Quadro 5, os entrevistados relataram que a maioria das decisões logísticas urbanas ainda é tomada de forma reativa e sem base técnica estruturada. A ausência de diagnóstico, a pressão política e a carência de indicadores dos objetivos foram apontados como entraves frequentes na priorização de ações e alocação de recursos.

Quadro 5 – Identificação de problemas urbanos

| Participante  | Contribuição                                                                                                                                       |
|---------------|----------------------------------------------------------------------------------------------------------------------------------------------------|
| $\delta$      | “A gente costuma atuar no improviso. Muitas vezes o que define a prioridade não é o impacto urbano, mas a pressão política ou a demanda imediata.” |
| $\varepsilon$ | “Falta um diagnóstico estruturado. Tem problema que se arrasta por anos, mas ninguém consegue quantificar o impacto para justificar investimento.” |

Fonte: Elaborado pela autora.

Houve consenso entre os participantes sobre a existência de disparidades significativas entre instituições públicas quanto à capacidade de adotar soluções baseadas em dados. Foram mencionadas barreiras técnicas, como infraestrutura deficiente, além de lacunas normativas e ausência de cultura organizacional voltada à inovação tecnológica evidenciado no Quadro 6.

Quadro 6 – Maturidade institucional

| Participante | Contribuição                                                                                                         |
|--------------|----------------------------------------------------------------------------------------------------------------------|
| $\alpha$     | “Não adianta tentar implementar <i>Machine Learning</i> se a prefeitura ainda está organizando planilha no Excel.”   |
| $\beta$      | “A maturidade digital varia muito entre os órgãos. Em alguns, nem a rede interna suporta um sistema mais robusto.”   |
| $\delta$     | “A legislação é outro ponto: já vimos projetos barrados por falta de respaldo jurídico para uso de dados sensíveis.” |

Fonte: Elaborado pela autora.

A fragmentação e a baixa padronização das bases de dados públicas foram apontadas como um dos principais desafios. O Quadro 7, os participantes relataram dificuldades em localizar, validar e integrar informações de diferentes setores, comprometendo a confiabilidade dos dados para uso analítico.

Quadro 7 – Compreensão e mapeamento dos dados

| Participante  | Contribuição                                                                                   |
|---------------|------------------------------------------------------------------------------------------------|
| $\gamma$      | “Existem dados, mas não sabemos exatamente o que temos, onde estão, nem se podemos confiar.”   |
| $\beta$       | “Muitos dados foram produzidos para prestação de contas, não para tomada de decisão.”          |
| $\varepsilon$ | “A fragmentação das bases dificulta a integração. Cada setor trabalha com seu próprio padrão.” |

Fonte: Elaborado pela autora.

A fase de preparação dos dados foi destacada como essencial para garantir a validade das análises. No Quadro 8, os especialistas enfatizaram a necessidade de padronização, limpeza e anonimização das bases, especialmente quando se lida com informações heterogêneas oriundas de sistemas públicos.

Quadro 8 – Preparação e organização dos dados

| Participante  | Contribuição                                                                                          |
|---------------|-------------------------------------------------------------------------------------------------------|
| $\alpha$      | “A modelagem começa pela base. Sem tratamento mínimo dos dados, o resultado é ruído.”                 |
| $\delta$      | “É preciso garantir padronização, anonimização e algum grau de validação antes de pensar em modelar.” |
| $\varepsilon$ | “Os dados vêm de fontes diferentes e com formatos variados. É um desafio organizacional também.”      |

Fonte: Elaborado pela autora.

Os participantes apontaram que a implementação de modelos de ML no setor público deve considerar a simplicidade, o custo computacional e a viabilidade técnica. No Quadro 9, o uso de modelos robustos, porém acessíveis, foi defendido como condição prática para adoção institucional.

Quadro 9 – Desenvolvimento do modelo preditivo

| Participante  | Contribuição                                                                                             |
|---------------|----------------------------------------------------------------------------------------------------------|
| $\beta$       | “A gente não pode esperar que o setor público implemente ML completos. Tem que ser funcional e simples.” |
| $\gamma$      | “Modelos com bom desempenho e baixo custo computacional são os mais viáveis.”                            |
| $\varepsilon$ | “É importante que haja algum tipo de validação, mesmo que simplificada. Nem tudo precisa ser complexo.”  |

Fonte: Elaborado pela autora.

O Quadro 10 mostra a unanimidade que a percepção de que a utilidade dos modelos depende de sua tradução em interfaces acessíveis e informativas. A clareza na visualização dos resultados foi apontada como um fator determinante para que as recomendações geradas pelos modelos sejam incorporadas à rotina decisória.

Quadro 10 – Integração com SSD

| Participante  | Contribuição                                                                                    |
|---------------|-------------------------------------------------------------------------------------------------|
| $\alpha$      | “Se o modelo não entrega algo visual e direto, ele não chega ao gestor. Interface é essencial.” |
| $\beta$       | “Não adianta entregar um modelo se ninguém entende o que ele está dizendo.”                     |
| $\gamma$      | “Dashboards simples, com alertas e mapas de calor, ajudam muito na hora da decisão.”            |
| $\delta$      | “A interface é o elo entre o dado e a política pública. Sem isso, o modelo fica parado.”        |
| $\varepsilon$ | “Os tomadores de decisão não vão interpretar código. Precisam de painéis claros e objetivos.”   |

Fonte: Elaborado pela autora.

Os especialistas enfatizaram que a implementação de soluções analíticas depende também de fatores humanos e institucionais mostrado no Quadro 11, além disso, barreiras culturais, falta de capacitação e ausência de envolvimento das equipes desde o início do processo foram mencionadas como fatores críticos de insucesso.

Quadro 11 – Adoção, capacitação e ajustes

| Participante  | Contribuição                                                                                   |
|---------------|------------------------------------------------------------------------------------------------|
| $\beta$       | “Se o servidor não entender para que serve o modelo, ele vai sabotar ou simplesmente ignorar.” |
| $\varepsilon$ | “A capacitação tem que ser contínua. É uma mudança de cultura.”                                |
| $\alpha$      | “É preciso envolver os setores desde o início, para garantir que a ferramenta faça sentido.”   |

Fonte: Elaborado pela autora.

Por fim, os entrevistados defenderam a importância de mecanismos contínuos de validação e revisão do artefato. Indicadores de impacto e ciclos periódicos de atualização foram vistos como estratégias indispensáveis para assegurar a sustentabilidade do modelo no longo prazo como mostra o Quadro 12.

Quadro 12 – Validação e retroalimentação

| Participante  | Contribuição                                                                      |
|---------------|-----------------------------------------------------------------------------------|
| $\gamma$      | “Se não medir o impacto, o projeto morre. Tem que mostrar que faz diferença.”     |
| $\alpha$      | “Indicadores simples como tempo de resposta e adesão ao sistema já ajudam.”       |
| $\varepsilon$ | “Revisar o modelo periodicamente é o que garante a atualização e o uso contínuo.” |

Fonte: Elaborado pela autora.

Na sequência da análise qualitativa, as falas foram organizadas no Quadro 13, o que permitiu categorizar e interpretar as respostas de maneira sistemática. Esse processo de redução dos dados viabilizou uma leitura analítica aprofundada, alinhada ao propósito de construir um framework teoricamente fundamentado e adaptado às condições reais da gestão urbana.

Quadro 13 – Respostas por participante

| <i>Categoria/Participante</i>  | <i>Alfa</i>                                                                 | <i>Beta</i>                                                                | <i>Gama</i>                                                                 | <i>Delta</i>                                                                  | <i>Épsilon</i>                                                               |
|--------------------------------|-----------------------------------------------------------------------------|----------------------------------------------------------------------------|-----------------------------------------------------------------------------|-------------------------------------------------------------------------------|------------------------------------------------------------------------------|
| <i>Uso de dados Urbanos</i>    | Experiência pontual com mobilidade urbana                                   | Atua com dados hospitalares, pouco urbano                                  | Experiência em projetos com acessibilidade e dados operacionais urbanos.    | Uso de indicadores e mapas para planejamento urbano.                          | Uso de KPIs fiscais e planejamento estratégico de projetos.                  |
| <i>Contato com ML aplicado</i> | Atuação com modelos supervisionados, com foco em classificação e automação. | Utiliza previsões básicas em dashboards; contato indireto com ML.          | Coordena aplicação de ML em contextos financeiros e urbanos.                | Sem aplicação direta de ML; entende potencial, mas carece de suporte técnico. | Reconhece valor do ML, mas não aplicou na prática; precisa ser validado.     |
| <i>Barreiras percebidas</i>    | Necessidade de sistemas cíclicos que atualizem modelos com dados contínuos. | Falta cultura analítica, integração entre sistemas e equipe especializada. | Ruído, baixa padronização e desafios de infraestrutura são barreiras-chave. | Limitações de equipe, ferramentas e excesso de burocracia.                    | Barreiras institucionais, falta de orçamento e alta rotatividade de pessoal. |
| <i>Papel dos SSDs</i>          | Essencial para tornar modelos interpretáveis; defende visualização clara.   | Importância de ferramentas com linguagem acessível e simples.              | SSD deve traduzir modelos em recomendações acionáveis para gestores.        | Ferramenta fundamental para decisões públicas; precisa gerar confiança.       | Importância de visualizações objetivas e justificativas embasadas.           |

|                                       |                                                                             |                                                                             |                                                                               |                                                                                 |                                                                               |
|---------------------------------------|-----------------------------------------------------------------------------|-----------------------------------------------------------------------------|-------------------------------------------------------------------------------|---------------------------------------------------------------------------------|-------------------------------------------------------------------------------|
| <i>Expectativas sobre o framework</i> | Framework cíclico, com explicações técnicas, e integração com fluxos reais. | Ferramentas de fácil uso e justificativa técnica clara para adoção pública. | Framework adaptável, com atualização automatizada e integração institucional. | Interface amigável, foco em cenários de decisão e usabilidade no setor público. | Ferramentas com aplicabilidade direta, linguagem clara e viabilidade prática. |
|---------------------------------------|-----------------------------------------------------------------------------|-----------------------------------------------------------------------------|-------------------------------------------------------------------------------|---------------------------------------------------------------------------------|-------------------------------------------------------------------------------|

Fonte: Elaborado pela autora.

As análises e interpretações relacionadas a esses achados serão aprofundadas no Capítulo 5, onde os dados serão discutidos à luz do referencial teórico e dos objetivos da pesquisa.

## 4.2 RESULTADOS DO QUESTIONÁRIO NA ETAPA DE AVALIAÇÃO DO FRAMEWORK

Concluída a etapa qualitativa da pesquisa, se seguiu para a aplicação de um questionário estruturado com o objetivo de avaliar, complementar e consolidar os elementos do framework teórico desenvolvido. As afirmações que compõem o instrumento foram elaboradas com base nas categorias emergentes das entrevistas e nos desafios identificados na literatura. Cada uma delas foi avaliada por especialistas por meio de escala de Likert de cinco pontos, variando entre 1 (discordo totalmente) e 5 (concordo totalmente), a fim de mensurar o grau de concordância com os pressupostos do modelo proposto.

A organização das afirmativas seguiu uma lógica de blocos temáticos, correspondentes às etapas do framework, possibilitando uma leitura analítica por dimensão conceitual. A estruturação em blocos permitiu, ainda, avaliar a consistência do modelo em diferentes níveis: diagnóstico urbano, condições técnicas, integração com sistemas de suporte à decisão e viabilidade de aplicação em contextos institucionais diversos.

Para garantir a consistência e a clareza das inferências, a análise dos dados foi conduzida a partir de medidas de tendência central (média e mediana) e dispersão (desvio-padrão), associadas à visualização gráfica das respostas. O tratamento estatístico foi realizado com o apoio da linguagem Python e bibliotecas especializadas.

Para realizar a análise estatística dos dados provenientes do questionário foi utilizada a linguagem de programação Python, reconhecida por sua versatilidade e eficiência no tratamento de dados e geração de visualizações. Para garantir a reprodutibilidade e precisão dos resultados, foram empregadas bibliotecas especializadas amplamente validadas na comunidade científica,

como as descritas no Quadro 14. Esse conjunto de ferramentas é referenciado por Virtanen et al. (2020) como parte do ecossistema da ciência de dados em Python.

