UNIVERSIDADE FEDERAL DE ITAJUBÁ

PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

JOSÉ DA SILVA FERREIRA JUNIOR

FRAMEWORK METODOLÓGICO DE MODELAGEM E SIMULAÇÃO HÍBRIDA COM APRENDIZAGEM POR REFORÇO APLICADO À RACIONALIZAÇÃO DE PONTOS DE ÔNIBUS

Itajubá

2026

JOSÉ DA SILVA FERREIRA JUNIOR

FRAMEWORK METODOLÓGICO DE MODELAGEM E SIMULAÇÃO HÍBRIDA COM APRENDIZAGEM POR REFORÇO APLICADO À RACIONALIZAÇÃO DE PONTOS DE ÔNIBUS

Tese submetida ao Programa de Pós-Graduação em Engenharia de Produção (IEPG) da Universidade Federal de Itajubá como parte dos requisitos para obtenção do título de Doutor em Engenharia de Produção.

Área de concentração: Modelagem, Otimização e Controle

Orientador: Dr. Alexandre Ferreira de Pinho

Coorientadora: Dra. Josiane Palma Lima

Itajubá

2026

Ficha catalográfica elaborada pela Biblioteca Mauá
e Seção Técnica de Informática, ICMC/USP,
com os dados inseridos pelo(a) autor(a)

F383f

Ferreira Junior, José da Silva
Framework metodológico de modelagem e simulação híbrida com aprendizagem por reforço aplicado à racionalização de pontos de ônibus / José da Silva Ferreira Junior; orientador Alexandre Ferreira de Pinho; coorientador Josiane Palma Lima. -- Itajubá, 2026.
150 p.

Tese (Doutorado - Programa de Pós-Graduação em Engenharia de Produção) -- Universidade Federal de Itajubá, 2026.

1. Modelagem e Simulação Híbrida. 2. Mobilidade Urbana. 3. Transporte Público. 4. Aprendizagem por Reforço. 5. Acessibilidade. I. Pinho, Alexandre Ferreira de, orient. II. Lima, Josiane Palma, coorient. III. Título.

DEDICATÓRIA

Dedico este trabalho a Deus, à minha mãe, irmãos, namorada, orientadores e a todos que sempre me incentivaram e deram forças para a conclusão desta tese.

AGRADECIMENTOS

Agradeço primeiramente a Deus, que em todos os momentos esteve me iluminando, guiando e dando forças para a conclusão deste trabalho e em todos os momentos de minha vida. Agradeço a Ele todas as alegrias e felicidades durante toda a jornada.

À minha mãe, Nilva Garcia, pelo amor incondicional, carinho, cuidado e paciência, por estar sempre presente, investir e cuidar de minha educação e me apoiar nesta empreitada. Ao meu pai, José da Silva (*in memoriam),* por sempre querer o meu bem.

Aos meus irmãos, Eduardo Henrique e Jane Grisiele, minha gratidão pelo apoio e por fazerem parte de minha vida, entenderem as dificuldades e colaborarem sempre que possível com tudo no dia-a-dia. À minha namorada, Simone Aparecida, obrigado por partilhar comigo as vitórias, estar ao meu lado e compreender com generosidade os momentos de ausência e dedicação aos estudos.

Aos amigos, em especial à Monique Mendes, pelo incentivo contínuo, pelas palavras firmes e por nunca deixar de acreditar em mim; e ao professor Fernando Laugeni, que me deu a primeira oportunidade na carreira acadêmica e confiou no meu potencial. Aos familiares, cada qual ao seu modo, agradeço pela presença e apoio ao longo dessa caminhada. Aos colegas e amigos do NEEAD e do LogTrans, sou grato pelas ideias compartilhadas, pelas leituras críticas e pelos auxílios que contribuíram significativamente para superar os desafios deste trabalho.

Ao meu orientador, Prof. Dr. Alexandre Ferreira de Pinho, agradeço imensamente pela disponibilidade, orientação dedicada e pelos valiosos direcionamentos que moldaram esta pesquisa. À minha coorientadora, Profa. Dra. Josiane Palma Lima, agradeço pelas contribuições intelectuais, sugestões cuidadosas e pelo enriquecimento constante do trabalho.

À Universidade Federal de Itajubá e ao Programa de Pós-Graduação em Engenharia de Produção, registro meu reconhecimento pela estrutura acadêmica oferecida e pelo ambiente de formação científica. Agradeço, também, às agências FAPEMIG, CAPES e CNPq, pelo apoio essencial durante esta jornada de construção do conhecimento.

Por fim, a todos que, de alguma forma, contribuíram para esta conquista, deixo aqui meu mais sincero e profundo agradecimento.

Tantas vezes pensamos ter chegado; Tantas vezes é preciso ir mais além.

Fernando Pessoa

RESUMO

A racionalização de pontos de parada constitui um desafio central no planejamento do transporte público urbano, com implicações diretas na acessibilidade da população, na eficiência operacional do sistema e na qualidade dos deslocamentos. Apesar dos avanços em computação urbana, constata-se uma escassez de *frameworks* capazes de integrar, de forma estruturada e sinérgica, a Simulação Baseada em Agentes (SBA), a Simulação a Eventos Discretos (SED) e a Aprendizagem por Reforço (RL) para apoiar a racionalização da infraestrutura de transporte. Diante dessa lacuna conceitual e metodológica, esta tese tem como objetivo desenvolver um *framework* metodológico de Modelagem e Simulação Híbrida (MSH) para apoiar a racionalização da localização de pontos de parada do transporte público urbano, integrando SBA, SED e RL com base em medidas de acessibilidade e utilização do sistema. O percurso metodológico compreendeu a realização de uma Revisão Sistemática da Literatura (RSL), conduzida segundo o protocolo PRISMA, a formulação teórica do *framework* e sua implementação computacional na plataforma AnyLogic, utilizando como objeto de validação um estudo de caso georreferenciado no município de Passos/MG. O modelo computacional integrou uma população sintética espacialmente distribuída, matrizes origem-destino (OD), rede viária georreferenciada obtida por meio do OpenStreetMap, pontos de interesse urbanos (POIs) e processos comportamentais e operacionais do sistema de transporte. Os parâmetros relacionados ao comportamento dos agentes foram calibrados e validados estatisticamente em relação a dados reais de embarque e bilhetagem. Na etapa de racionalização, empregou-se um algoritmo *Q-Learning* tabular sob política *ε-greedy*, cuja função de recompensa combinou a variação do indicador global de acessibilidade e a variação no número de usuários do transporte coletivo. Em um experimento configurado com 10 episódios e 2.000 passos de treinamento em cada episódio, o modelo identificou configurações espaciais alternativas para a rede de pontos de parada, produzindo melhoria de aproximadamente 8% no indicador global de acessibilidade e aumento superior a 10% no número de usuários, em comparação ao cenário-base calibrado e validado. Os resultados foram obtidos mediante alteração exclusiva da localização dos pontos de parada, mantendo-se inalteradas as linhas, os itinerários e as demais características operacionais do sistema. As novas localizações foram interpretadas como soluções candidatas e posteriormente submetidas à avaliação de viabilidade física e topológica. Os resultados corroboram a viabilidade metodológica e a aplicabilidade do *framework* como instrumento de apoio ao planejamento urbano baseado em evidências. A tese contribui cientificamente ao propor uma estrutura metodológica sistematizada, replicável e adaptável, ampliando as possibilidades de integração entre simulação híbrida, aprendizagem por reforço e análise espacial para apoiar a racionalização do transporte público urbano.

Palavras-chave: Modelagem e Simulação Híbrida; Mobilidade Urbana; Transporte Público; Aprendizagem por Reforço; Acessibilidade; Q-Learning.

ABSTRACT

The rationalization of bus stops represents a major challenge in urban public transportation planning, with direct implications for population accessibility, system operational efficiency, and travel quality. Despite advances in urban computing, there remains a lack of methodological frameworks capable of integrating Agent-Based Simulation (ABS), Discrete-Event Simulation (DES), and Reinforcement Learning (RL) in a structured and synergistic manner to support the rationalization of public transportation infrastructure. To address this conceptual and methodological gap, this dissertation aims to develop a Hybrid Modeling and Simulation (HMS) methodological framework to support the rationalization of urban public transportation bus stop locations by integrating ABS, DES, and RL based on measures of accessibility and system usage. The methodological approach comprised a Systematic Literature Review (SLR) conducted according to the PRISMA protocol, the theoretical formulation of the framework, and its computational implementation in the AnyLogic platform, using a georeferenced case study of the municipality of Passos, Minas Gerais, Brazil, for validation. The computational model integrated a spatially distributed synthetic population, origin–destination (OD) matrices, a georeferenced road network obtained from OpenStreetMap, urban Points of Interest (POIs), and the behavioral and operational processes of the public transportation system. Agent behavioral parameters were calibrated and statistically validated against real boarding and electronic ticketing data. During the rationalization stage, a tabular Q-Learning algorithm employing an ε-greedy policy was implemented, in which the reward function combined variations in the global accessibility indicator with variations in the number of public transportation users. In an experiment configured with 10 episodes and 2,000 training steps per episode, the model identified alternative spatial configurations for the bus stop network, producing an improvement of approximately 8% in the global accessibility indicator and an increase of more than 10% in the number of public transportation users compared with the calibrated and validated baseline scenario. These improvements were achieved exclusively by modifying bus stop locations while keeping routes, itineraries, and all other operational characteristics of the system unchanged. The resulting locations were interpreted as candidate solutions and subsequently subjected to physical and topological feasibility assessments. The results demonstrate the methodological feasibility and practical applicability of the proposed framework as an evidence-based decision-support tool for urban transportation planning. Scientifically, this dissertation contributes by proposing a systematic, replicable, and adaptable methodological framework that expands the possibilities for integrating hybrid simulation, reinforcement learning, and spatial analysis to support the rationalization of urban public transportation.

Keywords: Hybrid Modeling and Simulation; Urban Mobility; Public Transport; Reinforcement Learning; Accessibility; Q-Learning.

LISTA DE FIGURAS

Figura 1 - Área de Interesse da Tese 16
Figura 2 - Fluxo PRISMA para a RSL 18
Figura 3 - Dados iniciais da RSL 20
Figura 4 - Dados dos tipos de simulação da RSL 21
Figura 5 - Funções, interações e estrutura do agente em um ambiente 33
Figura 6 - Incorporação das tecnologias e abordagens no método de pesquisa 50
Figura 7 - Etapa de Concepção do Framework Proposto 52
Figura 8 - Possibilidades de agentes, parâmetros e variáveis para etapa da SBA 54
Figura 9 - Etapa de Implementação do Framework Proposto 56
Figura 10 - Etapa de Análise do Framework Proposto 60
Figura 11 - Simbologia IDEF-Sim 64
Figura 12 - Simbologia do diagrama de estados 65
Figura 13 - IDEF-Sim do agente ônibus na estação de parada 66
Figura 14 - Diagrama de estados do agente ônibus 69
Figura 15 - Diagrama de estados para Matriz OD do agente Passageiro 74
Figura 16 - Diagrama de estados do passageiro para deslocamento com ônibus ou a pé 74
Figura 17 - Boxplot e gráfico de dispersão dos dados de embarque da Linha 1 77
Figura 18 - Modelo conceitual completo 81
Figura 19 - Fluxo de comportamentos do agente Passageiro para construção da Matriz OD 86
Figura 20 - Blocos de ação SED para o agente Ponto de ônibus 88
Figura 21 - Fluxo de comportamento do agente ônibus 88
Figura 22 - Fluxo comportamental do Passageiro para deslocamento origem x destino 89
Figura 23 - Resultados da calibração dos parâmetros probabilísticos de efetivação 91
Figura 24 - Indicador de acessibilidade simulado no AnyLogic® em escala normalizada 94
Figura 25 - Comparação qualitativa pirâmide etária simulada (acima) x censitária (abaixo) 97
Figura 26 - Roteiro de viagem feito pelo passageiro 0 98
Figura 27 - ANOVA Real x Simulado 101
Figura 28 - ANOVA Simulação original x Simulação racionalizada 112
Figura 29 - Gráfico de médias e intervalos de confiança de 95% entre modelo original e racionalizado 114
Figura 30 - Localização dos pontos por linha atual (acima) e racionalizado (abaixo) 117
Figura 31 - Análise da nova localização do ponto 1 linha 1 119

Figura 32 - Análise da nova localização do ponto 7, linha 1.....120
Figura 33 - Resumo gráfico do Framework.....121

LISTA DE QUADROS

Quadro 1 - Taxonomia de modelagem e simulação híbrida 16
Quadro 2 - Exemplificação de trabalhos e lacunas 20
Quadro 3 - Métodos de simulação utilizado nos artigos selecionados na RSL 21
Quadro 4 - Impactos e inovações da tese 24
Quadro 5 - Técnicas para racionalização e roteirização de pontos de ônibus 28
Quadro 6 - Definições de Simulação 29
Quadro 7 - Etapas propostas para projetos de simulação segundo a literatura 30
Quadro 8 - Classificação da MSBA de acordo com as propriedades dos agentes 32
Quadro 9 - Exemplos de aplicações de MSH em Mobilidade e TP 36
Quadro 10 - Descrição das estruturas de modelagem para TP 37
Quadro 11 - Destinos para a população sintética 39
Quadro 12 - Resumo de dados de entrada para construção da simulação em mobilidade 40
Quadro 13 - Classificação de indicadores para modelos de mobilidade 42
Quadro 14 - Definições de Aprendizado de Máquina 43
Quadro 15 - Resumo das etapas de Concepção do Framework Proposto 53
Quadro 16 - Resumo das etapas de Implementação do Framework Proposto 57
Quadro 17 - Resumo das etapas de Análise do Framework Proposto 59
Quadro 18 - Resumo do agente Ponto de ônibus 68
Quadro 19 - Resumo do agente ônibus 70
Quadro 20 - Resumo do agente Pontos de Interesse 71
Quadro 21 - Parâmetros e variáveis do agente Passageiro incorporados no objeto de estudo 73
Quadro 22 - Resumo do agente Passageiro 75
Quadro 23 - Resultados qualitativos da verificação por inspeção 96
Quadro 24 - Exemplo de análise da alteração para os pontos racionalizados 118

LISTA DE TABELAS

Tabela 1 - Atributo idade do agente Passageiro 72
Tabela 2 - Exemplo de dados após filtros para a Linha 1 77
Tabela 3 - Média e Desvio Padrão Amostral do número de usuários por linha 78
Tabela 4 - Exemplo dos dados georreferenciados dos POIs e seus tipos 85
Tabela 5 - Exemplo da Matriz OD gerada por simulação 85
Tabela 6 - Exemplo tabulação ponto de ônibus 87
Tabela 7 - Exemplo dos tempos simulados de deslocamento pedonal até ponto de ônibus 92
Tabela 8 - Exemplo do valor de acessibilidade dos pontos de ônibus de Passos/MG 93
Tabela 9 - Exemplo de emulações de viagens AnyLogic® 99
Tabela 10 - Componentes estruturais do experimento *Q-Learning* no AnyLogic® 108
Tabela 11 - Exemplos de localização original x localização racionalizada 110
Tabela 12 - Comparação entre médias de usuários entre simulações 115
Tabela 13 - Índices de viabilidade qualitativa dos pontos racionalizados 119
Tabela 14 - Acessibilidade dos pontos de ônibus 139
Tabela 15 - Análise qualitativa da viabilidade de alteração de localização dos pontos de ônibus após racionalização 142

LISTA DE SIGLAS

ANOVA	Análise de Variância
API	Application Programming Interface
DOI	Digital Object Identifier
GIS	Sistema de Informação Geográfica
IDEF-Sim	Integrated Definition Methods - Simulation
FIFO	First-in first-out – Primeiro que entra, primeiro que sai
GLM	Modelo Linear Geral
Matriz OD	Matriz Origem-Destino
ML	Machine Learning – Aprendizagem de máquina
MSH	Modelagem e Simulação Híbrida
ODD	Overview, Design Concepts, and Details
OSM	OpenStreetMap
PO	Pesquisa Operacional
POI	Pontos de Interesse
RSL	Revisão Sistemática da Literatura
RL	Reinforcement Learning – Aprendizagem por reforço
SBA	Simulação Baseada em agentes
SD	Simulação Dinâmica
SEA	Soma dos Erros Absolutos
SED	Simulação a eventos discretos
SIG	Sistemas de Informações Geográficas
TP	Transporte público
V&V	Verificação e Validação
WoS	Web of Science

SUMÁRIO

1 INTRODUÇÃO 14

1.1 Visão Geral e Relevância da Pesquisa 14

1.2 Justificativa e Revisão Sistemática da Literatura 15

1.3 Pergunta da pesquisa, Objetivo Geral e Objetivos Específicos 22

1.4 Contribuição Científica, Impacto e Inovação 23

1.5 Estrutura do trabalho 25

2 FUNDAMENTAÇÃO TEÓRICA 26

2.1 Mobilidade urbana e Transporte Público 26

2.2 Modelagem e Simulação 29

2.3 Modelagem e Simulação híbrida em transporte público 35

2.4 Aprendizagem de máquina 43

3 MÉTODO DE PESQUISA 48

4 DESENVOLVIMENTO DO PROTOCOLO DE PESQUISA (FRAMEWORK MSH EM TRANSPORTE PÚBLICO) 51

4.1 Concepção 51

4.2 Implementação 55

4.3 Análise e Experimentação 58

5 MODELAGEM E SIMULAÇÃO DO OBJETO DE ESTUDO 63

5.1 Concepção do objeto de estudo 63

5.2 Implementação do objeto de estudo 80

5.3 Análise e experimentação do objeto de estudo 104

6 CONCLUSÕES 122

REFERÊNCIAS 127

APÊNDICE A – ACESSIBILIDADE DOS PONTOS DE ÔNIBUS 139

APÊNDICE B – VIABILIDADE DE ALTERAÇÃO DO PONTO DE ÔNIBUS PARA O RACIONALIZADO 142

APÊNDICE C – REPOSITÓRIO DA PESQUISA 148

1 INTRODUÇÃO

1.1 Visão Geral e Relevância da Pesquisa

A mobilidade urbana constitui um dos principais desafios enfrentados pelas cidades contemporâneas, influenciando diretamente o acesso da população a oportunidades de trabalho, educação, saúde, lazer e demais atividades cotidianas. O crescimento populacional, a expansão territorial das áreas urbanas e o aumento da demanda por deslocamentos tornam necessária a busca por soluções que promovam sistemas de transporte mais eficientes, acessíveis e sustentáveis (Santos; Lima, 2021; Toro-Gonzalez; Cantillo; Cantillo-Garcia, 2020; Vidovic; Sostaric; Budimir, 2019).

Nesse contexto, Manser *et al.* (2020) e Palanca *et al.* (2021) observam que o transporte público coletivo por ônibus desempenha papel fundamental na promoção da mobilidade urbana, especialmente em cidades de pequeno e médio porte, onde frequentemente representa o principal modo motorizado disponível à população. Apesar dos avanços na literatura deste tema, permanecem desafios associados à complexidade crescente das cidades e à demanda por sistemas mais confiáveis, eficientes e adaptáveis. Ademais, muitos sistemas de transporte operam com limitações relacionadas à cobertura espacial, à distribuição dos pontos de parada, aos tempos de deslocamento e à acessibilidade dos usuários aos serviços ofertados (Santos; Oliveira; Simões, 2026; Palanca *et al.*, 2021; Senne; Lima; Favaretto, 2021).

A acessibilidade constitui um dos principais indicadores de desempenho dos sistemas de transporte, pois expressa a facilidade com que indivíduos conseguem alcançar destinos e oportunidades distribuídos no espaço urbano. Entre os diversos fatores que influenciam essa condição, destaca-se a localização dos pontos de parada de ônibus, cuja distribuição inadequada pode ampliar distâncias de caminhada, reduzir a atratividade do transporte coletivo e comprometer a eficiência operacional do sistema (Ceder, 2007; Cipriani; Gori; Petrelli, 2012; Current; Daskin; Schilling, 2002; Delling *et al.*, 2009; Laporte, 2009; Mandl, 1980; Schilling; Jayaraman; Barkhi, 1993). Dessa forma, a racionalização da rede de pontos de parada surge como uma alternativa para equilibrar cobertura espacial, acessibilidade dos usuários e eficiência operacional.

Apesar da relevância do tema, a literatura ainda apresenta limitações na integração de diferentes abordagens capazes de representar simultaneamente o comportamento individual dos

usuários, a dinâmica operacional do transporte coletivo e os processos de otimização ou racionalização associados ao planejamento da rede (Kagho *et al.*, 2021; Lessa; Lobo; Cardoso, 2019; Leobons; Campos; Bandeira, 2019; Buyukozkan; Ilicak, 2022). Estudos frequentemente utilizam paradigmas isolados de modelagem, dificultando a representação integrada da complexidade inerente aos sistemas urbanos de transporte. A Seção 1.2 aborda com mais detalhes estas limitações da literatura.

1.2 Justificativa e Revisão Sistemática da Literatura

A relevância desta pesquisa reside na necessidade de antecipar e compreender como os sistemas urbanos respondem a novos eventos e influências, conectando o comportamento individual (microscópico) ao comportamento coletivo das cidades (macroscópico). Torna-se, portanto, imprescindível adotar métodos integrados, que combinem diferentes métricas e abordagens multidimensionais voltadas ao aprimoramento da mobilidade urbana (Manley *et al.*, 2014; Vidovic; Sostaric; Budimir, 2019; Mahmoudi; Saidi; Wirasinghe, 2024).

Neste contexto, cresce o interesse pela aplicação de simulação computacional e aprendizado de máquina no transporte público. Essas abordagens permitem representar sistemas complexos e apoiar decisões em ambientes urbanos caracterizados por elevada heterogeneidade e dinamismo (Huang *et al.*, 2022; Hong; Jung, 2016).

Apesar dos avanços em simulação híbrida e aprendizado de máquina, ainda são escassos *frameworks* que integrem essas abordagens de forma estruturada e replicável no contexto da mobilidade urbana. Esta falta de sistematização dificulta a comparabilidade e compromete a reprodutibilidade, reduzindo a utilidade prática dos modelos (Alves *et al.*, 2019; Martins, 2022; Oliveira *et al.*, 2022; Torres *et al.*, 2020). A combinação de abordagens de simulação (Modelagem e simulação híbrida – MSH) fortalece a análise de dinâmicas complexas no transporte público, emergindo como uma prática promissora para representar sistemas complexos (Bounadi; Boussalia; Bellaouar, 2023; Carmen; Idalia, 2023). Assim, é relevante se propor o desenvolvimento de um quadro que organize os elementos da MSH, fortalecendo sua robustez metodológica e utilidade no plano urbano.

Para demonstrar tal fato, esta pesquisa se insere em uma interseção teórica ainda pouco explorada: (i) a aplicação simultânea de simulação híbrida (Simulação a Eventos Discretos (SED) + Simulação Baseada em Agentes (SBA)); (ii) algoritmos de aprendizado por reforço; (iii) e indicadores de acessibilidade no contexto do transporte público urbano por ônibus. Apesar do avanço isolado desses campos, a literatura carece de propostas integradoras que

tratem a complexidade estrutural, operacional e comportamental dos sistemas urbanos de forma sinérgica e replicável. A Figura 1 ilustra essa convergência temática.

Figura 1 - Área de Interesse da Tese

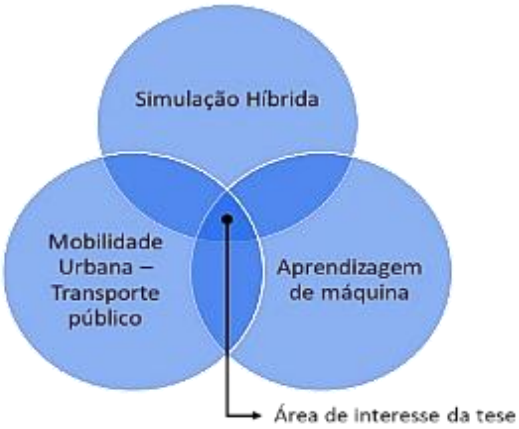

Fonte: Elaborado pelo autor (2026).

Incorporar incertezas em várias etapas de planejamento no transporte público, como projeto de rede, planejamento de linhas e elaboração de horários, é uma área de pesquisa cada vez mais importante, porém desafiadora. Embora diversos estudos tenham começado a abordar a natureza incerta dos parâmetros da vida real nesses domínios, a escolha de uma abordagem de modelagem apropriada permanece complexa e frequentemente ambígua (Klasovitá; Corman, 2026).

Para mitigar essas limitações, Mustafee, Harper e Fakhimi (2022) propuseram uma taxonomia com seis tipos de hibridismo, detalhados no Quadro 1, sendo esta tese embasada no tipo E.

Quadro 1 - Taxonomia de modelagem e simulação híbrida

Classificação	Definição
Tipo A	Simulação híbrida de múltiplas metodologias, usando métodos discretos e contínuos simultaneamente.
Tipo B	Simulação híbrida de múltiplas técnicas, usando mais de um método, mas sempre discreto ou contínuo, sem misturar ambos.
Tipo C	Simulação híbrida de múltiplas técnicas e metodologias, quando há uso de métodos discretos e contínuos, com mais de uma técnica em cada um deles;
Tipo D	Modelo Híbrido com técnicas de Pesquisa Operacional (algoritmos de otimização, por exemplo) ou de Gestão de Processos (*Business Intelligence*, por exemplo) em conjunto com a simulação.
Tipo D1	Modelo Híbrido com técnicas de Pesquisa Operacional ou de Gestão de Processos com simulação multiparadigma tanto qualitativo quanto quantitativo.
Tipo E	Modelo Híbrido com PO e Gestão de Processos com simulação em diferentes campos de pesquisa, como logística, saúde ou outros.

Fonte: Adaptado de Mustafee, Harper e Fakhimi (2022) e Tolk, Harper e Mustafee (2021).

Articulando-se à MSH sob a taxonomia de "Estudo Tipo E", o Aprendizado por Reforço (RL) emerge como um paradigma matemático robusto para governar processos decisórios em ambientes estocásticos, dinâmicos e sequenciais, propriedades intrínsecas aos sistemas de transporte coletivo urbano (Sutton; Barto, 2018). Nesse panorama, o emprego de abordagens fundamentadas em inteligência artificial e aprendizado de máquina tem se consolidado na literatura como vetor de suporte a mecanismos preditivos, de otimização de recursos e de tomada de decisão em cenários de infraestrutura e mobilidade (Huang *et al.*, 2022).

Embora abordagens meta-heurísticas clássicas de otimização combinatória (tais como Algoritmos Genéticos, Busca Tabu, algoritmos de busca local estocástica, entre outros) sejam amplamente consagradas na resolução de problemas de localização de facilidades e roteirização, tais formulações operam, via de regra, sob uma perspectiva de otimização estática. Esses métodos convencionais convergem para soluções ótimas vinculadas a instantâneos ou configurações rigidamente predefinidas do sistema. Em contrapartida, o RL viabiliza uma arquitetura na qual o agente inteligente deduz e refina progressivamente sua política de controle por meio de interações assíncronas com o modelo simulado. Desse modo, as diretrizes de ação sofrem uma calibragem adaptativa face às flutuações operacionais e às respostas comportamentais dos usuários emuladas ao longo do horizonte de simulação (Santos; Oliveira; Simões, 2026; Sutton; Barto, 2018; Huang *et al.*, 2022).

Essa propriedade confere ao RL uma melhor aderência para o tratamento de ecossistemas urbanos de alta complexidade, nos quais variáveis críticas (como o indicador de acessibilidade espacial, as matrizes de origem-destino e a velocidade operacional da rede viária abordadas nesta tese) manifestam forte variabilidade espaço-temporal. Em resumo, a capacidade de autoajuste contínuo do agente, balizada pelo método de tentativa e erro inserido no ciclo fechado Estado-Ação-Recompensa, transforma o modelo de simulação híbrida em um laboratório dinâmico para a indução de políticas racionalizadas de infraestrutura (Huang *et al.*, 2022; Jang *et al.*, 2019; Santos; Oliveira; Simões, 2026; Sutton; Barto, 2018).