Quadro 14 – Bibliotecas Python utilizadas na análise estatística

| <b>Biblioteca</b> | <b>Descrição</b>                                                                                              | <b>Referência</b>     |
|-------------------|---------------------------------------------------------------------------------------------------------------|-----------------------|
| <i>Pandas</i>     | Manipulação e análise de dados tabulares. Permite leitura de arquivos, organização e cálculo de estatísticas. | MCKINNEY, 2010        |
| <i>Seaborn</i>    | Visualização estatística. Facilita a criação de gráficos como boxplots, mapas de calor e distribuições.       | WASKOM, 2021          |
| <i>Matplotlib</i> | Biblioteca base para visualização gráfica. Auxilia na personalização de gráficos, eixos, cores e legendas.    | HUNTER, 2007          |
| <i>SciPy</i>      | Realização de análises estatísticas, testes de hipótese, correlações e outras funções científicas avançadas.  | VIRTANEN et al., 2020 |

Fonte: Elaborado pela autora.

O uso combinado dessas ferramentas viabilizou uma análise automatizada, precisa e replicável, como recomenda a literatura de pesquisa aplicada em estudos com abordagem quantitativa (Cooper; Schindler, 2003 & Hair et al., 2005). O questionário, composto por 21 afirmações avaliadas em escala de Likert de cinco pontos, foi segmentado em cinco blocos temáticos, alinhados às dimensões estruturantes do framework proposto. Cada bloco foi tratado estatisticamente com base nas seguintes etapas: 1) importação dos dados via Pandas a partir de uma planilha Excel contendo as respostas; 2) categorização das variáveis em blocos, com agrupamento temático; 3) cálculo das medidas descritivas (média, mediana e desvio-padrão) por bloco; 4) geração de gráficos de barras, visando facilitar a visualização dos padrões de concordância entre os participantes.

A etapa de análise quantitativa buscou identificar o grau de concordância dos respondentes com os pressupostos teóricos do framework, segmentando as afirmações em blocos temáticos alinhados às principais dimensões da proposta. Cada bloco foi analisado com base em medidas descritivas (média, mediana, desvio-padrão) e complementado com visualizações gráficas geradas via Python.

Para sintetizar os resultados obtidos no questionário, as respostas das 21 afirmações foram organizadas na Tabela 1, agrupadas conforme os cinco blocos temáticos previamente definidos: (1) problemas urbanos e subutilização de dados; (2) infraestrutura de dados e limitações técnicas; (3) potencial de aplicação de ML; (4) cultura institucional; e (5) infraestrutura tecnológica.

Tabela 1 - Resultados consolidados do questionário

| Bloco | Questão | Afirmção                                                                            | Média | Mediana | Desvio Padrão |
|-------|---------|-------------------------------------------------------------------------------------|-------|---------|---------------|
| 1     | Q4      | A cidade enfrenta desafios logísticos urbanos não diagnosticados.                   | 4,4   | 5,0     | 0,89          |
| 1     | Q5      | Os dados urbanos existentes não são utilizados para orientar decisões.              | 4,2   | 5,0     | 0,84          |
| 1     | Q6      | Não há uma cultura de uso de dados para definir prioridades urbanas.                | 4,27  | 5,0     | 0,88          |
| 2     | Q7      | Os dados urbanos são fragmentados e difíceis de integrar.                           | 4,5   | 5,0     | 0,53          |
| 2     | Q8      | Falta padronização e documentação nas bases públicas de dados.                      | 4,3   | 4,0     | 0,85          |
| 2     | Q9      | Há dificuldades técnicas para consolidar dados de diferentes setores.               | 4,6   | 5,0     | 0,84          |
| 3     | Q10     | O uso de ML pode melhorar a eficiência da logística urbana.                         | 4,5   | 5,0     | 0,53          |
| 3     | Q11     | As previsões feitas por modelos de ML são de difícil interpretação.                 | 3,9   | 4,0     | 0,81          |
| 3     | Q12     | A aplicação de ML depende da clareza dos resultados para os gestores.               | 4,1   | 4,0     | 0,73          |
| 3     | Q13     | A interpretação dos resultados de ML é um desafio para equipes públicas.            | 4,2   | 4,0     | 0,79          |
| 3     | Q14     | Soluções baseadas em ML devem considerar o contexto urbano.                         | 4,5   | 5,0     | 0,63          |
| 4     | Q15     | A adoção de ML enfrenta resistência institucional.                                  | 4,3   | 5,0     | 0,78          |
| 4     | Q16     | Falta cultura analítica nas instituições públicas.                                  | 4,4   | 5,0     | 0,83          |
| 4     | Q17     | A inovação tecnológica é vista com desconfiança por gestores.                       | 4,2   | 4,0     | 0,91          |
| 4     | Q18     | O uso de SSDs ainda é limitado no setor público.                                    | 4,1   | 4,0     | 0,82          |
| 4     | Q19     | Capacitar servidores é essencial para adoção de ML.                                 | 4,4   | 5,0     | 0,89          |
| 5     | Q20     | É necessário um ambiente minimamente preparado para aplicar ML.                     | 4,6   | 5,0     | 0,71          |
| 5     | Q21     | A infraestrutura tecnológica impacta diretamente a eficácia dos modelos preditivos. | 4,4   | 4,0     | 0,70          |

Fonte: Elaborado pela autora.

A consolidação das respostas evidencia que, no Bloco 1, os participantes reconhecem amplamente a existência de gargalos na gestão urbana e a subutilização dos dados para orientar decisões logísticas, com médias elevadas ( $\geq 4,2$ ) e medianas de 5,0. Contudo, a presença de desvios-padrão próximos a 0,9 indica certa heterogeneidade nas percepções, possivelmente associada a diferentes níveis de familiaridade com a gestão pública ou acesso aos dados.

No Bloco 2, a concordância com afirmações sobre a fragmentação e a falta de padronização das bases de dados reforça um dos principais entraves identificados na etapa qualitativa. As médias acima de 4,3 e a baixa dispersão das respostas sugerem consenso de que

as limitações estruturais comprometem a integração intersetorial, dificultando o uso estratégico das informações.

O Bloco 3 revela uma percepção positiva quanto ao potencial do ML para otimizar a logística urbana (médias de até 4,5), mas expõe desafios ligados à interpretação dos resultados e à necessidade de contextualização das soluções. A menor média (3,9, Q11) indica que a complexidade técnica ainda é vista como barreira relevante, alinhando-se a achados da literatura sobre explicabilidade de modelos.

No Bloco 4, aspectos culturais e institucionais aparecem como fatores críticos: resistência à inovação, falta de cultura analítica e uso limitado de SSDs no setor público. Apesar disso, o reconhecimento da importância da capacitação de servidores (média 4,4) sugere abertura para superar essas barreiras mediante investimentos em qualificação.

Por fim, o Bloco 5 aponta quase unanimidade quanto à necessidade de infraestrutura tecnológica adequada para viabilizar ML e SSDs, com médias elevadas ( $\geq 4,4$ ) e baixa dispersão, evidenciando que, para os participantes, a disponibilidade de recursos tecnológicos é condição indispensável para que o framework proposto possa ser implementado de forma efetiva.

A consolidação dos resultados nos cinco blocos apresentados oferece um panorama quantitativo das percepções dos participantes quanto aos problemas urbanos, à qualidade e à utilização dos dados, ao potencial do ML, à cultura institucional e às condições tecnológicas. Essas informações serviram de base para a próxima etapa da pesquisa, na qual serão analisadas as implicações desses achados para a validação do framework proposto.

#### 4.3 RESULTADOS DAS ENTREVISTAS PARA A VALIDAÇÃO DO FRAMEWORK

A terceira etapa da pesquisa consistiu na validação do framework por meio de entrevistas estruturadas com cinco especialistas da área de tecnologia, todos atuantes em uma empresa dedicada ao desenvolvimento de soluções para mobilidade urbana. Os participantes foram convidados a analisar criticamente o modelo proposto com base em critérios como clareza, aplicabilidade, completude, impacto e sugestões de melhoria.

As contribuições foram organizadas por agrupamentos temáticos, de acordo com as oito etapas que compõem o framework. Cada bloco é apresentado a seguir com base nas falas dos entrevistados.



A primeira contribuição recorrente diz respeito ao início do ciclo decisório. Os participantes reforçaram a importância de um diagnóstico institucional claro antes da aplicação de soluções baseadas em dados, considerando a realidade técnica e cultural das instituições.

Quadro 15 – Contribuição sobre início do ciclo e maturidade institucional

| Participante | Contribuição                                                                                                                                         |
|--------------|------------------------------------------------------------------------------------------------------------------------------------------------------|
| P1           | “O ciclo faz sentido. Mas, para validar de fato, seria interessante pensar em indicadores operacionais, tipo tempo de resposta e redução de falhas.” |
| P4           | “A maturidade institucional precisa ser medida com critérios claros. Às vezes, o problema não está na técnica, mas na cultura da instituição.”       |

Fonte: Elaborado pela autora.

As etapas relacionadas ao levantamento, compreensão e preparação dos dados também foram foco de atenção. Os especialistas enfatizaram a dificuldade de trabalhar com bases públicas heterogêneas e a importância de processos mínimos de padronização e limpeza de dados antes da modelagem.

Quadro 16 – Contribuição sobre dados e infraestrutura

| Participante | Contribuição                                                                                                                         |
|--------------|--------------------------------------------------------------------------------------------------------------------------------------|
| P4           | “A compatibilidade com a infraestrutura é essencial. E vale reforçar a parte de padronização dos dados logo na etapa de preparação.” |
| P2           | “Existem muitos dados brutos. Mas organizar, limpar e padronizar isso tudo demanda esforço e, muitas vezes, não está previsto.”      |

Fonte: Elaborado pela autora.

No desenvolvimento do modelo preditivo, foi sugerido que o framework mantenha foco em soluções simples, com indicadores básicos de desempenho, evitando a dependência de estruturas complexas como ML.

Quadro 17 – Contribuição sobre modelagem preditivo

| Participante | Contribuição                                                                                                                            |
|--------------|-----------------------------------------------------------------------------------------------------------------------------------------|
| P2           | “Gostei da separação entre preparação, modelagem e integração. Acho que dá para usar checkpoints simples, sem precisar de ML completo.” |
| P5           | “Faria sentido medir coisas como tempo de processamento e frequência de reprocessamento. São parâmetros simples, mas úteis.”            |

Fonte: Elaborado pela autora.

As interfaces entre o modelo preditivo e os gestores públicos foram apontadas como pontos críticos para garantir o uso prático das informações geradas. Houve sugestões de recursos visuais que tornem os dados acessíveis a usuários não técnicos.

Quadro 18 – Contribuição sobre visualização e SSD

| <b>Participante</b> | <b>Contribuição</b>                                                                                                                       |
|---------------------|-------------------------------------------------------------------------------------------------------------------------------------------|
| <b>P3</b>           | “O framework está claro. Para facilitar a comunicação com gestores, poderia incluir exemplos visuais, como dashboards ou mapas de calor.” |
| <b>P1</b>           | “A interface é o elo entre o dado e a política pública. Sem isso, o modelo fica parado.”                                                  |

Fonte: Elaborado pela autora.

Com relação à adoção institucional, os entrevistados destacaram a importância da capacitação contínua e do engajamento dos setores desde as fases iniciais do processo.

Quadro 19 – Contribuição sobre capacitação e engajamento

| <b>Participante</b> | <b>Contribuição</b>                                                                          |
|---------------------|----------------------------------------------------------------------------------------------|
| <b>P3</b>           | “A capacitação tem que ser contínua. É uma mudança de cultura.”                              |
| <b>P4</b>           | “É preciso envolver os setores desde o início, para garantir que a ferramenta faça sentido.” |

Fonte: Elaborado pela autora.

Por fim, os participantes sugeriram que a etapa de validação de resultados e retroalimentação inclua métricas objetivas e práticas de revisão periódica, de modo a garantir a atualização do modelo ao longo do tempo.

Quadro 20 – Contribuição sobre impacto e revisão contínua

| <b>Participante</b> | <b>Contribuição</b>                                                               |
|---------------------|-----------------------------------------------------------------------------------|
| <b>P3</b>           | “Se não medir o impacto, o projeto morre. Tem que mostrar que faz diferença.”     |
| <b>P1</b>           | “Indicadores simples como tempo de resposta e adesão ao sistema já ajudam.”       |
| <b>P5</b>           | “Revisar o modelo periodicamente é o que garante a atualização e o uso contínuo.” |

Fonte: Elaborado pela autora.

O conjunto de contribuições apresentadas nas etapas anteriores permitiu consolidar percepções práticas e técnicas relevantes para o aprimoramento do framework, incluindo a importância de métricas objetivas e processos de revisão periódica para sua atualização contínua. Com base nos dados coletados e nos fundamentos teóricos discutidos, a análise e discussão dos resultados foi realizada conforme exposto na Capítulo 5, buscando interpretar as evidências à luz da literatura e avaliar a aderência da pesquisa aos desafios da logística urbana.