Para fundamentar a pesquisa, foi conduzida uma Revisão Sistemática da Literatura (RSL) seguindo protocolos explícitos e reprodutíveis, com dados de qualidade para síntese e análise (Samnami *et al.*, 2017). Para tanto, utilizou-se procedimento alinhado às diretrizes metodológicas executadas por Mehdizadeh, Nordfjaern e Klockner (2022), Carmen e Idalia (2023) e Stockkamp *et al.* (2021).

A RSL utilizou o protocolo PRISMA, composto por três etapas: identificação; triagem; e elegibilidade (Badakhshan; Mustafee; Bahadori, 2024; Stockkamp *et al.*, 2021). As buscas ocorreram em julho de 2025 nas bases Web of Science (WoS) e SCOPUS, reconhecidas por

sua cobertura multidisciplinar e elevado rigor editorial (Chadegani *et al.*, 2013). Ressalta-se que essas bases não esgotam as fontes de literatura potencialmente relacionadas ao tema. Bases especializadas, como a Transport Research International Documentation (TRID), direcionada especificamente à pesquisa em transportes, e a IEEE Xplore Digital Library, com ampla cobertura de publicações nas áreas de engenharia, computação, inteligência artificial e sistemas tecnológicos, também podem conter estudos aderentes às combinações de termos investigadas. Dessa forma, sua utilização em revisões futuras poderá ampliar a abrangência do levantamento e complementar o corpus obtido nesta pesquisa.

A primeira busca nas bases supracitadas, com a *string* (“hybrid simulation” AND “machine learning” AND “public transport”), não retornou resultados relevantes, evidenciando inconsistência terminológica na área. A ausência de resultados relevantes na primeira rodada de busca evidencia a falta de padronização terminológica no campo da modelagem híbrida, confirmando a crítica de Brailsford *et al.* (2019). Tal inconsistência compromete a localização, classificação e comparação entre estudos, limitando a construção de *frameworks* replicáveis e metodologicamente robustos. Assim, replicando a estratégia desses mesmos autores, refez-se a busca com uma nova definição de *strings*. O modelo PRISMA para esta segunda tratativa da RSL é apresentado na Figura 2.

Figura 2 - Fluxo PRISMA para a RSL

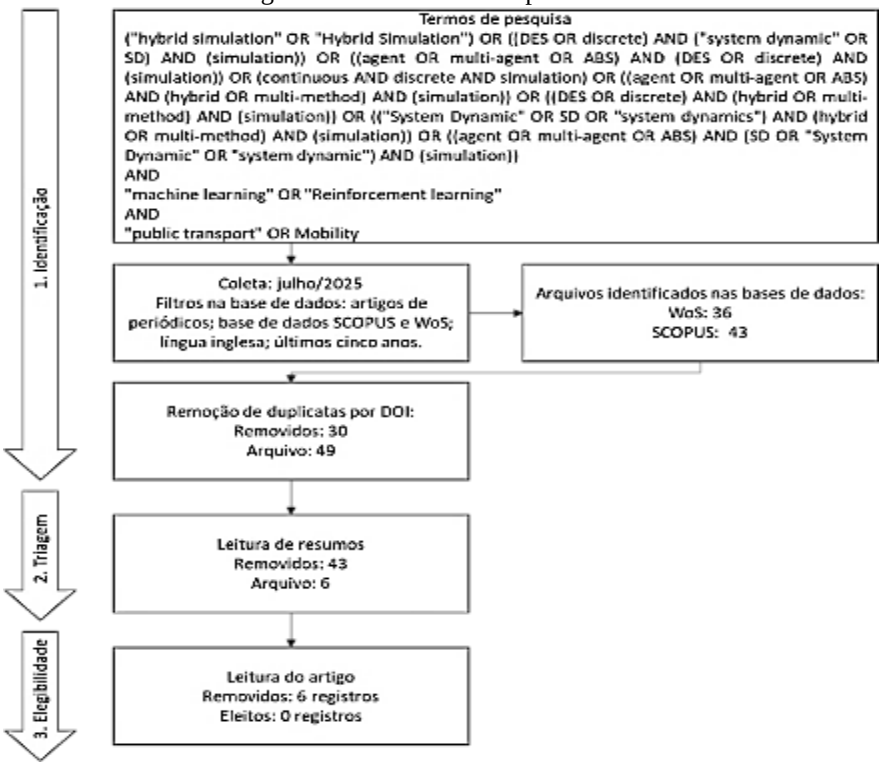

Fonte: Elaborado pelo autor (2026).

Na fase de triagem da segunda coleta, foram excluídos 37 artigos que, embora contivessem termos da *string* de busca, não tratavam de mobilidade urbana ou simulação. Outros 6 artigos foram descartados por abordarem apenas simulações restritas a elementos isolados, como semáforos, rampas de acesso ou pontos de recarga de veículos elétricos, sem relação direta com o escopo desta pesquisa.

Na fase de elegibilidade, os 6 artigos restantes foram considerados inadequados. Cinco deles não aplicavam simulação híbrida, limitando-se a apenas um paradigma (SED, SBA ou SD), ou utilizavam exclusivamente fórmulas analíticas e dados probabilísticos. O sexto, embora integrasse MSH e aprendizado de máquina, focava no planejamento de velocidade em vias urbanas, sem abordar mobilidade urbana como definida neste trabalho (Lu *et al.*, 2024).

Esses resultados evidenciam a escassez de estudos na interseção entre simulação híbrida, mobilidade urbana e aprendizado de máquina, reforçando a lacuna que esta tese busca explorar. Para aprofundar a compreensão sobre como a literatura tem tratado a combinação entre mobilidade urbana e simulação híbrida, foi realizada uma terceira coleta, desta vez excluindo os termos relacionados ao aprendizado de máquina. Com esta nova coleta de dados, o seguinte passo a passo foi realizado, seguindo o mesmo método PRISMA supracitado:

- Fase de Identificação: (i) foram encontrados 294 registros (153 na WoS e 141 na SCOPUS); (ii) remoção de duplicatas: 29 artigos excluídos com base no código DOI;
- Fase de Triagem: leitura dos resumos resultou na exclusão de 186 registros que não tratavam de mobilidade urbana nem de simulação híbrida;
- Fase de Elegibilidade: dos 79 restantes, 8 foram excluídos por restrição de acesso, resultando em 71 artigos completos para análise.

A Figura 3 resume os dados básicos da amostragem final. Observou-se que, embora haja publicações recentes sobre simulação híbrida aplicada à mobilidade urbana, o número de trabalhos manteve-se relativamente estável nos últimos cinco anos, sugerindo uma possível fase de maturação da temática.

Figura 3 - Dados iniciais da RSL

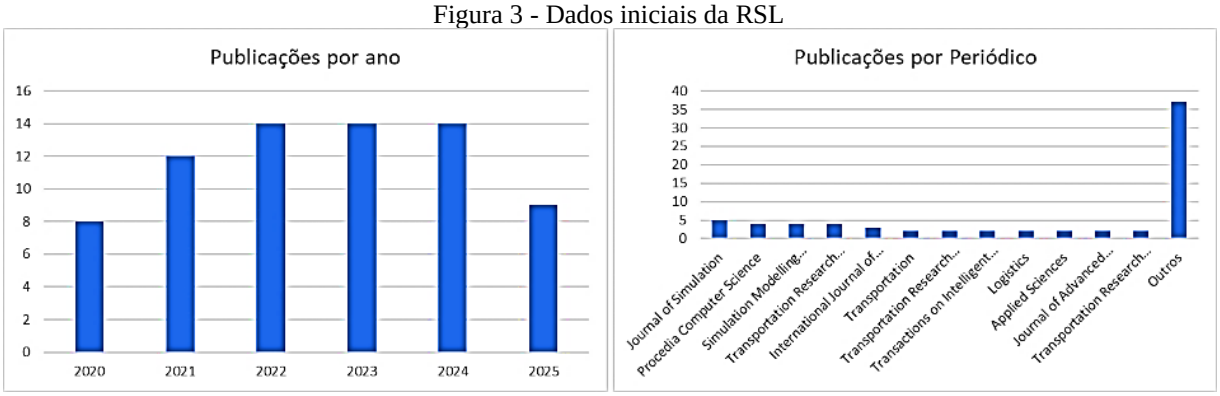

Fonte: Elaborado pelo autor (2026).

A análise dos 71 artigos incluídos na amostra final revelou que apenas 30 utilizam efetivamente algum tipo de modelagem híbrida com aplicabilidade ao transporte urbano. Ainda assim, nenhum destes contempla simultaneamente os paradigmas SED e SBA com integração explícita de algoritmos de aprendizado de máquina, evidência clara da lacuna que esta pesquisa pretende preencher. Sintetiza-se no Quadro 2 esta evidência e o foco desta tese.

Quadro 2 - Exemplificação de trabalhos e lacunas

Estudo	Tipo de Simulação	Domínio Aplicado	Algoritmo de ML	Limitações
Yao e Schomocker (2023)	SBA + SED	Bicicletas compartilhadas	Não	Sem RL, foco em reservas
Muravev *et al.* (2021)	SED + SBA + SD	Transporte intermodal	Não	Sem aprendizado adaptativo
Bae *et al.* (2022)	SBA + SD + Metaheurística	Transporte coletivo	Sim (heurístico)	Sem simulação realista
Proposta desta tese	SED + SBA + RL	Ônibus urbanos	Sim (*Reinforcement Learning*)	-

Fonte: Elaborado pelo autor (2026).

A maioria dos modelos foi classificada como axiomática descritiva, com foco na construção conceitual e computacional dos modelos. Quanto ao tipo de agente, a maioria era interativa, com influência mútua entre agentes e o ambiente. Como exemplo, Muravev *et al.* (2021) executaram uma MSH para identificar parâmetros chave que interferem no desempenho de um terminal multimodal. A Figura 4 ilustra estas três características dos artigos de cunho prático extraídos da RSL.

Figura 4 - Dados dos tipos de simulação da RSL

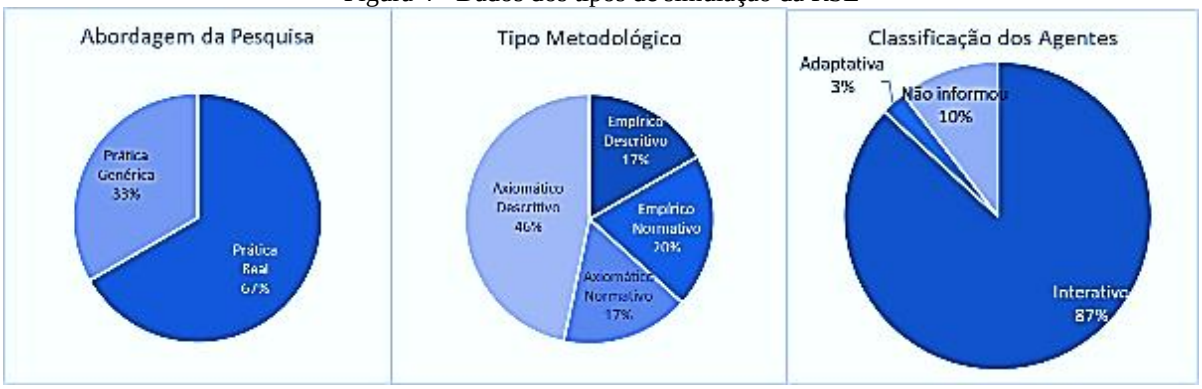

Fonte: Elaborado pelo autor (2026).

A maioria dos estudos apresentou diagramas conceituais, como fluxogramas, BPMN ou diagramas de estados, embora poucos tenham relatado a validação formal desses modelos. Em termos de software, cerca de 70% utilizaram o AnyLogic®, enquanto outros optaram por AnyLogistix, Siemens Tecnomatrix, entre outros. Ainda destes 30 artigos extraídos da RSL, foi possível classificar o tipo de método de simulação utilizados transporte público e/ou mobilidade, conforme apresenta o Quadro 3, destacando o trabalho de Muravev *et al.* (2021) que utilizou os três tipos.

Quadro 3 - Métodos de simulação utilizado nos artigos selecionados na RSL

Artigos	SED	SBA	SD	Artigos	SED	SBA	SD
Silva, Lima e Alves (2024)	x	x		**Schuhmann *et al.* (2025)**	x	x	
Xanthopoulos e Kostavelis (2024)	x		x	**Kaboudvand e Montreuil (2024)**	x	x	
Ercan *et al.* (2022)	x		x	**Kulkarni *et al.* (2022)**	x	x	
Kadosh, Simuany-Stern e Biten (2023)	x	x		**Farhan, Krejci e Cantor (2023)**	x	x	
Zeng, Li e Li (2024)	x	x		**Zhang *et al.* (2021)**	x	x	
Castrellon *et al.* (2023)	x	x		**Torbali e Alpan (2023)**	x	x	
Sungkono *et al.* (2024)	x	x		**Muravev *et al.* (2021)**	x	x	x
Cramer e Fikar (2024)	x	x		**Hussein *et al.* (2023)**	x	x	
Cunha, Reis e Teixeira (2022)	x	x		**Bounadi, Boussalia e Bellaouar (2023)**	x	x	
Man *et al.* (2020)		x	x	**Pessoa *et al.* (2025)**	x	x	
Scorrano e Danielis (2022)		x	x	**Yao e Schmocker (2023)**	x	x	
Al-Hawari *et al.* (2022)	x		x	**Hu, Li e Wu (2023)**	x	x	
Castillo *et al.* (2022a)	x	x		**Santana *et al.* (2021)**	x	x	
Castillo *et al.* (2022b)	x	x		**Bashabsheh (2024)**	x	x	
Bae *et al.* (2022)		x	x	**Binsfeld e Gerlach (2022)**	x	x	

Fonte: Elaborado pelo autor (2026).

A verificação e validação (V&V) ainda são tratadas superficialmente na MSH. A maioria dos artigos mencionou entrevistas com especialistas ou comparação com dados históricos, sem métodos quantitativos rigorosos, conforme crítica de Brailsford *et al.* (2019).

Mais de 60% dos estudos analisaram algum modo de transporte, como carros, trens, bicicletas e robôs logísticos. Destaca-se a dificuldade recorrente em modelar a interação entre múltiplos elementos e garantir a replicabilidade dos modelos, conforme também critica Brailsford *et al.* (2019). Mustafee, Harper e Fakhimi (2022) também apresentam inconsistências terminológicas sobre o que constitui simulação híbrida, confundindo métodos (SED, SBA, SD) com técnicas (IA e meta-heurísticas).

Exemplificam-se as apreciações negativas com o trabalho de Prajapati, Bhaumik e Kumar (2023), os quais informaram em seus termos iniciais que executariam uma simulação híbrida, no entanto, utilizaram o método SBA em conjunto com ferramentas meta-heurísticas para chegar aos seus resultados. Também os trabalhos de Khattak e Hussain (2021) e de Faria *et al.* (2024) careceram de uma melhor definição da simulação ou modelagem híbrida, pois ambos utilizam a SED em conjunto com meta-heurísticas para buscar otimizações, também não vinculando outros tipos de simulação.

Como propostas futuras de trabalho neste tema de modelagem híbrida, Brunetti e Campuzano (2022) e Xanthopoulos e Kostavelis (2024) sugerem a ampliação da coleta de dados e a incorporação de maior quantidade de variáveis comportamentais. Já Bae *et al.* (2022) e Binsfeld e Gerlach (2022) apontam o uso de inteligência artificial e meta-heurísticas para refinar resultados. Ambas as propostas reforçam a relevância da proposta desta tese.

Os resultados revelam uma lacuna metodológica clara dentro dos limites da estratégia de busca adotada nas bases de dados científicos: não foi identificado, até o presente momento, nenhum estudo publicado que integre simultaneamente simulação baseada em agentes, simulação a eventos discretos e algoritmos de aprendizado por reforço em sistemas de transporte público urbano por ônibus. Esta ausência reforça a originalidade e a relevância científica da proposta apresentada na tese. A consolidação dessa abordagem representa um avanço no campo da engenharia de produção aplicada à mobilidade urbana.

1.3 Pergunta da pesquisa, Objetivo Geral e Objetivos Específicos

Nesse contexto, a questão central desta tese é: como estruturar um *framework* metodológico de Modelagem e Simulação Híbrida que integre SBA, SED e RL para apoiar a racionalização da localização de pontos de parada do transporte público urbano com base em medidas de acessibilidade e utilização do sistema? Para tanto, parte-se da hipótese de que a integração estruturada entre Simulação Baseada em Agentes, Simulação a Eventos Discretos e Aprendizagem por Reforço, em um *framework* metodológico de Modelagem e Simulação

Híbrida, permite representar conjuntamente as dimensões comportamentais, espaciais, operacionais e decisórias do transporte público urbano e apoiar a identificação de configurações locacionais com melhor desempenho agregado de acessibilidade e atendimento da demanda em relação ao cenário-base.

Diante disto, o objetivo desta pesquisa é desenvolver um *framework* metodológico de Modelagem e Simulação Híbrida para apoiar a racionalização da localização de pontos de parada do transporte público urbano, integrando Simulação Baseada em Agentes, Simulação a Eventos Discretos e Aprendizagem por Reforço com base em medidas de acessibilidade e utilização do sistema.

Para alcançar esse objetivo, a pesquisa propõe os seguintes objetivos específicos:

- Sistematizar, por meio de Revisão Sistemática da Literatura, os fundamentos, componentes, práticas metodológicas e lacunas relacionados à aplicação da Modelagem e Simulação Híbrida em sistemas de mobilidade urbana e transporte público;
- Conceber e formalizar a arquitetura do *framework* metodológico, definindo suas fases, componentes, agentes, fluxos de informação, indicadores, mecanismos de integração e procedimentos de verificação e validação;
- Implementar computacionalmente o *framework* proposto em um ambiente híbrido tipo E e georreferenciado de transporte público urbano, de modo a representar de forma integrada as dimensões comportamental, espacial e operacional do sistema;
- Avaliar a validade e a aplicabilidade do *framework* por meio de sua implementação em um objeto de estudo real, utilizando procedimentos de calibração, verificação, validação e análise estatística;
- Analisar os efeitos da racionalização locacional dos pontos de parada sobre a acessibilidade e a utilização do transporte público, comparando o cenário-base com o cenário produzido pelo mecanismo de Aprendizagem por Reforço.

1.4 Contribuição Científica, Impacto e Inovação

A principal contribuição científica desta tese consiste na proposição de um *framework* metodológico para MSH aplicada ao transporte público urbano. Essa combinação, segundo Huang *et al*. (2022), viabiliza decisões orientadas por dados e padrões aprendidos, aumentando a adaptabilidade e a robustez preditiva. Tal proposta também responde a recomendações recentes da literatura quanto ao aprimoramento de modelos integrados aplicados ao transporte

público por ônibus, conforme Santos, Oliveira e Simões (2026), Ferreira Junior, Lima e Pinho (2024), Badakhshan, Mustafee e Bahadori (2024) e Zhukov e Moroz (2021). A aplicação direta no objeto de estudo de Passos/MG demonstra sua viabilidade operacional, com potencial de expansão para outras cidades de médio porte.

A pesquisa também oferece um quadro metodológico padronizado para construção de modelos híbridos, algo pouco encontrado na literatura atual. Ao organizar as etapas de concepção, implementação e validação, bem como definir categorias de agentes, indicadores e fluxos operacionais, o *framework* contribui para a transparência científica, replicabilidade experimental e formação acadêmica de novos pesquisadores da área.

A natureza transdisciplinar da proposta, ao integrar engenharia de produção, pesquisa operacional, ciência de dados e políticas públicas, permite modelar sistemas urbanos de forma mais realista e adaptativa. O modelo simula não apenas fluxos físicos, mas também incorpora aprendizagem progressiva dos agentes frente à dinâmica urbana.

Por fim, o modelo desenvolvido apresenta alto potencial de aplicação prática. Sua estrutura modular e compatível com dados georreferenciados facilita sua adoção por gestores públicos, operadores de transporte e instituições de planejamento urbano, com perspectivas de redução de custos operacionais, ampliação da cobertura e aumento da eficiência dos deslocamentos. O Quadro 4 resume os principais impactos e inovações.

Quadro 4 - Impactos e inovações da tese

Eixo	Inovação	Impacto	Lacuna resolvida
Framework híbrido tipo E	Modelo unificado SBA e SED estruturado.	Metodológico e replicável.	Falta de estrutura padronizada em MSH para mobilidade em TP.
Aprendizagem de máquina por reforço	Racionalização dos pontos de ônibus com algoritmos *machine learning*.	Operacional e estratégico.	Métodos heurísticos estáticos com menor eficiência para apresentar comportamento de agentes.
Aplicação prática	Estudo real com dados de Passos/MG.	Prático e transferível.	Baixa viabilidade operacional dos modelos existentes.
Sistematização e padronização	Modelo com agentes, dados, indicadores e etapas documentadas.	Científico e didático.	Fragmentação e baixa reprodutibilidade.

Fonte: Elaborado pelo autor (2026).

1.5 Estrutura do trabalho

Em conformidade com os objetivos e justificativas apresentados nesta Seção 1, de Introdução, a presente tese organiza-se em mais cinco seções, estruturadas de forma a conduzir o leitor pela fundamentação teórica, metodologia, aplicação prática e etapas finais da pesquisa.

A Seção 2 apresenta os fundamentos conceituais necessários ao desenvolvimento do trabalho, sendo subdividida em quatro tópicos: (i) mobilidade urbana e transporte público; (ii) modelagem e simulação de sistemas; (iii) modelagem e simulação híbrida (MSH) aplicada à mobilidade urbana com transporte coletivo; e (iv) técnicas de aprendizado de máquina, com ênfase no aprendizado por reforço.

A Seção 3 descreve a metodologia adotada, abordando a taxonomia da pesquisa dada como aplicada, quali-quantitativa e metodologicamente dedicada à modelagem e simulação do tipo axiomático-descritivo. Já a Seção 4 apresenta o protocolo metodológico, ou seja, o *framework* da pesquisa, incluindo a definição das etapas, os fundamentos teóricos que o sustentam e os procedimentos previstos para sua implementação.

A Seção 5, aplica as etapas do *framework*, no objeto de estudo real, com o objetivo de validar empiricamente os elementos estruturantes do modelo proposto. Inicia-se construindo o modelo conceitual com todos os seus elementos de caracterização. Passa-se para o design da pesquisa com o desenvolvimento do modelo computacional e suas calibrações, validações e verificações. Finaliza-se este quinto tópico com a inserção do ML no algoritmo para racionalizar a posição dos pontos de ônibus. Por fim, na seção 6 há a conclusão do trabalho seguido das referências e apêndices.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Mobilidade urbana e Transporte Público

A mobilidade urbana refere-se à capacidade de deslocamento de pessoas e bens no espaço urbano, permitindo o acesso a oportunidades, serviços e atividades distribuídas nas cidades. Esse conceito envolve não apenas os meios de transporte disponíveis, mas também as condições de acessibilidade, conectividade e integração entre diferentes componentes da infraestrutura urbana (Zhang *et al.*, 2024).

Embora os deslocamentos individuais em veículos privados ainda predominem em muitas cidades, observa-se um crescimento dos modos de transporte alternativos (Kagho *et al.*, 2021; Oh *et al.*, 2020; Pessoa *et al.*, 2025; Santos; Lima, 2021). Entre eles, o transporte público coletivo desempenha papel estratégico na mobilidade urbana por possibilitar deslocamentos em larga escala, ampliar o acesso da população às oportunidades urbanas e contribuir para a redução dos impactos ambientais e da dependência do transporte individual. Em cidades de pequeno e médio porte, os sistemas de ônibus frequentemente constituem o principal modo motorizado de transporte coletivo, assumindo importância fundamental para a inclusão social e para a eficiência da dinâmica urbana (Carmen; Idalia, 2023; Huang *et al.*, 2022; Santos; Lima, 2023).

A qualidade dos sistemas de transporte coletivo está diretamente relacionada à capacidade de conectar usuários aos seus destinos de forma eficiente (Vidovic; Sostaric; Budimir, 2019). Nesse contexto, Omar e Ogut (2024), Bracarense e Ferreira (2018) e Ingram (1971) destacam que a acessibilidade é um dos principais indicadores de desempenho do transporte urbano, pois expressa a facilidade com que indivíduos alcançam empregos, instituições de ensino, serviços públicos, estabelecimentos comerciais e demais pontos de interesse distribuídos na cidade. Entre os diversos fatores que influenciam a acessibilidade, a localização dos pontos de parada exerce papel relevante, afetando simultaneamente as distâncias de caminhada dos usuários, a cobertura espacial do sistema e o desempenho operacional das linhas.

A literatura da área apresenta diferentes formas para a mensuração da acessibilidade, cuja seleção depende do objetivo da análise, da unidade espacial, das informações disponíveis e das características da intervenção avaliada. Entre as vertentes, destacam-se: as métricas de proximidade, baseadas no custo até a oportunidade mais próxima; as cumulativas (ou de contorno), que contabilizam as oportunidades alcançáveis dentro de determinado limite

temporal; as gravitacionais, que ponderam o volume de oportunidades por meio de uma função contínua de impedância; os modelos de oferta e demanda, como o método Two-Step Floating Catchment Area (2SFCA); e as abordagens comportamentais, espaço-temporais e multicritério (Geurs; Van Wee, 2004; Albacete *et al.*, 2017; Mazzulla; Pirrone, 2024).

As medidas cumulativas apresentam elevada facilidade de interpretação, mas dependem da definição de um limite temporal e atribuem o mesmo peso às oportunidades situadas em diferentes posições dentro desse limite. As abordagens espaço-temporais, baseadas em utilidade e multicritério incorporam mais dimensões individuais, comportamentais e operacionais, embora demandem dados detalhados sobre preferências, horários, capacidade dos serviços e condições físicas das paradas. Já as medidas gravitacionais representam a redução progressiva da atratividade de uma oportunidade à medida que aumenta o custo necessário para alcançá-la, evitando a descontinuidade produzida por limites rígidos (Geurs; Van Wee, 2004; Klar *et al.*, 2023; Kapatsila *et al.*, 2023).

Diante dessas alternativas, adotou-se nesta tese uma medida integral de acessibilidade potencial de base gravitacional, fundamentada em Ingram (1971). Sua escolha decorre da aderência ao problema de racionalização locacional investigado, uma vez que sintetiza a atratividade dos Pontos de Interesse (POIs) e a impedância inerente ao tempo de caminhada (deslocamento pedonal). Adicionalmente, a estrutura matemática de Ingram (1971) converge em um indicador escalar, contínuo, transparente e computacionalmente viável para ser recalculado durante as interações do algoritmo de RL. Essa característica permite mensurar os efeitos marginais de cada reposicionamento dos pontos de ônibus sem incorporar dimensões operacionais mantidas constantes no projeto experimental, como itinerários, linhas e frequências.

Dessa forma, a racionalização dos pontos de parada tem sido objeto de crescente interesse por parte de pesquisadores e gestores públicos, buscando equilibrar a acessibilidade dos usuários e a eficiência operacional do transporte coletivo. O desafio consiste em determinar configurações que reduzam tempos de deslocamento e custos operacionais sem comprometer a cobertura espacial necessária ao atendimento da população (Santos; Oliveira Simões, 2026; Buyukozkan; Ilicak, 2022; Kagho *et al.*, 2021; Maheshwari; Axhausen, 2021).

O avanço das tecnologias digitais, da inteligência artificial e das ferramentas de modelagem computacional tem ampliado significativamente a capacidade de análise dos sistemas urbanos de transporte. Essas tecnologias permitem integrar dados espaciais, comportamentais e operacionais, possibilitando a construção de modelos capazes de representar a complexidade inerente aos sistemas de mobilidade urbana e apoiar processos de planejamento

e tomada de decisão (Maheshwari; Axhausen, 2021; Buyukozkan; Ilicak, 2022; Mahmoudi; Saidi; Wirasinghe, 2024; Mahmoudi; Saidi; Emrouznejad, 2025).