## 5 ANÁLISE DOS RESULTADOS

Este capítulo apresenta a análise e a discussão dos dados obtidos ao longo das três etapas empíricas da pesquisa: entrevistas em profundidade com especialistas, aplicação do questionário estruturado e condução de entrevistas para validação do framework teórico. A estrutura adotada segue a lógica iterativa da DSR, na qual os dados coletados servem não apenas para compreender o fenômeno estudado, mas também para orientar a construção, refinamento e validação do artefato proposto.

As entrevistas permitiram a identificação dos principais desafios enfrentados na logística urbana, bem como das percepções sobre a aplicação de SSDs com recursos de ML nesse contexto. A partir dessas evidências qualitativas, foi possível definir critérios norteadores para o desenvolvimento do artefato.

Na etapa seguinte, o questionário estruturado foi utilizado para mensurar o grau de concordância dos participantes em relação aos critérios identificados, promovendo um aprofundamento da análise sob uma perspectiva quantitativa. Esses dados permitiram refinar as etapas e funcionalidades do artefato proposto, aumentando sua aderência às necessidades reais dos usuários.

Por fim, a terceira etapa envolveu a realização de entrevistas estruturadas com especialistas que já haviam participado das fases anteriores, a fim de validar o artefato construído. Essa abordagem possibilitou uma avaliação crítica de sua aplicabilidade, clareza, coerência e completude, além de permitir ajustes finais com base em um processo participativo.

Dessa forma, esta seção está organizada para apresentar os resultados de cada etapa de forma sequencial, evidenciando como os dados coletados contribuíram para o desenvolvimento iterativo do artefato, em consonância com os princípios da DSR (Hevner et al., 2004; Peffers et al., 2007; Vaishnavi & Kuechler, 2004).

### 5.1 ANÁLISE DAS ENTREVISTAS COMO SUPORTE À CONSTRUÇÃO DO FRAMEWORK

Com base nas entrevistas realizadas com os cinco participantes, foram identificados seis etapas que orientaram a construção e o refinamento do framework proposto. Essas contribuições permitiram estruturar o modelo de forma a refletir tanto os desafios da gestão

pública urbana quanto as exigências técnicas para a aplicação de modelos de ML integrados a SSD.

A primeira etapa (i), Identificação do Problema Urbano, foi sustentada principalmente pelas contribuições dos participantes com atuação na gestão pública, os quais destacaram as dificuldades enfrentadas na priorização de projetos urbanos, em especial os voltados à mobilidade e à pavimentação. O participante  $\delta$  mencionou a escassez de ferramentas técnicas para tomada de decisão e os entraves orçamentários como fatores que comprometem a efetividade da gestão. Já o participante  $\varepsilon$  ressaltou a importância de um modelo que ofereça clareza técnica, alinhamento institucional e respaldo orçamentário, facilitando decisões mais ágeis e justificadas. Essas percepções foram mobilizadas a partir da questão: “Quais características você considera essenciais para um modelo que oriente decisões orçamentárias em projetos logísticos urbanos?”

A segunda etapa (ii), compreensão dos dados públicos disponíveis, surgiu da percepção recorrente de limitações estruturais nos dados urbanos. O participante  $\beta$  apontou que tais dados, frequentemente utilizados em projetos com enfoque em cidades, costumam apresentar baixa padronização, inconsistência e ausência de metadados, o que compromete seu uso analítico. O participante  $\varepsilon$  complementou esse diagnóstico ao afirmar que, mesmo quando disponíveis, esses dados raramente são utilizados como referência técnica para licitações, devido à dificuldade de acesso e à fragilidade da origem institucional. Essas contribuições foram motivadas pela pergunta: “Quais são as principais dificuldades técnicas em trabalhar com dados urbanos?”

A terceira etapa (iii), Preparação dos Dados Urbanos, foi fortemente enfatizada pelos especialistas técnicos. O participante  $\gamma$  observou que os dados urbanos, por sua natureza heterogênea e ruidosa, requerem procedimentos rigorosos de limpeza, padronização e integração antes de serem utilizados em modelos preditivos. O participante  $\alpha$  reforçou esse ponto ao afirmar que, sem uma preparação adequada, os modelos de ML se tornam instáveis e pouco confiáveis. Essa etapa foi desenvolvida a partir da seguinte questão: “Quais cuidados devem ser considerados antes de aplicar modelos de ML em dados urbanos?”

A quarta etapa (iv), Modelagem Preditiva com Aprendizado de Máquina, foi construída com base nas contribuições dos participantes  $\alpha$  e  $\gamma$ , que sugeriram a adoção de algoritmos

supervisionados, como *Random Forest* por sua interpretabilidade e capacidade de adaptação a diferentes contextos operacionais. Ambos destacaram que os modelos devem ser sensíveis à variabilidade das dinâmicas urbanas, permitindo ajustes frequentes e sustentando sua aplicabilidade em ambientes com alta complexidade. A discussão foi conduzida a partir da pergunta: “Qual abordagem de modelagem você considera mais apropriada ao contexto urbano?”

A quinta etapa (v), Interface com SSD, foi sustentada pela convergência entre participantes técnicos e gestores. O participante  $\beta$  enfatizou que não é viável esperar que gestores públicos operem diretamente com predições estatísticas ou scripts técnicos, sendo essencial dispor de dashboards, mapas de calor e relatórios visuais que traduzam os resultados dos modelos para uma linguagem acessível. O participante  $\varepsilon$  endossou essa visão, destacando que a simplicidade e o alinhamento legal são fundamentais para garantir a adoção da ferramenta. A questão orientadora foi: “Como a interface de um SSD pode facilitar o uso de modelos por gestores públicos?”

A sexta etapa (vi), Validação e Retroalimentação, emergiu da ênfase na necessidade de manutenção contínua do modelo ao longo do tempo. O participante  $\alpha$  sugeriu que a sustentabilidade do framework está condicionada à sua capacidade de adaptação, por meio de ciclos periódicos de atualização e feedback. O participante  $\gamma$  complementou, propondo que a validação envolva tanto métricas técnicas quanto a percepção dos usuários finais, assegurando a adequação entre a solução tecnológica e as exigências operacionais das instituições. Esse componente do framework foi construído a partir da pergunta: “Como o framework pode se manter útil e confiável ao longo do tempo?”

A sistematização dessas contribuições está sintetizada na Quadro 21, a qual relaciona as principais etapas do framework com as perguntas norteadoras, as interpretações extraídas das entrevistas.


Quadro 21 - Contribuições dos participantes por etapas do framework

| <i>Etapas do framework</i>                        | <i>Pergunta</i>                                                                                                                   | <i>Descrição</i>                                                                                                                                                  |
|---------------------------------------------------|-----------------------------------------------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| <i>Identificação do Problema Urbano</i>           | Quais características você considera essenciais para um modelo que oriente decisões orçamentárias em projetos logísticos urbanos? | Gestores relataram dificuldades para priorizar projetos devido à falta de ferramentas e recursos. A etapa inicial deve captar as demandas reais da gestão urbana. |
| <i>Compreensão dos Dados Públicos Disponíveis</i> | Quais são as principais dificuldades técnicas em trabalhar com dados urbanos?                                                     | Especialistas apontaram problemas como baixa padronização e inconsistência dos dados, justificando uma etapa dedicada à compreensão das bases disponíveis.        |
| <i>Preparação dos Dados Urbanos</i>               | Quais cuidados devem ser considerados antes de aplicar modelos de ML em dados urbanos?                                            | Técnicos destacaram a necessidade de limpeza e padronização dos dados antes da modelagem, devido à heterogeneidade dos dados urbanos.                             |
| <i>Modelagem Preditiva</i>                        | Qual abordagem de modelagem você considera mais apropriada ao contexto urbano?                                                    | Os participantes recomendaram algoritmos supervisionados, por sua capacidade de interpretação e ajuste contínuo aos contextos urbanos.                            |
| <i>Interface com SSD</i>                          | Como a interface de um SSD pode facilitar o uso de modelos por gestores públicos?                                                 | Defendida a importância de dashboards e visualizações claras que traduzam previsões para linguagem acessível aos gestores públicos.                               |
| <i>Validação e Retroalimentação</i>               | Como o framework pode se manter útil e confiável ao longo do tempo?                                                               | Sugerida a inclusão de ciclos de feedback com métricas técnicas e validação dos usuários, garantindo atualização e aderência prática.                             |

Fonte: Elaborado pela autora.

O framework resultante, consolidado a partir das contribuições colhidas nas entrevistas e da fundamentação teórica desta pesquisa, foi estruturado em formato cíclico. Sua organização contempla etapas sequenciais que conectam os dados urbanos à formulação de decisões apoiadas por tecnologia. A Figura 6 apresenta a representação visual da proposta, evidenciando a dinâmica iterativa do modelo e os elementos centrais de cada fase. O papel dos sistemas de suporte à decisão se destaca como componente articulador entre os processos de modelagem preditiva e as demandas práticas da gestão pública.

Figura 6 – Framework após contribuições da etapa 1



Fonte: Elaborado pela autora.

A etapa qualitativa permitiu reunir insumos teóricos e práticos fundamentais para a construção do framework, refletindo tanto os desafios identificados na gestão pública urbana quanto as exigências técnicas para aplicação de ML e SSDs. Encerrada essa fase, a pesquisa avançou para a etapa quantitativa, descrita na Seção 5.2, na qual se buscou avaliar e complementar os elementos definidos a partir das entrevistas.

## 5.2 ANÁLISE DOS QUESTIONÁRIOS NA ETAPA DE AVALIAÇÃO DO FRAMEWORK

Esta seção apresenta os resultados da etapa quantitativa, organizados de forma a evidenciar as percepções dos participantes. As respostas foram agrupadas em cinco blocos temáticos, permitindo identificar tendências, convergências e divergências relevantes para o refinamento do framework.

O Bloco 1, referente aos problemas urbanos e à subutilização de dados, evidencia que a ausência de diagnóstico logístico baseado em dados permanece como uma fragilidade estrutural nas práticas de gestão pública. A média elevada (4,4 a 4,27) e a mediana de 5,0 nas três afirmações do bloco confirmam um padrão de concordância forte entre os respondentes, sugerindo que decisões ainda são majoritariamente orientadas por práticas tradicionais ou reativas. Essa evidência dá suporte ao que autores como Gatta et al. (2017) e Lakshmanan

(2022) argumentam ao apontar que a eficácia da logística urbana depende da articulação entre evidências empíricas e mecanismos decisórios. A etapa de identificação dos problemas urbanos, proposta como ponto de partida do framework, demonstra-se não apenas necessária, mas urgente diante da persistência de decisões descoladas de diagnósticos robustos.

No Bloco 2, que investigou as condições técnicas das bases de dados públicas, a elevada média das respostas (até 4,6) e a baixa dispersão estatística (desvios entre 0,53 e 0,85) indicam um consenso consolidado sobre a precariedade da infraestrutura informacional no setor público. A fragmentação dos dados, a ausência de padronização e as dificuldades de integração intersetorial se confirmam como gargalos operacionais que comprometem qualquer esforço de modelagem preditiva em nível institucional. Esses achados corroboram a pertinência da Etapa 2 – Diagnóstico de Maturidade, uma vez que, conforme apontam Ferrari et al. (2023), a eficácia de algoritmos de ML em contextos urbanos está condicionada à qualidade, integridade e acessibilidade das fontes de dados. Trata-se de uma etapa não apenas técnica, mas também estratégica, pois define o grau de viabilidade do projeto em função da estrutura existente.

O Bloco 3, centrado no potencial da ML e nas barreiras interpretativas, revela uma tensão significativa. Embora o reconhecimento do valor da ML na logística urbana seja alto (Q10 e Q14 com média 4,5), há incertezas sobre a inteligibilidade dos outputs por parte dos gestores (Q11: 3,9) e sobre a dependência da clareza dos resultados (Q12: 4,1). Isso reforça o alerta presente em autores como Shajan et al. (2024), que argumentam que a sofisticação técnica dos modelos deve ser equilibrada com mecanismos de tradução e visualização acessíveis. A existência de SSD que funcione como interface entre o modelo e a gestão é, portanto, uma exigência operacional e não meramente estética. A validação dessa necessidade pelos participantes indica que o framework acerta ao incorporar, desde a versão pós-entrevistas, uma etapa específica de interface interpretativa (Etapa 6), cuja função é promover transparência e utilidade prática aos outputs gerados por ML.