Diversas abordagens vêm sendo empregadas para apoiar a racionalização de redes de transporte coletivo e a localização de pontos de parada. Entre elas destacam-se métodos de otimização matemática, teoria dos grafos, problemas de cobertura, sistemas de informação geográfica, heurísticas, meta-heurísticas e técnicas de modelagem e simulação. O Quadro 5 apresenta uma síntese das principais abordagens identificadas na literatura.

Observa-se que as abordagens existentes apresentam diferentes capacidades de representação dos fenômenos associados ao transporte público. Enquanto alguns métodos concentram-se na otimização espacial da rede, outros permitem incorporar aspectos comportamentais, operacionais ou geográficos do sistema. A escolha da abordagem mais adequada depende dos objetivos da análise e do nível de detalhamento requerido.

No contexto desta pesquisa, optou-se pela utilização da Modelagem e Simulação Híbrida (MSH), em razão da necessidade de representar simultaneamente comportamentos individuais dos usuários, processos operacionais do transporte coletivo e mecanismos de otimização orientados por dados. Essa característica torna a MSH particularmente adequada para a análise integrada dos desafios associados à racionalização de pontos de parada em sistemas urbanos de transporte (Brailsford, 2023; Diallo *et al.*, 2021; Huang *et al.*, 2022; Manley *et al.*, 2014; Mustafee; Harper; Fakhimi, 2022; Tolk; Harper; Mustafee, 2021).

Quadro 5 - Técnicas para racionalização e roteirização de pontos de ônibus

Autores	Nomenclatura	Descrição
Current, Daskin e Schilling (2002) e Farahani *et al.* (2019)	Location-Allocation Models (Modelos de Localização-Alocação)	Otimizar a localização dos pontos de ônibus considerando demanda espacial, cobertura e acessibilidade.
Delling *et al.* (2009) e Ceder (2007)	Teoria dos Grafos e Análise de Redes	Definição de rotas eficientes, minimização de custos operacionais e na maximização da conectividade da rede.
Schilling, Jayaraman e Barkhi (1993)	Problema de Cobertura de Conjuntos (Set Covering Problem)	Garantir que todos os usuários estejam dentro de uma distância máxima de um ponto de ônibus, reduzindo sobreposição e otimizando a quantidade de pontos.
Laporte (2009) e Ceder (2007)	Problema de Roteamento de Veículos (Vehicle Routing Problem)	Ajustar sequenciamento e roteirização de linhas, considerando capacidade, janelas de tempo e frequência.
Macal e North (2009) e Brailsford *et al.* (2019)	Modelagem e Simulação Híbrida	Avaliar, de forma dinâmica, o impacto de diferentes configurações de pontos e linhas sobre o comportamento dos usuários e do sistema em uma simulação.
Mandl (1980) e Cipriani, Gori e Petrelli (2012)	Otimização Multiobjetivo	Aplicar algoritmos evolutivos ou heurísticas para balancear critérios conflitantes como tempo de viagem, custo, cobertura e acessibilidade.

Fonte: Elaborado pelo autor (2026).

2.2 Modelagem e Simulação

Um modelo é uma representação simplificada da realidade, construída com fins analíticos e voltada a objetivos específicos (Abar *et al.*, 2017; Bertrand; Fransoo, 2002). Robinson (2013) reforça que o modelo deve ser direcionado a um objetivo específico, não devendo ser generalizado para outras aplicações.

A simulação é a execução de modelos computacionais que permitem experimentar e analisar o funcionamento de sistemas reais ou hipotéticos (Abar *et al.*, 2017). O Quadro 6 apresenta de forma resumida algumas definições de Modelagem e Simulação.

Quadro 6 - Definições de Simulação

Autores	Definição
Banks e Carson (1984)	Processo de projetar um modelo de um sistema real e conduzir experimentos com esse modelo com o propósito de compreender o comportamento do sistema e/ou avaliar estratégias para sua operação.
Montevechi *et al.* (2010)	Técnica para imitar o comportamento de um sistema real, utilizando um modelo representativo que permite a realização de experimentos para entender seu funcionamento e melhorar a tomada de decisão.
Sargent (2020)	Execução de um modelo computacional que representa o tempo e o comportamento de um sistema real ou hipotético com o objetivo de compreender esse sistema e/ou avaliar estratégias para sua operação.
Sturrock (2014)	Consiste em um sequência de atividades para a descoberta, partindo do conhecimento obtido em descrever com precisão o sistema real e encaminhando-se para os resultados gerados pela simulação.
Palanca *et al.* (2021)	Permite a emulação computacional do funcionamento de sistemas reais com o propósito de avaliar o desempenho dos sistemas e propor melhorias.
Barbieri (2023)	É um meio que possibilita analisar os fenômenos de um sistema real ao manipular as principais variáveis desse sistema em um ambiente virtual.

Fonte: Elaborado pelo autor (2026).

Um modelo de simulação, também chamado de projeto de simulação, compreende algoritmos computacionais, expressões matemáticas e equações que representam o comportamento e o desempenho de um sistema. Essa estrutura permite a modelagem de entidades, eventos e recursos, além de fornecer resultados por meio de visualizações e análises numéricas (Abar *et al.*, 2017; Barbieri, 2016; Singh, 2021).

A construção de projetos de simulação requer uma sequência estruturada de etapas, que definem objetivos, elementos relevantes, agentes, interações e indicadores de desempenho. Bertrand e Fransoo (2002) destacam a importância dessa estruturação, reforçada por autores como Mitroff *et al.* (1974), Banks e Carson (1984), Chwif e Medina (2014), Grimm *et al.* (2006), Montevechi *et al.* (2010) e Sargent (2013). O Quadro 7 sintetiza as principais etapas descritas por esses autores.

Quadro 7 - Etapas propostas para projetos de simulação segundo a literatura

Etapa proposta x autores	Mitroff *et al.* (1974)	Banks e Carson (1984)	Balci (1990)	Robinson (2004)	Sargent (2013)	Chwif e Medina (2014)	Montevechi *et al.* (2010)	Grimm *et al.* (2006)
Objetivos e definição do sistema	x	x	x	x	x	x	x	x
Viabilidade de modelagem e simulação			x					
Planejamento do modelo		x						x
Modelagem conceitual	x		x	x	x	x	x	x
Coleta de dados	x	x	x		x	x	x	x
Validação do modelo conceitual		x	x	x	x		x	
Documentação do modelo conceitual		x	x	x		x	x	
Conceitos de design								x
Modelagem computacional	x		x	x	x	x	x	x
Verificação e validação do modelo computacional	x	x	x	x	x	x	x	
Documentação do modelo computacional			x	x	x	x	x	
Definição do projeto experimental		x	x	x			x	
Execução dos experimentos		x	x		x	x	x	
Análise e validação estatística			x	x	x	x	x	
Resolução do modelo	x	x	x			x		
Proposta e implantação de melhorias	x	x	x	x		x	x	
Validação e aceitabilidade da melhoria			x	x				

Fonte: Elaborado pelo autor (2026).

Em geral, conforme literatura da área ditada no Quadro 7, o desenvolvimento de um projeto de simulação pode ser dividido em três fases: concepção; implementação; e análise. Na fase de concepção, definem-se os objetivos, estrutura-se o modelo conceitual e coletam-se os dados do sistema real, devendo ser validada toda esta construção. A fase de implementação compreende a construção do modelo computacional e sua validação e verificação frente ao modelo conceitual e aos dados históricos reais do ambiente estudado. Por fim, na fase de análise, realizam-se experimentos com base em delineamentos estatísticos que possibilitam a proposição de melhorias validadas no ambiente simulado (Barbieri, 2016; Bateman *et al.*, 2013; Montevechi *et al.*, 2010).

Quase todos os autores citados no Quadro 7 destacam a importância do modelo conceitual, que representa abstratamente os componentes do sistema real. Essa representação pode assumir formas diversas, como fluxogramas, mapas mentais, redes de Petri, diagramas UML ou BPMN (Onggo; Foramitti, 2021; Robinson, 2013). Nesta tese, optou-se por duas abordagens principais: o diagrama IDEF-Sim, desenvolvido por Leal *et al.* (2008); e o diagrama de estados, amplamente utilizado em modelagens baseadas em agentes (Bauer *et al.*, 2001; Harel, 1987; Runbaugh *et al.*, 1999).

A literatura apresenta diversas abordagens para a construção de modelos computacionais, como a Simulação de Monte Carlo, a Simulação Contínua e os Sistemas Dinâmicos. Entretanto, destacam-se a SED e a SBA, empregadas isoladamente ou de forma híbrida, como se propõe nesta tese. A SED adota uma perspectiva *top-down* centrada em processos, enquanto a SBA utiliza uma abordagem *bottom-up*, focada nas interações entre agentes e ambiente (Barbieri, 2016; Mehdizadeh; Nordfjaern; Klockner, 2022; Singh, 2021). Ambas estão melhor explanadas nas seções 2.2.1 e 2.2.2 desta tese.

2.2.1 Modelagem e Simulação a Eventos Discretos

A Simulação a Eventos Discretos (SED) é uma abordagem consolidada na modelagem computacional, com ampla aplicação em manufatura, logística e serviços. Conforme Borshchev e Filippov (2004), a SED descreve sistemas por meio de entidades, recursos e filas, sendo governada por eventos que provocam alterações de estado em momentos discretos no tempo. Os principais componentes incluem eventos, variáveis, calendário, geradores de números aleatórios e coletores estatísticos (Barbieri, 2023; Law, 1988; Schriber; Brunner; Smith, 2013).

Os modelos SED operam por meio de eventos que, ao ocorrerem, alteram o estado do sistema. Para lidar com incertezas, utilizam variáveis estocásticas amostradas de distribuições de probabilidade. Essa abordagem é especialmente eficaz na análise de sistemas com filas, recursos compartilhados e fluxos interdependentes (Chwif; Medina, 2014; Law, 1988; Macal; North, 2005).

Bertrand e Fransoo (2002) propõem uma tipologia dos modelos de simulação com base na natureza dos dados e nos objetivos da análise: (i) empírico-descritivo, voltado à compreensão de sistemas reais; (ii) empírico-normativo, com foco em melhorias práticas, também com dados reais; (iii) axiomático-descritivo, baseado em premissas teóricas para entendimento de fenômenos, por meio de modelos conceituais; e (iv) axiomático-normativo, voltado à proposição de soluções ideais matemáticas ou por meio de modelos conceituais. Nesta tese, o foco é no desenvolvimento do *framework* axiomático-descritivo.

Dentre os softwares amplamente utilizados em SED, destacam-se Arena, ProModel, GPSS/H, AutoMod, ExtendSim e Simio. Essas ferramentas oferecem suporte à modelagem de fluxos produtivos, gerenciamento de filas e análise estatística, sendo amplamente adotadas tanto em contextos industriais quanto acadêmicos (Chwif; Medina, 2014; Schriber; Brunner; Smith, 2013).

2.2.2 Modelagem e Simulação Baseada em Agentes

A Simulação Baseada em Agentes (SBA) consiste em uma abordagem de modelagem computacional voltada à representação de sistemas compostos por entidades autônomas capazes de interagir entre si e com o ambiente. Diferentemente das abordagens agregadas, a SBA permite representar comportamentos individuais e analisar como interações locais podem produzir padrões observados em nível sistêmico em uma abordagem *bottom up* (Abar *et al.*, 2017, Macal, 2006; Macal; North, 2009; Onggo; Foramitti, 2021).

Segundo Abar *et al.* (2017) e Onggo e Foramitti (2021), a flexibilidade da SBA tem favorecido sua aplicação em diferentes áreas do conhecimento, incluindo logística, saúde, manufatura, mercados econômicos e mobilidade urbana. Sua principal contribuição reside na capacidade de representar heterogeneidade comportamental e processos de decisão individuais, características frequentemente presentes em sistemas urbanos de transporte.

Para orientar a estruturação dos modelos SBA, Macal (2016) propôs uma tipologia com quatro categorias de agentes: individual; autônomo; interativo; e adaptativo. A classificação considera o grau de independência decisória, interação e capacidade de aprendizagem dos agentes. O Quadro 8 resume essas categorias e seus principais atributos.

Quadro 8 - Classificação da MSBA de acordo com as propriedades dos agentes

Class.	Individ.	Comport.	Interações	Adaptabilidade	Exemplo
SBA Individual	Agentes heterogêneos individuais.	Prescrito ou com script.	Limitado.	Nenhum.	Modelo de tráfego que tem agentes movendo-se entre pares de origem e destino de acordo com script.
SBA Autônoma	Agentes heterogêneos individuais.	Autônomo e dinâmico.	Limitado.	Nenhum.	Modelo de tributação em que os agentes escolhem ocupações e locais de trabalho, mas não interagem com outros.
SBA interativa	Agentes heterogêneos individuais.	Autônomo e dinâmico.	Entre os outros agentes e o ambiente.	Nenhum.	Modelo de doença infecciosa em que os agentes transmitem e são infectados por meio do contato e respondem ao seu estado de doença de acordo com comportamentos prescritos.
SBA Adaptativa	Agentes heterogêneos individuais.	Autônomo e dinâmico.	Entre os outros agentes e o ambiente.	O agente escolhe o comportamento durante a simulação.	Modelo de assistência à saúde em que os agentes mudam seus comportamentos de acordo com o estado de sua saúde.

Fonte: Adaptado de Macal (2006).

O desenvolvimento de modelos SBA normalmente segue um processo estruturado envolvendo a definição dos agentes, atributos, comportamentos, ambiente de simulação e mecanismos de interação. Embora estruturadas de forma sequencial, essas fases não são rígidas, permitindo ciclos iterativos de refinamento conforme o modelo evolui (Macal; North, 2009; Huang *et al.*, 2022). A Figura 5 ilustra estas etapas e funcionalidades, conforme proposto por Macal e North (2009) e Huang *et al.* (2022).

Figura 5 - Funções, interações e estrutura do agente em um ambiente

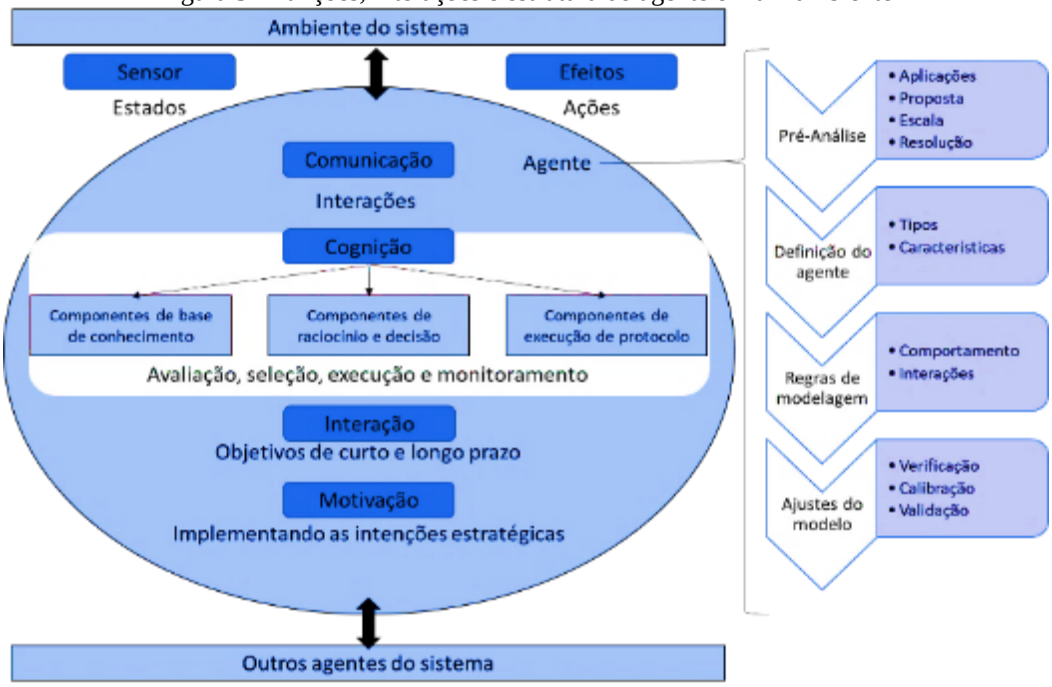

Fonte: Adaptado de Macal e North (2009) e Huang *et al.* (2022).

Grimm *et al.* (2006) e Onggo e Foramitti (2021) enfatizam que entre os padrões mais difundidos para documentação desses modelos destaca-se o protocolo ODD (Overview, Design Concepts, and Details), que fornece uma estrutura padronizada para descrição, comunicação e replicação de modelos baseados em agentes. Complementarmente, procedimentos de verificação e validação são empregados para assegurar consistência lógica, aderência ao sistema representado e confiabilidade dos resultados produzidos pelo modelo.

Dentro da primeira fase, o modelo conceitual é desenvolvido focando-se em um objetivo para a simulação de tal objeto de estudo. Deve-se aqui deixar claro as entradas, saídas, conteúdos, suposições e simplificações a serem executadas. Já a representação gráfica pode ser executada com o auxílio de diagramas do tipo fluxograma, diagrama de estados, redes de petri, UML ou mesmo BPMN, entre outras (Onggo; Foramitti, 2021; Robinson, 2013). Nesta

pesquisa foi utilizado o diagrama de estados, conforme simbologia e procedimentos determinados por Campos (2021), Harel (1987), Scheltes e Correia (2017) e Alves *et al.* (2019).

Diversas plataformas computacionais suportam a implementação de modelos SBA, destacando-se NetLogo®, Repast® e AnyLogic® (Macal; North, 2009). Entre elas, o AnyLogic® apresenta particular relevância para esta pesquisa por permitir a integração nativa entre SBA, SED e ambiente georreferenciado em um mesmo ambiente de modelagem. Abar *et al.* (2017) complementa que tal software é um dos que possuem alta escalabilidade (ideal para o estudo com populações) e moderado esforço de programação.

2.2.3 Modelagem e Simulação Híbrida

A MSH consiste na integração de dois ou mais paradigmas de modelagem e simulação em um mesmo ambiente computacional, permitindo explorar diferentes perspectivas de análise de um sistema. Essa integração busca combinar as capacidades específicas de cada abordagem, ampliando o potencial de representação de fenômenos que não podem ser adequadamente descritos por um único paradigma de modelagem (Brailsford *et al.*, 2019; Mustafee *et al.*, 2022).

Diversos autores propuseram classificações para organizar as diferentes formas de integração existentes na literatura. Entre elas, destaca-se a taxonomia proposta por Mustafee, Harper e Fakhimi (2022), amplamente utilizada para categorizar modelos híbridos de acordo com a forma de integração entre os paradigmas empregados. Essa classificação contribui para a padronização da terminologia utilizada na área e facilita a comparação entre diferentes estudos. O Quadro 1 apresentou os desdobramentos propostos.

Além da classificação dos modelos, a literatura também descreve diferentes mecanismos de integração entre paradigmas de simulação. Essa integração pode ocorrer por meio do compartilhamento de dados, sincronização temporal, acoplamento de processos ou troca de informações entre modelos executados de forma conjunta. A escolha do mecanismo de integração depende dos objetivos da pesquisa, do nível de interação requerido e das características do sistema analisado (Brailsford *et al.*, 2019; Miedviedieva; Baharii, 2023; Yang *et al.*, 2021).

A MSH tem se destacado como uma ferramenta robusta para análise de sistemas urbanos, sendo útil no planejamento, na formulação de políticas e na tomada de decisões (Bounadi; Boussalia; Bellaouar, 2023). Considerando a crescente complexidade dos sistemas

de mobilidade urbana e a necessidade de integrar múltiplas perspectivas analíticas, a MSH apresenta-se como abordagem metodológica adequada para esta pesquisa.

A partir das definições e classificações apresentadas, este trabalho adota um modelo híbrido do tipo E, conforme tipologia de Mustafee, Harper e Fakhimi (2022), combinando no software AnyLogic® elementos da SED, SBA e técnicas de aprendizado de máquina para apoiar decisões no planejamento do transporte público.

2.3 Modelagem e Simulação híbrida em transporte público

2.3.1 Aplicação da MSH em transporte público

A crescente complexidade dos sistemas de transporte público tem impulsionado o desenvolvimento de abordagens capazes de integrar diferentes perspectivas de análise em um mesmo ambiente computacional. Nesse contexto, a MSH tem sido empregada para apoiar estudos relacionados ao planejamento, operação, acessibilidade e avaliação de políticas públicas de transporte. Essa integração favorece a compreensão das interações entre componentes humanos, tecnológicos e operacionais, contribuindo para decisões fundamentadas em dados e embasando políticas públicas mais eficazes (Bounadi; Boussalia; Bellaouar, 2023).

A literatura recente demonstra que a aplicação da MSH ao transporte público ocorre principalmente em problemas que envolvem múltiplas escalas de análise e diferentes tipos de processos, como análise de tráfego, demanda e sustentabilidade, comportamentos individuais e dinâmicas de veículos, e integração de diferentes paradigmas para avaliar redes responsivas à demanda. Essas aplicações incluem estudos sobre planejamento de redes, localização de infraestrutura, comportamento dos usuários, integração modal, acessibilidade urbana, operação de linhas e avaliação de cenários de intervenção no sistema de transporte (Carmen; Idalia, 2023; Manley *et al.*, 2014).

Diversos trabalhos têm utilizado modelos híbridos para representar simultaneamente características operacionais e comportamentais dos sistemas de transporte. Em geral, essas pesquisas buscam compreender como alterações na infraestrutura, na oferta de serviços ou nos padrões de deslocamento influenciam o desempenho do sistema e a experiência dos usuários. O Quadro 9 exemplifica estudos recentes neste contexto.

Quadro 9 - Exemplos de aplicações de MSH em Mobilidade e TP

Autores	Descrição do estudo
Manser *et al.* (2020)	Roteamento de ônibus em Zurique, na Suíça, permitindo alteração de capacidade dos equipamentos e variando na simulação os subsídios de tarifas de transporte, com o software MATSim®.
Man *et al.* (2020).	Introduziram um modelo híbrido SED e SD para capturar a relação entre transporte, turismo e uso do solo, fornecendo uma base para a formulação de políticas públicas no planejamento de infraestrutura de transporte, aumentando a acessibilidade aos pontos turísticos.
Liu *et al.* (2021)	Fluxo de pessoas dentro dos pontos de ônibus, com base na teoria das filas e tempos de espera, com o software AnyLogic®, demonstrando também o microcomportamento dos veículos ao chegarem e saírem de suas estações.
Oo *et al.* (2021).	Desenvolveram um modelo híbrido SED e SBA que permite avaliar a eficiência de sistemas de transporte público, otimizando o tempo de espera e a utilização dos veículos em um cenário urbano dinâmico.
Zhukov e Moroz (2021)	Modelo de simulação de uma rota de ônibus com quatro agentes principais (ambiente em que vivem os agentes; pontos de parada de ônibus; ônibus; e passageiros), descrevendo os processos e fluxos dentro do software AnyLogic®.
Ercan *et al.* (2022)	Demonstração de simulação no software Vensim® para compartilhamento de veículos, com foco na adoção de veículos elétricos autônomos em uma rede viária urbana com a métrica de redução de emissões de poluentes e políticas de transporte.
Serena *et al.* (2022).	Expandiram uma abordagem multiescala em um modelo SED e SD para incluir mais variáveis de comportamento individual, como idade, estado de saúde e preferências de transporte, além de aumentar a precisão dos modelos de mobilidade e poluição avaliando impactos de epidemias.
Yao e Schmocker (2023).	Quantificaram a distância de acesso a serviços de compartilhamento de bicicletas considerando a disponibilidade incerta e o uso de smartphones para reserva, e avaliaram o impacto de diferentes estratégias de reserva e busca de informações em uma simulação SBA e SED.
Challapalli (2024)	Rota de ônibus para otimização de suas linhas e horários para reduzir o tempo de espera dos passageiros, em uma cidade da China, com o software AnyLogic®.
Cramer e Fikar (2024)	Simulação híbrida com o software AnyLogic® demonstrando a viabilidade logística de distribuições de alimentos em cadeias de suprimentos de alimentos, reduzindo distâncias percorridas.
Silva, Lima e Alves (2024).	Analisaram o impacto da pandemia de COVID-19 nas entregas de última milha, utilizando simulação híbrida SED e SBA para modelar diferentes cenários e propor melhorias na operação logística dentro de uma cidade.

Fonte: Elaborado pelo autor (2026).

Apesar dos avanços, a aplicação da MSH na mobilidade urbana enfrenta desafios relevantes, como: (i) a modelagem de interações complexas entre agentes heterogêneos; (ii) a integração de dados realistas em ambientes não lineares; (iii) a padronização de *frameworks* que possibilitem a replicação dos modelos; (iv) a escassa documentação sobre a estruturação dos modelos a qual limita sua replicabilidade e validação científica (Brailsford *et al*, 2019; Chrisnawati; Susilo, 2024; Cisterna *et al.*, 2024; Huang *et al.*, 2022; Macal, 2016; Macal; North, 2009).

De forma semelhante, observa-se reduzido número de estudos direcionados especificamente à racionalização de pontos de parada do transporte coletivo. Grande parte das pesquisas concentra-se em planejamento de redes, operação de linhas e análise de demanda, existindo oportunidades para o desenvolvimento de modelos capazes de integrar acessibilidade

urbana, comportamento dos usuários e processos de otimização aplicados à infraestrutura de transporte (Santos; Oliveira; Simões, 2026; Ferreira Junior; Lima; Pinho, 2026).

Destaca-se ainda a escolha da acessibilidade como principal indicador de desempenho desta tese fundamenta-se no objetivo central da pesquisa, que consiste na racionalização de pontos de parada do transporte público urbano. Diferentemente de problemas voltados exclusivamente à redução de custos operacionais ou à minimização de tempos de viagem, a racionalização de pontos envolve decisões que afetam diretamente a capacidade dos usuários de acessar oportunidades distribuídas no espaço urbano (Omar; Ogut, 2024; Vidovic; Sostaric; Budimir, 2019).

Diante desse cenário, verifica-se a existência de oportunidades para o desenvolvimento de abordagens híbridas que combinem diferentes paradigmas de simulação, dados espaciais e técnicas de inteligência computacional. Essas oportunidades fundamentam a proposta desta tese, que busca contribuir para o avanço da aplicação da MSH no contexto da racionalização de pontos de parada do transporte público urbano.

2.3.2 Abordagens para construção de MSH em transporte público

O transporte público (TP) é essencial para ampliar o acesso da população a pontos de interesse além das distâncias viáveis para deslocamentos a pé ou de bicicleta. Torná-lo economicamente viável e adequado às necessidades dos usuários é um dos maiores desafios enfrentados pelos gestores urbanos. O ponto crítico reside na definição de rotas eficientes que conciliem desempenho operacional e escalabilidade demográfica (Rasca *et al.*, 2024).

Com base nos desafios do TP e no potencial da MSH, diversos estudos propuseram estruturas de modelagem específicas para esse contexto. O Quadro 10 resume os principais trabalhos utilizados nesta tese como base conceitual.