O Bloco 4 trouxe elementos estruturantes sobre a resistência institucional e a cultura organizacional. As médias entre 4,1 e 4,4, combinadas com medianas de 4,0 ou 5,0, revelam uma percepção homogênea sobre as barreiras internas à adoção de tecnologias baseadas em dados. Tal cenário é consistente com os diagnósticos de autores como Neumann, Guirguis & Steiner (2024), que apontam que a transformação digital na administração pública não ocorre apenas por falta de recursos, mas sobretudo por barreiras simbólicas, políticas e culturais. As



respostas justificam a consolidação da Etapa 7 – Adoção e Capacitação, que trata da implantação técnica da adesão organizacional e da superação de resistências institucionais.

Por fim, o Bloco 5, que analisou as condições técnicas para implementação, apresentou as médias mais altas da pesquisa (Q20: 4,6; Q21: 4,4), evidenciando uma percepção quase unânime de que não há aplicação bem-sucedida de modelos de ML sem uma estrutura mínima de suporte tecnológico. A infraestrutura não é vista como um facilitador, mas como condição de base. Esse resultado se alinha com os argumentos de Hevner et al. (2010), para quem a construção de artefatos no contexto da DSR deve partir de uma análise realista das condições institucionais de viabilidade. Assim, o framework avança na direção de uma proposta aplicada e adaptável, cuja robustez técnica está ancorada no diagnóstico de maturidade e na previsibilidade das restrições operacionais.

A análise estatística do questionário permitiu validar as dimensões levantadas na etapa qualitativa e orientar ajustes pontuais no framework teórico. Os dados coletados revelaram padrões de concordância que indicaram a necessidade de reorganização e detalhamento de algumas etapas, com o objetivo de alinhar o modelo às realidades técnicas e institucionais observadas na gestão urbana.

O framework passou a contemplar oito etapas dispostas ciclicamente, com início na identificação do problema urbano e encerramento na etapa de validação e retroalimentação, configurando um processo iterativo e passível de ajustes contínuos. Entre os ajustes realizados, destacam-se: a inserção da etapa de Diagnóstico de Maturidade (Etapa 2), considerando que a aplicação de ML demanda estrutura adequada e dados organizados; o detalhamento da etapa de Compreensão dos Dados (Etapa 3), anteriormente implícita; a inclusão da Interface com SSD (Etapa 6), voltada à interpretação dos outputs pelos gestores; e a consolidação da etapa de Adoção e Capacitação (Etapa 7), associada à superação de barreiras institucionais.

As modificações realizadas foram fundamentadas nas respostas dos participantes às afirmações do questionário, conforme sintetizado no Quadro 22, a qual estabelece a correspondência entre os ajustes incorporados ao framework e os respectivos indicadores empíricos que os justificaram.

Adicionalmente, os resultados esperados foram explicitados no modelo, buscando estabelecer vínculos entre a aplicação do framework e efeitos como melhor uso dos recursos disponíveis, maior agilidade nas decisões e uso mais estratégico da informação pública. Essas modificações não buscam encerrar o desenvolvimento do modelo, mas sim avançar na direção

de uma proposta que seja utilizável, realista e condizente com os desafios identificados na prática.

Quadro 22 - Modificações realizadas no framework a partir da análise do questionário


| <i>Modificação incorporada ao framework</i>                                                                                                                                                                | <i>Afirmações que motivaram a alteração</i>                                                                                                                                                                                                                                                                                                                                               |
|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| <b><i>Inclusão da etapa de Diagnóstico de Maturidade (Etapa 2)</i></b><br><i>Inserida para avaliar previamente a infraestrutura técnica e a organização dos dados antes da aplicação de modelos de ML.</i> | Q7 – Os dados urbanos são fragmentados e difíceis de integrar.<br>Q8 – Falta padronização e documentação nas bases públicas de dados.<br>Q9 – Há dificuldades técnicas para consolidar dados de diferentes setores.<br>Q20 – É necessário um ambiente minimamente preparado para aplicar ML.<br>Q21 – A infraestrutura tecnológica impacta diretamente a eficácia dos modelos preditivos. |
| <b><i>Detalhamento da etapa de Compreensão dos Dados (Etapa 3)</i></b><br><i>Etapa explicitada no modelo devido à complexidade dos dados e à sua subutilização nas decisões.</i>                           | Q5 – Os dados urbanos existentes não são utilizados para orientar decisões.<br>Q6 – Não há uma cultura de uso de dados para definir prioridades urbanas.<br>Q7 – Os dados urbanos são fragmentados e difíceis de integrar.<br>Q8 – Falta padronização e documentação nas bases públicas de dados.                                                                                         |
| <b><i>Inclusão da etapa de Interface com SSDs (Etapa 6)</i></b><br><i>Acrescentada para viabilizar a interpretação dos resultados preditivos por gestores públicos.</i>                                    | Q11 – As predições feitas por modelos de ML são de difícil interpretação.<br>Q12 – A aplicação de ML depende da clareza dos resultados para os gestores.<br>Q13 – A interpretação dos resultados de ML é um desafio para equipes públicas.<br>Q18 – O uso de SSDs ainda é limitado no setor público.                                                                                      |
| <b><i>Consolidação da etapa de Adoção e Capacitação (Etapa 7)</i></b><br><i>Reforçada para contemplar barreiras institucionais e a necessidade de qualificação dos servidores.</i>                         | Q15 – A adoção de ML enfrenta resistência institucional.<br>Q16 – Falta cultura analítica nas instituições públicas.<br>Q17 – A inovação tecnológica é vista com desconfiança por gestores.<br>Q19 – Capacitar servidores é essencial para adoção de ML.                                                                                                                                  |

Fonte: Elaborado pela autora.

A Figura 7 apresenta o framework ajustado, resultante da consolidação das análises qualitativas e quantitativas realizadas ao longo da pesquisa. A estrutura contempla oito etapas dispostas ciclicamente, reforçando a natureza iterativa do processo de tomada de decisão em logística urbana com apoio de modelos de ML.

O framework ilustra a integração entre os insumos oriundos do sistema urbano e os resultados esperados com a aplicação do modelo. Cada etapa foi refinada com base nas evidências obtidas, compondo um processo contínuo de aprendizado e retroalimentação.

Figura 7 – Framework ajustado após a etapa 2



Fonte: Elaborado pela autora.

Para assegurar que o framework apresentasse clareza conceitual, viabilidade técnica e aderência às demandas práticas da gestão pública, foi necessário submeter a versão ajustada à apreciação de especialistas. Assim, procedeu-se à etapa de validação por meio de entrevistas estruturadas, cujos resultados, analisados na Seção 5.3, complementaram a base empírica e possibilitaram um refinamento final da proposta.

### 5.3 ANÁLISE DAS ENTREVISTAS PARA VALIDAÇÃO DO FRAMEWORK

A versão final do framework proposto nesta pesquisa foi consolidada por meio de um processo iterativo de refinamento, fundamentado nas evidências empíricas obtidas ao longo das três etapas da investigação. A Etapa 3, em especial, foi decisiva nesse aprimoramento, ao reunir contribuições qualificadas de cinco profissionais técnicos atuantes em uma empresa de tecnologia voltada à mobilidade urbana. As entrevistas estruturadas, realizadas com base em critérios previamente definidos — clareza, relevância, aplicabilidade, completude, impacto e sugestões — permitiram validar a proposta teórica à luz de experiências práticas e contextos reais de aplicação.

Durante os encontros, os participantes analisaram criticamente a estrutura conceitual e visual do framework (Figura 6), composto por oito etapas organizadas de forma cíclica e

conectadas a um núcleo decisório central. O modelo propõe a transformação de dados urbanos em decisões qualificadas, por meio da articulação entre insumos institucionais, processos técnicos e SSD. A partir da escuta técnica e da análise interpretativa das respostas, foi possível identificar contribuições convergentes que indicaram ajustes relevantes e viáveis ao modelo original.

O participante P1 destacou a coerência do ciclo proposto e a fluidez entre as etapas, ressaltando a importância do diagnóstico de maturidade institucional como ponto-chave para orientar a viabilidade da aplicação em diferentes contextos. Propôs que a etapa final de validação incorporasse indicadores operacionais capazes de mensurar o impacto direto do uso do framework, como tempo de resposta, redução de falhas e otimização de rotas.

O participante P2, concentrou-se nas etapas técnicas do processo. Avaliou positivamente a separação entre preparação de dados, modelagem e integração com SSD, e sugeriu a adoção de mecanismos simples de acompanhamento do desempenho dos modelos, como checkpoints periódicos e protocolos de atualização manual, reforçando a necessidade de manutenção sem exigir estruturas complexas.

O participante P3, considerou o modelo claro e didático, especialmente para profissionais em formação. Ressaltou que a etapa de interface com o SSD poderia ser complementada com exemplos de visualizações, como dashboards e mapas de calor, para facilitar a comunicação entre áreas técnicas e gestores. Também recomendou que a etapa de capacitação detalhasse melhor os perfis e necessidades dos usuários finais.

O participante P4, apontou que a aplicação do modelo depende da compatibilidade com a infraestrutura tecnológica existente nas organizações. Destacou a importância de reforçar a etapa de preparação de dados com procedimentos básicos de padronização, especialmente em contextos que lidam com bases públicas fragmentadas, e sugeriu a articulação com equipes multidisciplinares para a operacionalização do framework.

Por fim, o participante P5, apresentou uma leitura centrada na performance operacional. Propôs a incorporação de parâmetros simples de controle, como tempo de processamento, frequência de reproprocessamento e uso de recursos computacionais, principalmente nas fases de treinamento e previsão. Reforçou que tais métricas podem ser adotadas sem comprometer a acessibilidade da proposta.

De modo geral, os cinco participantes validaram a estrutura e os objetivos do framework, reconhecendo sua aderência à realidade da logística urbana e sua aplicabilidade em

cenários técnicos com diferentes níveis de maturidade institucional. As sugestões recorrentes, como o reforço na etapa de preparação de dados, a valorização da comunicação com os usuários e a inclusão de estratégias de acompanhamento de desempenho foram consideradas pertinentes e foram incorporadas à versão final do modelo.

O Quadro 23, a seguir, apresenta uma síntese das oito etapas que compõem o ciclo central do framework, acompanhadas dos respectivos ajustes incorporados com base na análise das entrevistas.

Quadro 23 – Síntese das etapas do framework com respectivas adaptações empíricas

| <i>Nº</i> | <i>Etapas</i>                                  | <i>Ajustes sugeridos</i>                                                                                                  |
|-----------|------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------|
| 1         | Identificação do Problema Urbano               | Sem alterações. Mantém-se como ponto de partida.                                                                          |
| 2         | Diagnóstico de Maturidade Institucional        | Reforçar que avalia capacidades técnicas, culturais e legais da instituição para uso de ML e SSD.                         |
| 3         | Compreensão e Mapeamento dos Dados Disponíveis | Incluir ações de verificação de qualidade, origem, padronização e limitações dos dados.                                   |
| 4         | Preparação e Organização dos Dados             | Destacar processos básicos de padronização, limpeza, consistência e anonimização, conforme sugerido por TI.               |
| 5         | Desenvolvimento do Modelo Preditivo            | Reforçar limites de desempenho, tempo de treinamento, recursos disponíveis e validação básica.                            |
| 6         | Integração com o Sistema de Suporte à Decisão  | Incluir visualizações simples (dashboards, mapas de calor, alertas) que favoreçam o uso por gestores.                     |
| 7         | Adoção, Capacitação e Ajustes Operacionais     | Especificar tipos de usuários e treinamentos mínimos esperados; envolver setores-chave da organização.                    |
| 8         | Validação de Resultados e Retroalimentação     | Acrescentar: indicadores de impacto (ex: tempo de resposta, uso real do sistema, acurácia percebida) e revisão periódica. |

Fonte: Elaborado pela autora.

Além das etapas principais, o modelo considera elementos de apoio externos ao ciclo, fundamentais para garantir sua efetividade. Entre os insumos necessários estão, a disponibilidade e a qualidade dos dados, a infraestrutura tecnológica, o nível de maturidade institucional e o alinhamento com políticas públicas orientadas por evidências. Tais fatores condicionam o desempenho do modelo e devem ser diagnosticados previamente à sua aplicação.

Quanto aos resultados esperados, o framework visa promover decisões mais qualificadas, reduzir custos operacionais e ampliar a eficiência na gestão urbana. Entretanto, é

necessário reconhecer barreiras potenciais, como baixa adesão institucional, ausência de dados confiáveis e fragmentação entre setores. A antecipação dessas limitações é essencial para o êxito da proposta.

Para acompanhar o desempenho do modelo ao longo do tempo, recomenda-se a adoção de indicadores de monitoramento contínuo, como tempo médio de resposta, grau de adesão, percepção de impacto e reuso de soluções analíticas. Esses indicadores servem como base para ajustes iterativos e reforçam o caráter dinâmico do framework.

Visualmente, o modelo assume formato circular, com as oito etapas interligadas por setas que reforçam a natureza iterativa do processo. No centro do ciclo, o SSD funciona como núcleo integrador, conectando os dados preditivos às ações no território. Cada etapa pode ser representada por ícones intuitivos, como lupa para identificação do problema, engrenagens para desenvolvimento do modelo e gráfico para interface com SSD. Ao redor do ciclo, localizam-se indicadores operacionais e estratégicos, permitindo avaliação contínua e retroalimentação do sistema, garantindo sua adaptação progressiva aos contextos institucionais.

## 5.4 FRAMEWORK FINAL

A terceira etapa da pesquisa, composta por entrevistas estruturadas com especialistas atuantes em uma empresa de tecnologia voltada à mobilidade urbana, foi decisiva para a validação e o aprimoramento do framework proposto. As contribuições técnicas oriundas dessa etapa permitiram revisar criticamente a estrutura teórica anteriormente construída, ancorando-a em experiências práticas e em contextos reais de aplicação. Como resultado, foi possível consolidar uma versão final do artefato, mais aderente às condições institucionais e operacionais da logística urbana baseada em dados.

O processo de refinamento considerou não apenas a análise individual das percepções dos participantes, como também o grau de convergência entre os pontos destacados, a viabilidade de incorporação das sugestões e a coerência do modelo resultante com os pressupostos da pesquisa.

A versão final do framework mantém sua organização em oito etapas interligadas, estruturadas de forma cíclica e iterativa, centradas na transformação de dados urbanos em decisões qualificadas com apoio de sistemas inteligentes.

A primeira etapa, Identificação do Problema Urbano, corresponde ao reconhecimento inicial das demandas logísticas concretas, com base em evidências empíricas, relatórios

institucionais e escuta ativa dos atores envolvidos. Esse processo permite delimitar e priorizar o foco de intervenção do modelo.

Na segunda etapa, Diagnóstico de Maturidade Institucional, avalia-se a capacidade da organização para adotar soluções baseadas em dados. São considerados aspectos como infraestrutura tecnológica, cultura organizacional e conformidade legal, compondo um panorama realista do grau de prontidão institucional.

A terceira etapa, Compreensão e Mapeamento dos Dados Disponíveis, envolve o levantamento e a categorização das fontes de dados acessíveis. Onde é analisado a sua origem, formato, qualidade, padronização e restrições, a fim de assegurar sua aderência ao problema em análise e à modelagem subsequente.

Em seguida, a quarta etapa, Preparação e Organização dos Dados, contempla os procedimentos técnicos necessários à transformação dos dados brutos em insumos analiticamente utilizáveis. Inclui ações como limpeza, anonimização, padronização e transformação de variáveis, podendo ser adaptada conforme a maturidade técnica da instituição.

A quinta etapa, Desenvolvimento do Modelo Preditivo, consiste na aplicação de algoritmos de aprendizado de máquina supervisionado. Nessa fase, são definidos os métodos mais adequados à tarefa proposta, testados os modelos e avaliados indicadores de desempenho como acurácia, tempo de processamento e custo computacional.

A sexta etapa, Integração com o SSD, trata da operacionalização dos resultados analíticos por meio de ferramentas acessíveis aos gestores. São desenvolvidas interfaces como dashboards, mapas de calor e sistemas de alerta que possibilitam a interpretação prática dos resultados por públicos não técnicos.

Na sétima etapa, Adoção, Capacitação e Ajustes Operacionais, o modelo é inserido na rotina institucional. Essa fase inclui a capacitação dos usuários, a definição de protocolos operacionais e o acompanhamento inicial de uso, garantindo que a solução seja apropriada pelas equipes responsáveis.

Por fim, a oitava etapa, Validação e Retroalimentação, contempla a medição dos impactos gerados pela aplicação do framework, por meio de indicadores como tempo de resposta, acurácia percebida e frequência de uso. Esta etapa também prevê a revisão contínua do processo, alimentando novamente as fases iniciais e conferindo ao modelo flexibilidade e adaptabilidade.


Além das oito etapas centrais que compõem o framework, a proposta inclui elementos externos que influenciam diretamente sua implementação e sustentabilidade: insumos institucionais, resultados esperados e barreiras potenciais. Os insumos institucionais referem-se à base necessária para viabilizar a operacionalização do modelo, incluindo a disponibilidade e qualidade dos dados, a existência de infraestrutura tecnológica adequada, o suporte de políticas públicas e o grau de maturidade organizacional para adoção de soluções baseadas em dados. Já os resultados esperados dizem respeito aos impactos diretos advindos da aplicação do framework, como o aumento da eficiência operacional, a redução de custos logísticos e a qualificação das decisões, a partir de evidências empíricas e análises preditivas. As barreiras potenciais, por sua vez, englobam fatores institucionais e culturais que podem dificultar ou comprometer a adoção do modelo, como a baixa cultura de dados, a resistência de servidores públicos, a fragmentação entre setores e a escassez de profissionais qualificados.

A representação do framework assume um formato circular como o demonstrado na Figura 8, reforçando a natureza iterativa e cíclica do processo decisório apoiado por dados. As etapas são distribuídas ao redor do núcleo central, representado pelo SSD, e conectadas por setas bidirecionais que indicam a possibilidade de retroalimentação. Cada etapa é acompanhada por um ícone ilustrativo que facilita sua identificação, e os elementos externos são dispostos ao redor do ciclo, em diálogo com as etapas internas.

O SSD, posicionado no centro do diagrama, simboliza o ponto de convergência entre dados, algoritmos e ação pública, funcionando como interface entre os modelos preditivos e as práticas de gestão urbana. Ao seu redor, indicadores operacionais podem ser destacados como marcadores de performance, permitindo acompanhar a evolução do modelo e seus efeitos ao longo do tempo.



Figura 8 - Framework final para integração de ML em SSD na logística urbana



Fonte: Elaborado pela autora.

A Figura 8 sintetiza os principais componentes da proposta desenvolvida, consolidando as etapas cíclicas do processo decisório orientado por dados, os insumos institucionais necessários, as barreiras potenciais e os resultados esperados da aplicação do framework. Ao reunir, de forma integrada os elementos técnicos, operacionais e institucionais envolvidos na gestão logística urbana, o framework contribui para qualificar o processo decisório ao transformar dados fragmentados em informações acionáveis, potencializando o uso de evidências na formulação de políticas, otimizando recursos operacionais e ampliando a capacidade das instituições de responder de forma ágil e assertiva aos desafios urbanos, fortalecendo a integração entre inovação tecnológica e gestão pública.

## 6 CONSIDERAÇÕES FINAIS

A presente pesquisa buscou responder à seguinte questão: como a integração de técnicas de ML em SSD pode contribuir para aprimorar a tomada de decisão na gestão da logística urbana? Para tanto, foi desenvolvido e validado um framework teórico sustentado pela DSR, articulando literatura e evidências empíricas.

Os cinco objetivos específicos permitiram estruturar a análise e conectar os achados com contribuições práticas e conceituais. O primeiro objetivo, voltado a compreender os desafios da logística urbana em cenários de alta complexidade, confirmou entraves descritos por Ferrari et al. (2023), Gatta, Marcucci & Le Pira (2017) e Dong et al. (2021), como congestionamento, fragmentação institucional e pressões ambientais. Esses estudos reforçam que os gestores precisam de instrumentos que convertam dados dispersos em suporte prático às decisões.

O segundo objetivo, que buscou estabelecer requisitos e objetivos para um framework teórico, dialoga com Reznichenko et al. (2024) e Shajan et al. (2024), que apontam limitações na aplicabilidade prática de modelos de ML em ambientes públicos, sobretudo pela falta de governança de dados. A pesquisa respondeu a esse desafio ao propor critérios de clareza, aplicabilidade, coerência e completude, confirmados também como centrais na literatura de SSD (Carvalho, 2022).

O terceiro objetivo consistiu em desenvolver o framework teórico em etapas iterativas, apoiando-se na abordagem da DSR (Hevner et al., 2004; Vaishnavi & Kuechler, 2004). O resultado foi um modelo cíclico composto por oito etapas e elementos externos, reforçando que frameworks aplicados à gestão urbana devem incorporar mecanismos de retroalimentação e melhoria contínua, como defendem Peffers et al. (2007).

O quarto objetivo, voltado a demonstrar o framework junto a profissionais, mostrou que a aplicabilidade prática exige não apenas robustez técnica, mas também linguagem acessível e critérios de avaliação compreensíveis — em linha com os apontamentos de Chaudhary et al. (2025), que destacam a necessidade de infraestrutura institucional para que algoritmos se tornem soluções de gestão.

O quinto objetivo buscou avaliar o framework nos critérios de clareza, aplicabilidade, coerência e completude. A validação empírica indicou que o modelo cumpre tais critérios, ainda que ajustes tenham sido necessários. Essa constatação confirma as observações de Albino,

Berardi & Dangelico (2015) sobre a importância de estruturas adaptáveis e contextuais, capazes de equilibrar rigor metodológico e aplicabilidade real.

A partir dessa trajetória, emergem as contribuições, limitações e sugestões de pesquisa futura.

## 6.1 CONTRIBUIÇÕES GERENCIAIS

Os desafios identificados no Apêndice A revelam barreiras estruturais que comprometem a efetividade da gestão urbana, entre elas o congestionamento de tráfego (Parsaei & Afshari, 2022), a limitação de espaços para armazenagem (Berberoglu et al., 2023), a pressão por entregas rápidas (Dong et al., 2021), a fragmentação das operações logísticas (Ullah et al., 2020) e a complexidade regulatória (Janjelvic et al., 2019). Somam-se a esses aspectos a pressão ambiental pela redução de emissões (Ridaoui et al., 2024), os custos elevados de infraestrutura (Ren & Salleh, 2024), as mudanças nas preferências do consumidor (Heumann et al., 2021) e os desafios da última milha (Teixeira et al., 2023). Nesse cenário, o framework desenvolvido oferece contribuições gerenciais ao propor um caminho estruturado que relaciona essas dificuldades a etapas concretas de apoio à decisão, proporcionando uma abordagem aplicável ao cotidiano da gestão pública.

O diagnóstico de maturidade institucional responde de forma direta ao desafio da baixa capacidade organizacional em absorver tecnologias emergentes (Savin, 2020). Ao estabelecer parâmetros para avaliar a prontidão das instituições, a proposta permite alinhar expectativas, definir prioridades e adotar estratégias compatíveis com o nível real de preparo, evitando projetos desalinhados com a capacidade existente. Essa perspectiva possibilita que iniciativas voltadas ao uso de ML e SSD avancem em consonância com as condições institucionais reais.

A contribuição relativa à preparação e padronização dos dados endereça o desafio da fragmentação e inconsistência das bases urbanas (Ullah et al., 2020; Wang et al., 2018). Ao orientar a coleta, integração e validação dos dados, o framework fornece um roteiro prático para superar barreiras técnicas, fortalecendo a governança e criando insumos confiáveis para os SSD. Esse alinhamento responde ainda à necessidade de rastreabilidade e segurança das operações logísticas (Wang et al., 2018), que depende de informações padronizadas e consistentes.

No que se refere às barreiras operacionais e técnicas, a proposta avança ao tratar a interface com SSDs como elemento central, conectando análises de ML com sistemas já utilizados pela administração. Essa integração atenua a resistência operacional e reduz os custos de infraestrutura associados à implantação de soluções isoladas (Ren & Salleh, 2024),

favorecendo a institucionalização do uso de análises baseadas em dados. Trata-se de um passo essencial para transformar experimentações pontuais em práticas contínuas de apoio à decisão.

Por fim, os indicadores de desempenho e mecanismos de retroalimentação representam resposta direta às barreiras ligadas à baixa continuidade de iniciativas e dificuldade de mensurar impactos (Ridaoui et al., 2024; Janjelic et al., 2019). Ao incorporar métricas claras e ciclos iterativos, o framework fortalece a gestão baseada em evidências, ao mesmo tempo em que amplia a legitimidade das decisões públicas diante da sociedade.