Quadro 10 - Descrição das estruturas de modelagem para TP

Autores	Foco	Descrição	Elementos-chave
Cats, West e Eliasson (2016)	Embarque e desembarque	Buscaram representar este elemento da simulação do comportamento humano em transportes, variando de acordo com a heterogeneidade dos passageiros, como quesitos socioeconômicos diversos.	Definição do fluxo de entrada e saída de passageiros em formato de distribuições de probabilidade, configurando o desejo do agente de se locomover por determinado modo de transporte, podendo incluir tempo de espera, tempo de percurso e distância do local ao qual o indivíduo está e para onde ele irá executar sua atividade, incluindo também a capacidade do veículo.
Simoni *et al.* (2019)	População Sintética	Determinação de população sintética com diferentes características sociodemográficas, desenvolvendo	Definição do plano de deslocamento por agente, com horário de início e fim de

		comportamentos e planejamentos independentes em um plano de viagem e aprendendo por meio de um algoritmo qual a melhor forma de se deslocar.	cada atividade, conforme características sociodemográficas.
Franco, Johnston e McCormick (2020)	Comportamento humano e mobilidade	Associaram um sistema de entrada-processo-saída na construção desta visão geral da simulação de mobilidade urbana.	Representação de uma visão sistêmica do processo de simulação aplicado à mobilidade urbana, denominado Modle, estruturando-o em três etapas: entrada; processo; e saída.
Moeckel *et al.* (2020) e Belaroussi e Delhoum (2024)	Plano de viagens	Dividiram o plano de viagens em dois tipos, viagens obrigatórias, como trabalho e educação, e viagens discricionárias, como para compras e outras atividades, sendo que ambos são alocados em um limite de um dia normal de 24 horas.	Os planos de viagem devem ter início planejado, duração estipulada e um local para se executar cada atividade, além da escolha do transporte para se ir e vir de cada localização.
Moeckel *et al.* (2020) e Oh *et al.* (2020)	Plano de viagens	Fluxograma para micro-simulações de viagens com população sintética, gerando viagens a partir de um domicílio e calculando o tempo disponível dentro de um dia normal de 24h para realizar todas as atividades.	Modelo para organizar o plano de viagens em conjunto com as características da Persona.
Zhang *et al.* (2020)	Comportamento humano e mobilidade	Modelo SBA em conjunto com um algoritmo de localização e dimensionamento, denominado BEAM, utilizando o software MATSim.	Sobreposição de seis conjuntos de dados (laudas) para obter modelo de movimentação de veículos e mobilidade urbana.
Diallo *et al.* (2021)	Modo de transporte	Definiram conjuntos de locomoção em meio urbano para a população.	Determinação de modos de transporte urbano em: carros particulares; carros de transporte, como táxis; carros particulares até pontos de transporte público como metrôs ou ônibus; transporte público em conjunto com caminhadas; bicicletas; caminhadas.
Rasca *et al.* (2024)	População Sintética	Modelagem de grupos de indivíduos com características intrínsecas e tipos de comportamentos potenciais, chamando-os de Personas.	Desenvolvimento de 20 grupos de personas com requisições distintas de viagens e utilização de transportes público.
Kashiyama *et al.* (2024)	Comportamento humano e mobilidade	Modelo do comportamento humano diário no Japão por meio de um pseudo-fluxo gerado a partir de dados abertos e pesquisas de viagens.	Atividades humanas classificadas segundo restrições espaciais, temporais, propósito do deslocamento, localização e duração; Integra informações sobre domicílio, atividades, seleção de locais, modos de transporte e rotas, permitindo simular padrões de mobilidade sem utilizar dados empíricos.
Peng, Tong e Wang (2024)	Embarque e desembarque	Modelagem com dados de entrada de surveys e desenvolvimento por equacionamentos em linhas de trem expressas e locais nos arredores de Shangai.	Consideraram além do desejo de locomoção, a sensibilidade dos usuários em tópicos como tempo, conforto ou transferência de um modo de transporte para outro.
Zhang *et al.* (2024)	Plano de viagens	Definiram que os padrões e comportamentos do como e onde os indivíduos se movem ou viajam dentro de um determinado espaço físico vão ao encontro de suas preferências individuais, relacionadas a fatores espaciais e temporais.	Proveram a formatação base para a dinâmica dos usuários de forma espaço-temporal e seus fatores de priorização para tomada de decisão para a execução de planos de viagem.

Fonte: Elaborado pelo autor (2026).

A literatura destaca a construção de populações sintéticas como elemento central para modelos de simulação em mobilidade. No entanto, nem sempre há bancos de dados organizados

e adequados para esse propósito. Por isso, é comum a utilização de dados sintéticos, que buscam reproduzir o comportamento da população real, preservando suas propriedades estatísticas essenciais. Essa abordagem tem se mostrado promissora em áreas como mobilidade, planejamento urbano, desastres naturais e comportamento humano (Belaroussi; Delhoum, 2024; Kadosh; Sinuany-Stern; Bitan (2023); Kashiyama *et al.*, 2024). Listam-se exemplos na literatura para tal constituição da população sintética:

- Prédhumeau e Manley (2023): desenvolveram a partir de dados censitários e de domicílios do Canadá, uma população sintética para aplicações diversas;
- Kashiyama *et al.* (2024): desenvolveram um banco de dados intitulado Pseudo-PFlow para o Japão;
- Diallo *et al.* (2021): utilizaram de informações de viagens e questões sociodemográficas para inserir uma população sintética no simulador, com as possibilidades por agente de deslocamentos, para a cidade de Lille, na França;
- Belaroussi e Delhoum (2024): verificaram, em um bairro em Paris, os padrões de atividades da população interna e externa a este distrito por meio da atratividade dos locais;
- Oh *et al.* (2020): também desenvolveram uma população sintética com cronograma de agentes, classificação dos tipos dos mesmos, número e duração de atividades, locais e modos de se chegar até eles, em Singapura.

Outro aspecto amplamente discutido na literatura refere-se ao plano de viagem e à definição de seus destinos. Os pontos de destino são fundamentais para modelar a lógica de deslocamento dos agentes, pois representam as motivações espaciais e temporais que determinam o comportamento de mobilidade da população. O Quadro 11 sintetiza os principais destinos simulados nos estudos analisados.

Quadro 11 - Destinos para a população sintética

Autor	Casa	Trabalho	Educação	Compras	Alimentação	Saúde	Lazer	Outros
Simoni *et al.* (2019)	x	x	x	x			x	
Diallo *et al.* (2021)	x	x		x				
Hamadneh e Esztergar-Kiss (2022)	x	x		x			x	
Belaroussi e Delhoum (2024)	x	x	x	x	x		x	
Kashiyama *et al.* (2024)	x	x	x	x	x	x		x

Fonte: Elaborado pelo autor (2026).

Essas possibilidades de deslocamento são tratadas na literatura como Pontos de Interesse (POIs), que representam locais físicos vinculados às atividades humanas, como trabalho, lazer e compras. Os POIs são essenciais na simulação por refletirem o contexto espacial em que os agentes operam, embora seu uso dependa da correta atualização e correspondência com as atividades reais da população (Psyllidis *et al.*, 2022).

Atualmente, os POIs estão vinculados a bases digitais que detalham características como horário de funcionamento, valores de ingresso e horários de pico. Em ambientes GIS, esses dados aparecem como praças, centros comunitários, restaurantes, escolas, instituições públicas e locais turísticos. Com sistemas de rastreamento por GPS e ferramentas de georreferenciamento, é possível analisar padrões de mobilidade em larga escala, considerando restrições de tempo e espaço. Bancos de dados como OpenStreetMap (OSM) e Google Places são amplamente usados para esse fim (Psyllidis *et al.*, 2022; Zhang *et al.*, 2024).

O georreferenciamento, conforme Zhang *et al.* (2020), consiste na atribuição de coordenadas espaciais a cada POI, geralmente em latitude e longitude. Esses dados podem ser representados em pontos, linhas e polígonos, descrevendo o ambiente urbano com precisão. Ferramentas como Google Maps e OSM oferecem APIs que permitem a extração e conversão automatizada desses dados para simulações (Araújo; Dávalos, 2022; Mendes; Ferreira, 2019).

A integração dos elementos descritos (população sintética, POIs e planos de viagem) fornece a base para os dados de entrada do modelo híbrido. Diversos fatores influenciam a mobilidade, como características socioeconômicas, infraestrutura, padrões de viagem e disponibilidade de veículos. Essas variáveis são essenciais para modelagem dos fluxos e comportamentos dos agentes e estão resumidas no Quadro 12 (Vidovic; Sostaric; Budimir, 2019; Brailsford, 2023).

Quadro 12 - Resumo de dados de entrada para construção da simulação em mobilidade

Tipo de dados de entrada	Definição	Características, fontes e ferramentas
Dados de demanda	Quantidade e distribuição das viagens realizadas pelos passageiros em um sistema de transporte urbano.	Matriz origem-destino, padrões de deslocamento e preferências de modos de transportes.
Dados de infraestrutura	Informações físicas e operacionais que compõe o ambiente de mobilidade.	Redes viárias, sistemas de transporte público, localização de paradas e pontos de interesse.
Dados socioeconômicos	Características demográficas, econômicas e comportamentais da população para composição da Persona.	Perfis demográficos dos usuários, distribuição populacional e aspectos econômicos.
Dados operacionais	Informações relacionadas à capacidade e tipos de veículos, horários, frequência de serviços e custos operacionais envolvidos.	Capacidade de veículos, horários, frequência de serviços e custos de operação.
Outros dados	Informações complementares que não se enquadram nos grupos anteriores.	Dados climáticos, uso do solo, acidentes de trânsito, dados de sensores viários.

Fonte: Elaborado pelo autor (2026).

Além das variáveis contextuais, a definição dos agentes é elemento central nos modelos de simulação. Embora o agente “usuário” (ou persona) seja o mais recorrente, a literatura também destaca a presença de outros elementos como veículos, estações de embarque/desembarque, infraestrutura urbana e ordens internas do sistema. Esses agentes são descritos por parâmetros e variáveis específicas, que orientam seu comportamento durante a simulação, conforme abaixo listado:

- Usuário, com diversas variações de nomes, como Personas, passageiros, pedestre, consumidor, indivíduo e outros, no qual é o cerne das pesquisas em mobilidade e foi utilizado em todos os artigos de prática vislumbrados. Características como preferência por um modo de transporte, custo de viagem, localização de origem e destino, sensibilidade ao tempo de viagem, entre outros (Nguyen; Schumann, 2020; Cisterna *et al.*, 2024; Pessoa *et al.*, 2025; Zhang *et al.*, 2024);
- Veículos, os quais transportam os usuários, que assumem variados nomes ou tipos e são normalmente encapsulados por parâmetros e variáveis como: tipo de veículo; número de paradas; capacidade do veículo; custo de operação; entre outros (Cisterna *et al.*, 2024; Hamadneh; Esztergar-Kiss, 2022; Rasca *et al.*, 2024; Truden; Ruthmair; Kollingbaum, 2023);
- Estações de embarque e desembarque, os quais os usuários devem se deslocar até eles para obter o acesso ao veículo de mobilidade. Têm-se por parâmetros e variáveis a localização geográfica, a densidade, taxas de integração, tempo de permanência parada, nível de acessibilidade, entre outros (Challapalli *et al.*, 2024; Harks *et al.*, 2024; Liu *et al.*, 2021; Zhang *et al.*, 2024);
- Infraestrutura como semáforos, ruas, pontos de travessia, abastecimento, entre outros, pouco explorado individualmente em vista que o SIG já incorpora seus fatores dentro das simulações;
- Ordens, ou seja, fator interno dentro dos modelos, ou para equacionar um fator de decisão ou para servir de disparo de mensagens para iniciar ou executar outras ações.

Para cada agente, é fundamental identificar seus comportamentos, sejam eles definidos por parâmetros fixos, variáveis dinâmicas ou mecanismos de decisão. Definindo: parâmetros são atributos imutáveis estabelecidos na configuração inicial do modelo; variáveis representam estados internos que evoluem ao longo da simulação; e os mecanismos de decisão expressam

as regras que governam a escolha de ações dos agentes (Abar *et al.*, 2017; Brailsford, 2023; Grimm *et al.*, 2006; Mustafee; Harper; Fakhimi, 2022).

Os modelos de simulação devem ser capazes de gerar resultados que permitam avaliar o desempenho do sistema modelado. Para isso, utilizam-se indicadores de desempenho que medem aspectos como eficiência, acessibilidade, sustentabilidade e impactos sociais e econômicos. Esses indicadores auxiliam no diagnóstico da qualidade da mobilidade urbana e subsidiam a formulação de políticas públicas baseadas em evidências (Santos; Lima, 2021; Vidovic; Sostaric; Budimir, 2019).

Vidovic, Sostaric e Budimir (2019) propuseram em seu estudo uma classificação em cinco categorias de indicadores, os quais são exemplificados e explanados no Quadro 13. Os mesmos podem vir a ser úteis para os modelos de simulação na busca por resultados de mobilidade. No caso desta tese, conforme supracitado na seção 2.1, o principal indicador será o de acessibilidade, o qual se classifica na primeira taxonomia de indicadores de transporte.

Quadro 13 - Classificação de indicadores para modelos de mobilidade

Classificação	Definição	Exemplos
Indicadores de Transporte	Medem o desempenho operacional dos modos de transporte, avaliando a eficiência e a confiabilidade do sistema, avaliando tempo de viagem, capacidade da rede e congestionamento.	Quantificação de usuários atendidos (Yao *et al.*, 2020); Comparações sobre tempos dos veículos ou dos usuários (Truden; Ruthmair; Kollingbaum, 2023); Distância percorrida pelo veículo ou pelo passageiro (Cisterna *et al.*, 2024; Liu *et al.*, 2021).
Indicadores Econômicos	Medem os custos e os benefícios financeiros do sistema de mobilidade, tanto para os usuários quanto para os operadores e a sociedade.	Receita diária, anual ou total (Chrisnawati; Susilo, 2024; Castillo *et al.*, 2022a); Custos Operacionais (Maggi; Vallino, 2021; Castrellon *et al.*, 2023); Política de preços (Cisterna *et al.*, 2024)
Indicadores Sociais	Buscam medir o impacto do transporte sobre a qualidade de vida da população e sua acessibilidade ao sistema de mobilidade.	Adoção de transporte ou veículos com combustíveis alternativos (Bilali *et al.*, 2020); Taxa de colisão ou de acidentes (Orfanou *et al.*, 2022).
Indicadores Ambientais	Avaliam os impactos energéticos e ambientais do sistema de transporte, incluindo emissões de CO_2, consumo de energia e poluição sonora.	Consumo de energia (Stevens *et al.*, 2022); Emissão de poluentes (Maggi; Vallino, 2021; Ercan *et al.*, 2022).
Outros indicadores	Inclui indicadores para regulamentação, planejamento urbano e governança para avaliar a integração da mobilidade com políticas públicas.	Diversos.

Fonte: Elaborado pelo autor (2026).