O framework desenvolvido articula os desafios críticos identificados na literatura e confirmados pelos resultados da pesquisa com soluções estruturadas e aplicáveis, oferecendo aos gestores públicos um referencial consistente para enfrentar barreiras técnicas, institucionais e operacionais. Essa contribuição mantém vínculo direto com a dimensão teórica da pesquisa, ao traduzir conceitos em um modelo estruturado que aproxima o debate acadêmico das necessidades práticas da gestão pública.

## 6.2 CONTRIBUIÇÕES TEÓRICAS

A principal contribuição teórica deste estudo consiste na proposição de um framework teórico que organiza, em etapas interligadas, as dimensões técnicas, institucionais e operacionais relacionadas à aplicação de ML em SSDs voltados à logística urbana. Essa estrutura foi desenvolvida a partir da revisão da literatura (Seção 2), que evidenciou desafios como a fragmentação e a baixa padronização dos dados (Gatta et al., 2017; Ferrari et al., 2023), e complementada pelos resultados empíricos (Capítulo 4), que confirmaram a persistência de barreiras institucionais, dificuldades operacionais e limitações técnicas relatadas pelos participantes.

O modelo avança em relação aos estudos existentes ao integrar esses elementos em um ciclo iterativo único, conforme apresentado no framework final (Seção 5.4). Essa sistematização contribui para ampliar o debate teórico ao demonstrar como fatores isoladamente apontados na literatura — como a carência de integração tecnológica (Ferrari et al., 2023), a necessidade de estratégias de suporte à decisão em contextos urbanos (Reznychenko; Uglickich & Nagy, 2024) e os entraves institucionais para adoção de inovações (Shajan; Suresh Kumar & Elavarasan, 2024) — podem ser articulados de maneira integrada.

O framework contribui, ao oferecer uma lente conceitual que reforça a compreensão da interdependência entre dimensões técnicas, institucionais e operacionais, permitindo que os SSDs apoiados por ML sejam analisados como processos sistêmicos e não apenas como

soluções tecnológicas isoladas. Embora as contribuições teóricas indiquem avanços relevantes, é necessário reconhecer que o modelo proposto apresenta condicionantes e restrições ligadas ao campo empírico e ao escopo da pesquisa, aspectos que serão discutidos na seção seguinte sobre limitações.

### 6.3 LIMITAÇÕES DA PESQUISA

Apesar dos avanços alcançados, algumas limitações precisam ser reconhecidas. A primeira refere-se à escala da pesquisa, restrita a dez participantes distribuídos nas diferentes etapas empíricas. Embora a triangulação metodológica tenha garantido consistência e riqueza analítica, o número reduzido de respondentes não permite generalizações amplas sobre a aplicabilidade do framework.

Outra limitação está relacionada à ausência de testes práticos em contextos reais de gestão urbana. O framework foi desenvolvido e validado em nível conceitual, sem aplicação direta em municípios ou projetos-piloto. Essa condição decorre das restrições de acesso a dados institucionais e das dificuldades de implementação em ambientes públicos durante o período de desenvolvimento da pesquisa.

Adicionalmente, a validação concentrou-se na percepção de especialistas em tecnologia e gestão pública. Esse recorte assegura clareza conceitual e rigor analítico, mas não incorpora de forma mais abrangente diferentes níveis da administração pública, como técnicos municipais e gestores operacionais responsáveis pela execução cotidiana de políticas logísticas. A ausência dessas perspectivas restringe a avaliação da aplicabilidade prática do framework nas rotinas institucionais.

Essas limitações reforçam a necessidade de avanços em etapas posteriores de investigação, como a realização de estudos empíricos em contextos reais de gestão urbana, a expansão da amostra de validação e a inclusão de diferentes perfis institucionais na análise.

### 6.4 SUGESTÕES DE ESTUDOS FUTUROS

As limitações indicam caminhos para pesquisas futuras. Um primeiro desdobramento seria a aplicação prática do framework em municípios, a fim de testar sua eficácia em situações reais de planejamento e gestão da logística urbana. Tais testes poderiam contemplar projetos de mobilidade, distribuição de mercadorias e gestão de tráfego.

Outra possibilidade consiste em expandir a amostra de validação, incorporando gestores públicos de diferentes esferas administrativas e de cidades com perfis distintos. Essa ampliação permitiria avaliar como contextos institucionais variados influenciam a adoção de soluções baseadas em ML e SSD, enriquecendo a compreensão sobre a aplicabilidade do modelo em realidades heterogêneas.

Também se apresentam como promissoras as comparações entre territórios, a fim de verificar como fatores políticos, estruturais e organizacionais moldam os resultados da integração de ML em SSDs. Além disso, a associação do framework a indicadores de sustentabilidade e governança digital poderia ampliar seu alcance para agendas contemporâneas relacionadas a cidades inteligentes.

O ritmo acelerado de desenvolvimento em ML e suas implicações para a gestão pública urbana tornam inevitável o surgimento de novas demandas e incertezas. Estudos futuros deverão enfrentar essas tensões, assegurando que frameworks conceituais não sejam cristalizados, mas continuamente reconstruídos em diálogo com a realidade institucional e tecnológica das cidades.

## REFERÊNCIAS

- AL MAMLOUK, D. AI evolution impact on multi-criteria spatial decision support system: affordable smart cities in developing countries. 2024. Tese (Doutorado) — Politecnico di Torino, Torino, 2024.
- ALBINO, V.; BERARDI, U.; DANGELICO, R. M. Smart cities: Definitions, dimensions, performance, and initiatives. *Journal of Urban Technology*, v. 22, n. 1, p. 3-21, 2015. <https://doi.org/10.1080/10630732.2014.942092>
- AL-SURMI, A.; BASHIRI, M.; KOLIOUSIS, I. AI based decision making: combining strategies to improve operational performance. *International Journal of Production Research*, v. 60, n. 14, p. 4464-4486, 2022. <https://doi.org/10.1080/00207543.2021.1966540>
- ANG, K. L. M.; SENG, J. K. P.; NGHARAMIKE, E.; IJEMARU, G. K. Emerging technologies for smart cities' transportation: geo-information, data analytics and machine learning approaches. *ISPRS International Journal of Geo-Information*, v. 11, n. 2, p. 85, 2022. <https://doi.org/10.3390/ijgi11020085>
- ANTHONY JNR, B. Sustainable mobility governance in smart cities for urban policy development – a scoping review and conceptual model. *Smart and Sustainable Built Environment*, v. 14, n. 3, p. 649-671, 2025. <https://doi.org/10.1108/SASBE-05-2023-0109>
- BASKERVILLE, R.; BAIYERE, A.; GREGOR, S. Design Science Research Contributions: Finding a Balance Between Artifact and Theory. *Journal of the Association for Information Systems*, v. 19, n. 1, p. 361-377, 2018.
- BERBEROGLU, Y.; KAZANCOGLU, Y.; SAGNAK, M. Circularity assessment of logistics activities for green business performance management. *Business Strategy and the Environment*, v. 32, n. 7, p. 4734-4749, 2023. <https://doi.org/10.1002/bse.3390>
- BOUHANA, A. et al. An ontology-based CBR approach for personalized itinerary search systems for sustainable urban freight transport. *Expert Systems with Applications*, v. 42, n. 7, p. 3724-3741, 2015. <https://doi.org/10.1016/j.eswa.2014.12.012>
- BÜYÜKÖZKAN, G.; ILICAK, Ö. Smart urban logistics: Literature review and future directions. *Socio-Economic Planning Sciences*, v. 81, p. 101197, 2022. <https://doi.org/10.1016/j.seps.2021.101197>
- CARDENAS, I.; BORBON-GALVEZ, Y.; VERLINDEN, T.; VAN DE VOORDE, E.; VANELSLANDER, T.; DEWULF, W. City logistics, urban goods distribution and last mile delivery and collection. *Competition and Regulation in Network Industries*, v. 18, n. 1-2, p. 22-43, 2017. <https://doi.org/10.1155/2021/6697755>
- CARVALHO, H. D. S. An intelligent decision support system for the freight transport sector. 2022. Dissertação (Mestrado) — Universidade do Minho, Portugal, 2022.



CHAUDHARY, A. et al. Enhancing urban mobility: machine learning-powered fusion approach for intelligent traffic congestion control in smart cities. *International Journal of System Assurance Engineering and Management*, p. 1-8, 2025.

<https://doi.org/10.1007/s13198-024-02672-6>

CHENG, Y.; PAN, X. Design of a support system for complicated logistics location integrating big data. *Advances in Civil Engineering*, v. 2021, n. 1, p. 6697755, 2021.

<https://doi.org/10.1155/2021/6697755>

CHU, Z.; CHENG, M.; YU, N. N. Development potential of Chinese smart cities and its spatio-temporal pattern: A new hybrid MADM method using combination weight. *Growth and Change*, v. 53, n. 4, p. 1546-1566, 2022. <https://doi.org/10.1111/grow.12528>

COOPER, D. R.; SCHINDLER, P. S. *Métodos de pesquisa em administração*. 7. ed. Porto Alegre: Bookman, 2003. <https://doi.org/10.1590/S1415-65552003000300016>

DONG, C.; AKRAM, A.; ANDERSSON, D.; ARNÄS, P. O.; STEFANSSON, G. The impact of emerging and disruptive technologies on freight transportation in the digital era: Current state and future trends. *The International Journal of Logistics Management*, v. 32, n. 2, p. 386-412, 2021. <https://doi.org/10.1108/IJLM-01-2020-0043>

DOSSOU, P. E.; VERMERSCH, A. Development of a decision support tool for sustainable urban logistics optimization. *Procedia Computer Science*, v. 184, p. 476-483, 2021.

<https://doi.org/10.1016/j.procs.2021.03.060>

EICHENSEER, P.; HANS, L.; WINKLER, H. A data-driven machine learning model for forecasting delivery positions in logistics for workforce planning. *Supply Chain Analytics*, v. 9, p. 100099, 2025. <https://doi.org/10.1016/j.sca.2024.100099>

FERRARI, A. et al. 4.0 technologies in city logistics: an empirical investigation of contextual factors. *Operations Management Research*, v. 16, n. 1, p. 345-362, 2023.

<https://doi.org/10.1007/s12063-022-00304-5>

GATTA, V.; MARCUCCI, E.; LE PIRA, M. Smart urban freight planning process: integrating desk, living lab and modelling approaches in decision-making. *European Transport Research Review*, v. 9, p. 1-11, 2017. <https://doi.org/10.1007/s12544-017-0245-9>

GIL, A. C. *Como elaborar projetos de pesquisa*. 5. ed. São Paulo: Atlas, 2010.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. Cambridge: MIT Press, 2016.

GREGOR, S.; JONES, D. The anatomy of a design theory. *Journal of the Association for Information Systems*, v. 8, n. 5, p. 312-335, 2007. <https://doi.org/10.17705/1jais.00129>

GUTIERREZ-FRANCO, E.; MEJIA-ARGUETA, C.; RABELO, L. Data-driven methodology to support long-lasting logistics and decision making for urban last-mile operations.

*Sustainability*, v. 13, n. 11, p. 6230, 2021. <https://doi.org/10.3390/su13116230>

HAIR JR, J.; BABIN, B.; MONEY, A. H.; SAMOUEL, P. *Fundamentos de métodos de pesquisa em administração*. Porto Alegre: Bookman, 2005.

HEUMANN, M.; PUMP, R.; BREITNER, M. H.; KOSCHEL, A.; AHLERS, V. Towards sustainable transport: a strategic decision support system for urban logistics operations. In: *Innovation Through Information Systems: Volume I: A Collection of Latest Research on Domain Issues*. Cham: Springer International Publishing, 2021. p. 367-381.

[https://doi.org/10.1007/978-3-030-86790-4\\_25](https://doi.org/10.1007/978-3-030-86790-4_25)

HEVNER, A. R. A three cycle view of design science research. *Scandinavian Journal of Information Systems*, v. 19, n. 2, p. 4, 2007.

HEVNER, A.; CHATTERJEE, S. *Design Science Research in Information Systems*. New York: Springer, 2010. <https://doi.org/10.1007/978-1-4419-5653-8>

HEVNER, A.; GREGOR, S. Positioning and presenting design science research for maximum impact. *MIS Quarterly*, v. 37, n. 2, p. 337-355, 2013.

<https://doi.org/10.25300/MISQ/2013/37.2.01>

HUNTER, J. D. Matplotlib: a 2D graphics environment. *Computing in Science & Engineering*, v. 9, n. 3, p. 90-95, 2007. <https://doi.org/10.1109/MCSE.2007.55>

IWAN, S.; KIJIEWSKA, K. Urban freight transport demand modelling: comparative analysis of different approaches. *Procedia - Social and Behavioral Sciences*, v. 125, p. 169-181, 2014.

JANJEVIC, M.; KNOPPEN, D.; WINKENBACH, M. Integrated decision-making framework for urban freight logistics policy-making. *Transportation Research Part D: Transport and Environment*, v. 72, p. 333-357, 2019. <https://doi.org/10.1016/j.trd.2019.05.006>

HERATH, HMKKMB; MITTAL, Mamta. Adoption of artificial intelligence in smart cities: A comprehensive review. *International Journal of Information Management Data Insights*, v. 2, n. 1, p. 100076, 2022. <https://doi.org/10.1016/j.jjime.2022.100076>

KALBOUSSI, E.; NDHAEIF, N.; REZG, N. Machine learning for decision making in the improvement of digital press services. 2023.

KEIRSTEAD, J.; SHAH, N. The changing role of optimization in urban planning. In: *Optimization, Simulation and Control*. New York: Springer, 2013. p. 175-193.

[https://doi.org/10.1007/978-1-4614-5131-0\\_11](https://doi.org/10.1007/978-1-4614-5131-0_11)

KIBA-JANIAK, M. Urban freight transport in city strategic planning. *Research in Transportation Business & Management*, v. 24, p. 4-16, 2017.

<https://doi.org/10.1016/j.rtbm.2017.05.003>

KLEIN, A. Z.; VASCONCELLOS DA SILVA, L.; MACHADO, L.; AZEVEDO, D. *Metodologia de pesquisa em administração: uma abordagem prática*. São Paulo: Atlas, 2015.

KUBEK, D.; WIĘCEK, P. An integrated multi-layer decision-making framework in the Physical Internet concept for the city logistics. *Transportation Research Procedia*, v. 39, p. 221-230, 2019. <https://doi.org/10.1016/j.trpro.2019.06.024>

LAKATOS, E. M.; MARCONI, M. A. *Técnicas de pesquisa: planejamento e execução de pesquisas, amostragens e técnicas de pesquisas, elaboração, análise e interpretação de dados*. 7. ed. São Paulo: Atlas, 2009.

LEYERER, M. et al. Individually optimized commercial road transport: a decision support system for customizable routing problems. *Sustainability*, v. 11, n. 20, p. 5544, 2019. <https://doi.org/10.3390/su11205544>

LI, F. et al. Machine learning and remote sensing integration for leveraging urban sustainability: a review and framework. *Sustainable Cities and Society*, v. 96, p. 104653, 2023. <https://doi.org/10.1016/j.scs.2023.104653>

LIU, Q. Logistics distribution route optimization in artificial intelligence and Internet of Things environment. *Decision Making: Applications in Management and Engineering*, v. 7, n. 2, p. 221-239, 2024. <https://doi.org/10.3390/su11010189>

LIYANAGE, S.; BAGLOEE, S. A. Applications of artificial intelligence in transport: an overview. *Sustainability*, v. 11, n. 1, p. 189, 2019. <https://doi.org/10.3390/su11010189>

MARCH, S. T.; SMITH, G. F. Design and natural science research on information technology. *Decision Support Systems*, v. 15, n. 4, p. 251-266, 1995. [https://doi.org/10.1016/0167-9236\(94\)00041-2](https://doi.org/10.1016/0167-9236(94)00041-2)

MCKINNEY, W. Data structures for statistical computing in Python. In: *Proceedings of the 9th Python in Science Conference*. Austin: SciPy, 2010. <https://doi.org/10.25080/Majora-92bf1922-00a>

MILES, M. B.; HUBERMAN, A. M. *Análise de dados qualitativos: um guia com técnicas para o pesquisador*. 2. ed. Porto Alegre: Bookman, 1994.

MOUFAD, I. et al. Artificial intelligence use in urban logistics and transport activities: overview and research trends. In: *2024 IEEE 15th International Colloquium on Logistics and Supply Chain Management (LOGISTIQUA)*. IEEE, 2024. p. 1-6. <https://doi.org/10.1109/LOGISTIQUA61063.2024.10571425>

NAMPALLI, R. C. R.; ADUSUPALLI, B. Using machine learning for predictive freight demand and route optimization in road and rail logistics. *Library of Progress - Library Science, Information Technology & Computer*, v. 44, n. 3, 2024. <https://doi.org/10.36893/LIBPRO.2024.V44N3.17754>

NEUMANN, O.; GUIRGUIS, K.; STEINER, R. Exploring artificial intelligence adoption in public organizations: a comparative case study. *Public Management Review*, v. 26, n. 1, p. 114-141, 2024. <https://doi.org/10.1080/14719037.2022.2048685>

NIKITAS, A.; MICHALAKOPOULOU, K.; NJOYA, E. T.; KARAMPATZAKIS, D. Artificial intelligence, transport, and the smart city: definitions and dimensions of a new mobility era. *Sustainability*, v. 12, n. 7, p. 2789, 2020. <https://doi.org/10.3390/su12072789>

PAN, S. et al. Smart city for sustainable urban freight logistics. *International Journal of Production Research*, v. 59, n. 7, p. 2079-2089, 2021. <https://doi.org/10.1080/00207543.2021.1893970>

PARSAEE, M.; AFSHARI, A. R. Toward a modern last-mile delivery: consequences and obstacles of intelligent technology. *Applied System Innovation*, v. 5, n. 4, p. 82, 2022. <https://doi.org/10.3390/asi5040082>

PEFFERS, K. et al. A design science research methodology for information systems research. *Journal of Management Information Systems*, v. 24, n. 3, p. 45-77, 2007.  
<https://doi.org/10.3390/asi5040082>

PILLA, F.; PARDO, T. A.; NAM, T. Optimization and machine learning applied to last-mile logistics: a review. *Sustainability*, v. 14, n. 9, p. 5329, 2022.  
<https://doi.org/10.3390/su14095329>

REIM, W.; ÅSTRÖM, J.; ERIKSSON, O. Implementation of artificial intelligence (AI): a roadmap for business model innovation. *AI*, v. 1, n. 2, p. 11, 2020.  
<https://doi.org/10.3390/ai1020011>

REN, J.; SALLEH, S. S. Green urban logistics path planning design based on physical network system in the context of artificial intelligence. *The Journal of Supercomputing*, v. 80, n. 7, p. 9140-9161, 2024. <https://doi.org/10.1007/s11227-023-05796-x>

REZNYCHENKO, T.; UGLICKICH, E.; NAGY, I. Accuracy comparison of logistic regression, random forest, and neural networks applied to real MaaS data. In: *2024 Smart City Symposium Prague (SCSP)*. IEEE, 2024. p.1-5.  
<https://doi.org/10.1109/SCSP61506.2024.10552715>

RIDAOU, H. et al. Artificial intelligence: a key to smart and sustainable urban freight transport. In: *2024 IEEE 15th International Colloquium on Logistics and Supply Chain Management (LOGISTIQUA)*. IEEE, 2024. p. 1-7.  
<https://doi.org/10.1109/LOGISTIQUA61063.2024.10571498>

RISMANTO, H.; JUDIANTO, L. Dynamic routing in urban logistics: a comprehensive review of AI, real-time data, and sustainability impacts. *Sinergi International Journal of Logistics*, v. 3, n. 2, p. 68-79, 2025. <https://doi.org/10.61194/sijl.v3i2.741>

ROSE, W. J. et al. Urban logistics: establishing key concepts and building a conceptual framework for future research. *Transportation Journal*, v. 56, n. 4, p. 357-394, 2017.  
<https://doi.org/10.5325/transportationj.56.4.0357>

SAVIN, G. Smart city logistics. In: *E3S Web of Conferences*, v. 208, p. 04005. EDP Sciences, 2020. <https://doi.org/10.1051/e3sconf/202020804005>

SHAJAN, M.; SURESH KUMAR, K.; ELAVARASAN, R. Catalyzing urban logistics and road safety: truck recommendation system and real-time accident severity prediction. In: *International Conference on Artificial Intelligence and Smart Energy*. Cham: Springer Nature Switzerland, 2024. p. 248-260. [https://doi.org/10.1007/978-3-031-61475-0\\_20](https://doi.org/10.1007/978-3-031-61475-0_20)

SHARMA, V. et al. Advancements in urban logistics toward smart, sustainable reforms in developing enabling technologies and markets. *Kybernetes*, v. 51, n. 3, p. 1038-1061, 2022.  
<https://doi.org/10.1108/K-01-2021-0026>

SIMON, H. A. *The new science of management decision*. Englewood Cliffs, NJ: Prentice Hall, 1977.

TAKEDA, H.; VEERKAMP, P.; TOMIYAMA, T.; YOSHIKAWA, H. Modeling design processes. *AI Magazine*, v. 11, n. 4, p. 37-48, 1990.

TASCHE, L.; BÄHRING, M.; GERLACH, B. Digital supply chain twins in urban logistics system – conception of an integrative platform. *Tehnički glasnik*, v. 17, n. 3, p. 405-413, 2023. <https://doi.org/10.31803/tg-20230518081537>

TEKOUABOU, S. C. K. et al. AI-based on machine learning methods for urban real estate prediction: a systematic survey. *Archives of Computational Methods in Engineering*, v. 31, n. 2, p. 1079-1095, 2024. <https://doi.org/10.1007/s11831-023-10010-5>

THUAN, N. H.; DRECHSLER, A.; ANTUNES, P. Construction of design science research questions. *Communications of the Association for Information Systems*, v. 44, n. 1, p. 20, 2019. <https://doi.org/10.26686/wgtn.13088309>

ULLAH, Z. et al. Applications of artificial intelligence and machine learning in smart cities. *Computer Communications*, v. 154, p. 313-323, 2020.

VAISHNAVI, V.; KUECHLER, W. Design research in information systems. 2004.

Disponível em:

[https://www.researchgate.net/publication/235720414\\_Design\\_Science\\_Research\\_in\\_Information\\_Systems](https://www.researchgate.net/publication/235720414_Design_Science_Research_in_Information_Systems). Acesso em: 20 jul. 2024

VAN DER VOORT, S. *Explanatory dashboards: enhancing data-driven decision-making through explanatory analytics*. 2024. Tese (Doutorado em Data Science) — Tilburg University, Tilburg, 2024. Disponível em: <https://arno.uvt.nl/show.cgi?fid=178954>. Acesso em: 15 set. 2024

VIRTANEN, P. et al. SciPy 1.0: fundamental algorithms for scientific computing in Python. *Nature Methods*, v. 17, p. 261-272, 2020.

WANG, Z.; REN, F. Developing a decision support system for sustainable urban planning using machine learning-based scenario modeling. *Scientific Reports*, v. 15, n. 1, p. 13210, 2025. <https://doi.org/10.1038/s41598-025-90057-5>

WASKOM, M. L. Seaborn: statistical data visualization. *Journal of Open Source Software*, v. 6, n. 60, p. 3021, 2021. <https://doi.org/10.21105/joss.03021>

WOSCHANK, M.; RAUCH, E.; ZSIFKOVITS, H. A review of further directions for artificial intelligence, machine learning, and deep learning in smart logistics. *Sustainability*, v. 12, n. 9, p. 3760, 2020. <https://doi.org/10.3390/su12093760>

YIN, R. K. *Estudo de caso: planejamento e métodos*. 4. ed. Porto Alegre: Bookman, 2010.

YOUN, S. J. et al. A data analytics and machine learning approach to develop a technology roadmap for next-generation logistics utilizing underground systems. *Sustainability*, v. 16, n. 15, p. 6696, 2024. <https://doi.org/10.3390/su16156696>

YUCESAN, M. et al. Evaluating sustainability of urban mobility of Asian cities: an integrated approach of interval type-2 fuzzy best-worst method and MULTIMOORA. *Engineering Applications of Artificial Intelligence*, v. 127, p. 107266, 2024. <https://doi.org/10.1016/j.engappai.2023.107266>

ZHANG, L.; WEI, L.; LI, X. Smart city logistics: concepts, applications, and challenges. In: *Smart Cities: Issues and Challenges*. Elsevier, 2020. p. 157-175.

ZHANG, Q.; SUN, X.; ZHANG, M. Data matters: a strategic action framework for data governance. *Information & Management*, v. 59, n. 4, p. 103642, 2022.

<https://doi.org/10.1016/j.im.2022.103642>

## APÊNDICE A – IDENTIFICAÇÃO E PRIORIZAÇÃO DOS DESAFIOS DA LOGÍSTICA URBANA

| Desafio                                  | Categoria                         | Impacto nas Operações Logísticas                                                                                                                      | Prioridade |
|------------------------------------------|-----------------------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------|------------|
| Congestionamento de Tráfego              | Infraestrutura e Mobilidade       | Aumento dos tempos de entrega, custos operacionais elevados e maior complexidade na gestão de rotas (Parsae & Afshari, 2022).                         | Alta       |
| Limitações de Espaço para Armazenagem    | Infraestrutura e Armazenagem      | Dificuldade em armazenar mercadorias perto dos centros urbanos, aumentando custos e tempos de entrega (Berberoglu et al., 2023).                      | Alta       |
| Demandas Crescentes por Entregas Rápidas | Atendimento ao Cliente            | Pressão por sistemas logísticos mais eficientes e rápidos, exigindo inovação em rotas e otimização de recursos (Dong et al., 2021).                   | Alta       |
| Fragmentação das Operações Logísticas    | Integração de Modos de Transporte | Dificuldade em coordenar múltiplos modos de transporte, resultando em ineficiências e altos custos operacionais (Ullah et al., 2020).                 | Média      |
| Pressão Ambiental e Redução de Emissões  | Sustentabilidade e Regulação      | Necessidade de reduzir as emissões de carbono, adotando práticas mais eficientes e alinhando-se às regulamentações ambientais (Ridaoui et al., 2024). | Média      |
| Custos Elevados de Infraestrutura        | Infraestrutura e Custo            | Altos investimentos em infraestrutura e tecnologias necessárias para modernizar as operações logísticas urbanas (Ren & Salleh, 2024).                 | Alta       |
| Mudanças nas Preferências do Consumidor  | Atendimento ao Cliente            | A adaptação constante a novas expectativas dos consumidores, como entrega em horários flexíveis e personalização do serviço (Heumann et al., 2021).   | Alta       |
| Desafios na Logística de Última Milha    | Transporte e Distribuição         | Dificuldade em entregar mercadorias de forma eficiente e barata nos centros urbanos densos (Teixeira et al., 2023).                                   | Alta       |
| Dependência de Tecnologias Emergentes    | Tecnologia e Inovação             | Dificuldade em implementar e integrar tecnologias como IA, IoT e <i>Big Data</i> em ambientes urbanos (Savin, 2020).                                  | Média      |
| Segurança e Monitoramento de Mercadorias | Segurança e Rastreabilidade       | Necessidade de sistemas eficazes para garantir a segurança das mercadorias durante o transporte e rastreabilidade precisa (Wang et al., 2018)         | Média      |
| Complexidade Regulatória                 | Regulação e Governança            | Complexidade em lidar com regulações locais e internacionais que afetam as operações de transporte e distribuição (Janjelic et al., 2019).            | Alta       |

Fonte: Adaptado de Parsae & Afshari, 2022; Berberoglu et al., 2023; Dong et al., 2021; Ullah et al., 2020

## **APENDICE B - ETAPA 1: ROTEIRO DE ENTREVISTA DE PROFUNDIDADE**

### **Perfil 1 –Entrevista em Profundidade: Profissional de Planejamento Urbano**

#### **Bloco 1: Contexto e prática de planejamento**

1. Que tipos de projetos urbanos você mais avalia no seu dia a dia?
  2. No contexto da mobilidade e da logística urbana, como as decisões orçamentárias são normalmente estruturadas?
- 

#### **Bloco 2: Uso de dados e apoio à decisão**

3. Você costuma utilizar dados históricos, indicadores ou projeções para priorizar investimentos urbanos?
  4. Já teve contato com ferramentas ou modelos preditivos no apoio a decisões financeiras públicas? Como foi essa experiência?
- 

#### **Bloco 3: Inovação na gestão urbana**

5. Como você enxerga o papel de tecnologias baseadas em dados (como modelos preditivos) na modernização da gestão pública urbana?
  6. O uso de dados analíticos poderia contribuir para decisões mais seguras ou justificadas no planejamento de projetos logísticos?
- 

#### **Bloco 4: Aplicabilidade de um framework de apoio à decisão**

7. Que características você considera essenciais para um modelo que oriente decisões orçamentárias em projetos logísticos urbanos?
  8. Você acredita que ferramentas desse tipo seriam bem recebidas em ambientes públicos? O que poderia facilitar ou dificultar essa adoção?
- 

Fonte: Elaborado pela autora

### **Perfil 2 - Entrevista em Profundidade: Participantes da Área de Inteligência Artificial**

#### **Bloco 1: Experiência aplicada em contextos urbanos**

1. Em sua trajetória profissional, você já teve contato com projetos que envolvem dados relacionados a cidades, como mobilidade, transporte, infraestrutura ou serviços urbanos? Caso não diretamente, consegue identificar como seu conhecimento em IA poderia se aplicar a esse tipo de contexto?



2. Na sua percepção, quais são as principais dificuldades técnicas em trabalhar com dados urbanos (ex: mobilidade, tráfego, infraestrutura)?
- 

### **Bloco 2: Modelagem preditiva e desafios técnicos**

3. Quais algoritmos ou abordagens de ML você considera mais eficazes para lidar com problemas logísticos urbanos?
  4. Em sua experiência, quais fatores mais prejudicam a performance de modelos em contextos urbanos?
  5. Como você lida com a atualização e retreinamento de modelos em ambientes urbanos dinâmicos? Isso é viável no setor público?
- 

### **Bloco 3: Visualização e suporte à decisão**

6. Quais são os maiores desafios para tornar os resultados de modelos de ML compreensíveis e acionáveis por gestores não técnicos?
  7. Você acredita que uma interface intermediária — como um Sistema de Suporte à Decisão — pode ajudar a **traduzir modelos em ação prática**? Que tipo de recursos essa interface deveria ter?
- 

### **Bloco 4: Barreiras organizacionais e adoção de soluções**

8. Na sua visão, as estruturas públicas que atuam em cidades possuem as condições técnicas, institucionais e operacionais necessárias para incorporar soluções de Machine Learning de forma consistente e sustentável? Quais fatores você considera facilitadores ou limitadores nesse processo?
- 

### **Bloco 5: Expectativas e diretrizes para um framework viável**

9. Que tipo de diretrizes você considera essenciais para o desenvolvimento de soluções de ML aplicadas à logística urbana?
  10. Que tipo de avaliação (técnica ou de impacto) você considera indispensável para justificar o uso de uma solução baseada em ML em contextos urbanos?
- 

Fonte: Elaborado pela autora

**APÊNDICE C – ETAPA 2: QUESTIONÁRIO FORMULAÇÃO DO FRAMEWORK  
PARA APOIO À DECISÃO COM ML**

| Nº | Perguntas                                                                                                                                  | Discordo Totalmente | Discordo | Não concordo e nem discordo | Concordo | Concordo Totalmente |
|----|--------------------------------------------------------------------------------------------------------------------------------------------|---------------------|----------|-----------------------------|----------|---------------------|
| 1  | Os dados coletados sobre circulação, mobilidade ou entregas urbanas são pouco utilizados na tomada de decisão.                             |                     |          |                             |          |                     |
| 2  | Mesmo quando os dados estão disponíveis, há dificuldades técnicas ou operacionais para integrá-los à tomada de decisão.                    |                     |          |                             |          |                     |
| 3  | A fragmentação de dados entre diferentes setores e sistemas dificulta uma visão integrada da logística urbana.                             |                     |          |                             |          |                     |
| 4  | O uso de ML exige uma base de dados confiável e atualizada, o que nem sempre está disponível nas cidades.                                  |                     |          |                             |          |                     |
| 4  | A aplicação de modelos de Machine Learning pode revelar padrões e gargalos logísticos que os gestores humanos não percebem intuitivamente. |                     |          |                             |          |                     |
| 5  | Soluções baseadas em ML ainda não são utilizadas de forma estratégica porque falta clareza sobre seus limites e possibilidades.            |                     |          |                             |          |                     |
| 6  | O uso de ML exige uma base de dados confiável e atualizada, o que nem sempre está disponível nas cidades.                                  |                     |          |                             |          |                     |
| 7  | Uma das maiores barreiras para o uso de ML na gestão urbana é a dificuldade em interpretar seus resultados de forma prática.               |                     |          |                             |          |                     |
| 8  | Propor mudanças baseadas em dados muitas vezes gera resistência mesmo entre equipes técnicas.                                              |                     |          |                             |          |                     |
| 9  | A complexidade dos modelos de ML pode ser um obstáculo quando não há uma boa comunicação de seus resultados.                               |                     |          |                             |          |                     |
| 10 | Não basta prever cenários logísticos — é necessário que os resultados sejam compreensíveis e acionáveis por quem toma a decisão.           |                     |          |                             |          |                     |

|    |                                                                                                                                     |  |  |  |  |  |
|----|-------------------------------------------------------------------------------------------------------------------------------------|--|--|--|--|--|
| 11 | A cultura da gestão pública ainda enxerga a inovação tecnológica como risco, não como apoio.                                        |  |  |  |  |  |
| 12 | Propor mudanças baseadas em dados muitas vezes gera resistência mesmo entre equipes técnicas.                                       |  |  |  |  |  |
| 13 | Modelos baseados em ML só serão utilizados se forem incorporados a rotinas já estabelecidas, e não como soluções paralelas.         |  |  |  |  |  |
| 14 | Um modelo que integre ML com suporte à decisão precisa ir além da tecnologia — precisa gerar confiança, compreensão e legitimidade. |  |  |  |  |  |
| 15 | Manter as informações e os dados atualizados é essencial para garantir a utilidade dos modelos na tomada de decisão.                |  |  |  |  |  |
| 16 | Diretrizes que orientem como aplicar ML à logística urbana podem ajudar a qualificar decisões e reduzir improvisações.              |  |  |  |  |  |
| 17 | A possibilidade de adaptar o framework à estrutura e maturidade tecnológica local aumenta sua relevância prática.                   |  |  |  |  |  |
| 18 | A infraestrutura tecnológica disponível nas cidades é uma barreira importante para o uso de modelos preditivos.                     |  |  |  |  |  |
| 19 | Problemas como dados desatualizados, incompletos ou ruidosos prejudicam a eficiência dos modelos de ML.                             |  |  |  |  |  |
| 20 | Manter as informações e os dados atualizados é essencial para garantir a utilidade dos modelos na tomada de decisão.                |  |  |  |  |  |

Fonte: Elaborado pela autora

## APÊNDICE D – ETAPA 3: ENTREVISTA PARA VALIDAÇÃO DO FRAMEWORK

| Etapa do Framework                                     | Perguntas da Entrevista Estruturada                                                                                                                                                                                       |
|--------------------------------------------------------|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| 1. Identificação do Problema Urbano                    | <ul style="list-style-type: none"> <li>- Esta etapa é clara e viável para aplicação em contextos reais?</li> <li>- Os métodos sugeridos para identificar o problema são aplicáveis no setor público?</li> </ul>           |
| 2. Diagnóstico de Maturidade Institucional             | <ul style="list-style-type: none"> <li>- Os critérios propostos para avaliar a maturidade digital da instituição são suficientes?</li> <li>- Falta algum aspecto relevante para a análise institucional?</li> </ul>       |
| 3. Mapeamento e Compreensão dos Dados                  | <ul style="list-style-type: none"> <li>- A etapa contempla adequadamente os desafios enfrentados na coleta e padronização de dados?</li> <li>- Há barreiras técnicas adicionais que deveriam ser consideradas?</li> </ul> |
| 4. Preparação e Organização dos Dados                  | <ul style="list-style-type: none"> <li>- Os procedimentos de tratamento de dados estão bem representados?</li> <li>- Essa etapa é realista considerando o nível técnico médio dos municípios?</li> </ul>                  |
| 5. Desenvolvimento do Modelo Preditivo                 | <ul style="list-style-type: none"> <li>- A proposta de uso de algoritmos de machine learning está alinhada com a realidade de projetos urbanos?</li> <li>- Que cuidados deveriam ser reforçados nesta fase?</li> </ul>    |
| 6. Integração com o Sistema de Suporte à Decisão (SSD) | <ul style="list-style-type: none"> <li>- A representação do SSD como interface entre dados e decisão faz sentido para você?</li> <li>- Há sugestões de boas práticas para essa integração?</li> </ul>                     |
| 7. Adoção, Capacitação e Ajustes Operacionais          | <ul style="list-style-type: none"> <li>- Esta etapa cobre bem os desafios de implementação?</li> <li>- Como garantir engajamento e continuidade?</li> </ul>                                                               |
| 8. Validação de Resultados e Retroalimentação          | <ul style="list-style-type: none"> <li>- A proposta de medição de impactos está clara e viável?</li> <li>- O processo de melhoria contínua faz sentido dentro do modelo?</li> </ul>                                       |

Fonte: Elaborado pela autora