Considerando esse panorama, a presente pesquisa posiciona-se na vertente dos modelos híbridos, especialmente naqueles voltados à racionalização do transporte público coletivo urbano. A abordagem adotada contribui para o avanço metodológico na área ao propor um

framework replicável, fundamentado em estruturas bem documentadas e sustentado por bases teóricas consolidadas.

2.4 Aprendizagem de máquina

Dentro das abordagens de inteligência artificial, os métodos de aprendizado de máquina (Machine Learning – ML) são considerados técnicas mais promissoras para se trabalhar com dados não estruturados (Jimenez *et al.*, 2022). Essa abordagem tem sido amplamente utilizada em cenários onde a complexidade, a variabilidade e o volume de informações tornam inviável o uso exclusivo de métodos tradicionais determinísticos (Mohri; Rostamizadeh; Talwalkar, 2018; Vermeulen, 2019). Klasovitá e Corman (2026) reforçam que o aprendizado de máquina representa uma direção promissora, porém pouco explorada, para pesquisas futuras que lidam com incertezas. O Quadro 14 resume algumas definições de ML.

Quadro 14 - Definições de Aprendizado de Máquina

Autores	Definição
Mitchell (1997)	Diz-se que um programa de computador aprende com a experiência E no que diz respeito a alguma classe de tarefas T e medida de desempenho P, se seu desempenho nas tarefas em T, conforme medido por P, melhora com a experiência E.
Bishop (2006)	O aprendizado de máquina busca desenvolver algoritmos que possam generalizar a partir de exemplos e realizar previsões ou decisões com base em dados.
Mohri, Rostamizadeh e Talwalkar (2018)	Ramo da inteligência artificial que busca construir algoritmos capazes de aprender padrões e tomar decisões a partir de dados, sem serem explicitamente programados para cada situação.
Roth e Wermer-Colan (2023)	Ampla gama de métodos computacionais que envolvem a otimização e processos estatísticos e analíticos para aprimorar o conhecimento de padrões e a classificação de características comuns em diversos conjuntos de dados.
Sahu, Mokhade e Bokde (2023)	Processo iterativo no qual os algoritmos ajustam seus parâmetros com base em feedbacks extraídos do ambiente, melhorando progressivamente seu desempenho

Fonte: Elaborado pelo autor (2026).

No contexto da mobilidade urbana, o aprendizado de máquina tem se destacado por sua capacidade de racionalizar rotas, prever demanda, estimar tempos de deslocamento, apoiar decisões operacionais e racionalizar a alocação de recursos de transporte. Essas capacidades são particularmente relevantes em sistemas urbanos complexos, nos quais a variabilidade da demanda, o comportamento dos usuários e as condições da infraestrutura influenciam diretamente o desempenho do sistema (Santos; Oliveira; Simões, 2026; Huang *et al.*, 2022; Reggelin, Lang e Schauf, 2012; Mustafee *et al.*, 2020). Estudos mais recentes também evidenciam a crescente convergência entre aprendizado de máquina, cidades inteligentes, Digital Twins e modelagem baseada em dados, permitindo análises preditivas e adaptativas em tempo real para sistemas de mobilidade (Badakhshan; Mustafee; Bahadori, 2024;

Xanthopoulos; Kostavelis, 2024). No contexto de transporte por ônibus, as técnicas de aprendizado de máquina são úteis para avaliar suas operações e a confiabilidade do serviço, contudo, alguns desafios ainda precisam ser abordados, como generalização e escalabilidade (Santos; Oliveira; Simões, 2026).

Há três categorias principais para a ML: (i) aprendizado supervisionado, que utiliza dados rotulados para prever saídas a partir de entradas conhecidas; (ii) aprendizado não supervisionado, que identifica padrões em dados não rotulados; e (iii) aprendizado por reforço, no qual o agente aprende a tomar decisões otimizando recompensas acumuladas em um ambiente de interação (Jimenez *et al.*, 2022; Roth; Wermer-Colan, 2023).

Para esta tese, o aprendizado por reforço (*Reinforcement Learning* – RL) foi o utilizado. Segundo Kaelbling, Littman e Morre (1996), Sutton e Barto (2018) e Jang *et al.* (2019), esta técnica baseia-se em um ciclo fechado onde o agente observa o estado (S) do ambiente, executa uma ação (A) e recebe um feedback quantificável na forma de recompensa (R) ou penalidade, ou seja, o sistema aprende por meio de interações com o ambiente, ajustando-se conforme o recebimento de recompensas ou punições.

O RL diferencia-se de outras abordagens ao modelar o problema como um processo sequencial de tomada de decisão, no qual um agente interage continuamente com o ambiente, observa estados, executa ações e recebe recompensas associadas ao desempenho obtido. O objetivo não é encontrar apenas uma solução pontual para um único cenário, mas aprender uma política de decisão capaz de otimizar a recompensa acumulada ao longo de sucessivas interações com o ambiente (Sutton; Barto, 2018; Jang *et al.*, 2019; Vermeulen, 2019).

Do ponto de vista computacional, existe uma ampla variedade de softwares, bibliotecas e ambientes de desenvolvimento capazes de implementar algoritmos de aprendizado de máquina. Entre eles destacam-se plataformas especializadas como TensorFlow®, PyTorch®, Scikit-Learn®, Weka®, RapidMiner®, KNIME®, MATLAB® e ambientes de computação científica baseados em Python, R ou Java. No contexto da simulação, esses algoritmos podem ser integrados por meio de APIs externas ou encapsulados diretamente no próprio software AnyLogic®, utilizando sua linguagem nativa baseada em Java ou bibliotecas externas incorporadas ao modelo. Essa flexibilidade permite construir agentes capazes de aprender, adaptar-se e modificar suas decisões ao longo das execuções, ampliando o realismo e a capacidade analítica dos experimentos de simulação (Mustafee *et al.*, 2020; Brailsford, 2023; Badakhshan; Mustafee; Bahadori, 2024).

Dentre os diversos algoritmos de RL disponíveis na literatura, optou-se pela utilização do *Q-Learning* devido às características do problema abordado nesta pesquisa. O

reposicionamento de pontos de ônibus consiste em um processo sequencial de tomada de decisão, no qual cada deslocamento altera o estado da rede de transporte e produz uma nova recompensa representada pela variação do indicador global de acessibilidade. Esse tipo de problema pode ser modelado como um Processo de Decisão de Markov (PDM), sendo o *Q-Learning* um dos algoritmos clássicos mais consolidados para resolução desse tipo de problema por meio de interações sucessivas entre agente e ambiente (Chadi; Mousannif, 2023; Jang *et al.*, 2019).

O *Q-Learning* é uma abordagem de programação dinâmica estocástica amplamente consolidada para a resolução de problemas de tomada de decisão sequencial, proposto originalmente por Watkins e Dayan (1992), integrando a classe dos métodos baseados em valor. Sob esse paradigma, o agente abdica da necessidade de um mapeamento prévio da dinâmica de transição de estados do ambiente, aprendendo de forma assíncrona o valor esperado de executar determinada ação em um estado específico a partir da interação direta e da recepção de recompensas (Chadi; Mousannif, 2023; Jang *et al.*, 2019). Essa independência de um modelo analítico transicional prévio confere ao algoritmo uma adaptabilidade única para a racionalização de sistemas complexos representados por ambientes de simulação computacional, nos quais as funções de transição de estado são implicitamente computadas pelo simulador.

Although more recent algorithms, such as Deep Q-Network (DQN), Twin Delayed Deep Deterministic Policy Gradient (TD3), and Proximal Policy Optimization (PPO), exhibit above-average performance in continuous and high-dimensional environments, they rely on deep neural networks, large amounts of training data, greater computational capacity, and significantly more complex parameter tuning. Em contrapartida, o problema tratado nesta pesquisa possui um conjunto reduzido de ações discretas (deslocamentos nas direções cardeais e manutenção da posição), permitindo sua representação eficiente por meio de uma tabela Q (Chadi; Mousannif, 2023; Jang *et al.*, 2019). Nessas condições, Chadi e Mousannif (2023) recomendam a utilização do *Q-Learning* tabular devido à sua simplicidade, estabilidade e facilidade de interpretação do processo de aprendizagem.

Diferentemente dos métodos fundamentados em gradiente de política (TD3 e PPO, por exemplo), que parametrizam e otimizam a política diretamente, o *Q-Learning* estima iterativamente a função valor-ação, designada como função Q. Essa função quantifica a utilidade a longo prazo, traduzida pela recompensa acumulada esperada ao se adotar uma ação A em um estado S, assumindo que o agente seguirá a política ótima nos passos subsequentes. O processo de convergência fundamenta-se em um ciclo contínuo de experimentação e

refinamento, onde o agente avalia o estado corrente do sistema, seleciona e executa uma ação balizada por um balanço entre exploração e explotação, colhe a recompensa imediata do ambiente e atualiza a estrutura de dados matricial (Tabela Q) ou função aproximada correspondente (Sutton; Barto, 2018; Watkins; Dayan, 1992).

Sob a perspectiva metodológica da pesquisa operacional, a transição de abordagens meta-heurísticas de busca local estocástica para o arcabouço do *Q-Learning* oferece vantagens estruturais para o problema de alocação espacial. Enquanto as heurísticas convencionais operam trajetórias de busca restritas a soluções pontuais no espaço de soluções, o *Q-Learning* mapeia a topologia do problema em um espaço de estados dinâmico. Consequentemente, em vez de meramente identificar uma configuração estática e isolada para a localização dos pontos de parada de ônibus, o algoritmo induz uma política de decisão robusta, associando regras de ação aos múltiplos estados operacionais da rede de transporte (Chadi; Mousannif, 2023; Jang *et al.*, 2019). A melhor solução encontrada, portanto, transcende um arranjo físico fixo, onde o *Q-Learning* se consolida como uma política de governança de sistema, apta a ditar intervenções nas infraestruturas coerentes mesmo diante de perturbações dinâmicas na demanda ou na oferta viária.

A atualização recursiva dos valores da função Q é governada pela equação de Bellman adaptada para Diferenças Temporais de ordem zero (*TD(0)*), formalizada na Equação 1 (Watkins; Dayan, 1992).

$$Q(s,a) \leftarrow Q(s,a) + \alpha \times [r + \gamma \times \max_{\alpha'} Q(s',a') - Q(s,a)] \qquad \text{Eq. (1)}$$

Onde:

- $Q(s,a)$ representa o valor atual associado à execução da ação *a* no estado *s*;
- α corresponde à taxa de aprendizagem (*learning rate*), que pondera o grau de absorção do erro de diferença temporal em relação ao conhecimento historicamente acumulado;
- r constitui a recompensa imediata penalizada ou bonificada, retroalimentada pelo ambiente após a transição;
- γ expressa o fator de desconto, encarregado de modular a escala de relevância das recompensas futuras em detrimento da utilidade imediata, garantindo a convergência da série infinita;
- $\max_{\alpha'} Q(s',a')$ corresponde ao maior valor estimado para as ações possíveis no estado subsequente *s'*.

A equação 1 é baseada no princípio da diferença temporal, no qual o agente atualiza continuamente suas estimativas comparando a recompensa efetivamente observada com a recompensa esperada para os estados futuros. Dessa forma, o algoritmo tende a convergir para uma política ótima à medida que explora repetidamente o ambiente e acumula experiências de interação (Chadi; Mousannif, 2023; Jang *et al.*, 2019; Sutton; Barto, 2018).

No âmbito desta tese, o ambiente macroscópico de aprendizagem é operacionalizado pelo modelo de simulação híbrida de transporte público concebido na plataforma AnyLogic®. Os estados do PDM refletem as configurações espaciais instantâneas dos pontos de parada integrados aos níveis topológicos de acessibilidade urbana vigentes. As ações compreendem o portfólio de intervenções físicas exequíveis na infraestrutura, tais como a translação geométrica dos pontos de embarque e desembarque. A recompensa, por sua vez, é computada como o diferencial do indicador de acessibilidade de Ingram (1971) mensurado entre os estados de transição. Por meio desse encadeamento metodológico, o agente de *Q-Learning* converge para uma política de ordenamento territorial capaz de buscar configurações com melhor desempenho para o acesso populacional às centralidades urbanas, atuando de maneira inteligível na racionalização do sistema de transporte coletivo.

3 MÉTODO DE PESQUISA

A pesquisa adota uma abordagem metodológica baseada em modelagem e simulação, de natureza aplicada com caráter descritivo-explicativo. Utilizou-se uma estratégia quali-quantitativa, a partir de dados secundários extraídos de fontes bibliográficas e bases públicas disponíveis em plataformas governamentais e empresariais.

Segundo Miguel *et al.* (2012), a pesquisa aplicada visa resolver um problema concreto, frequentemente associada à experimentação baseada em experiências práticas ou especulações fundamentadas. Neste estudo, desenvolveu-se um *framework* de modelagem e simulação híbrida (MSH) aplicado ao transporte público, cuja validade foi testada por meio de um objeto de estudo.

A dimensão explicativa concentrou-se na identificação, com base na literatura, dos principais elementos, etapas e práticas que sustentam o desenvolvimento do *framework* híbrido. Já o caráter descritivo permitiu organizar e apresentar de forma sistemática as fases e características do modelo proposto. De acordo com Marconi e Lakatos (2022), pesquisas explicativas visam compreender fenômenos em profundidade, podendo envolver descrições qualitativas, quantitativas e inferências causais. Sampieri, Collado e Lucio (2013) acrescentam que a pesquisa descritiva busca especificar propriedades e perfis a partir da análise de informações já disponíveis na literatura científica.

A abordagem quali-quantitativa adotada permitiu a combinação de métodos descritivos com dados empíricos e teóricos, ampliando a compreensão do fenômeno estudado. Segundo Marconi e Lakatos (2022), Miguel *et al.* (2012) e Sampieri, Collado e Lucio (2013), a vertente qualitativa possibilita interpretar o objeto de estudo em profundidade, respondendo às questões que envolvem seu funcionamento. Por sua vez, segundo os mesmos autores, a abordagem quantitativa sistematiza e mensura os dados obtidos, com apoio de tabelas, quadros e medidas estatísticas. Essa combinação caracteriza a pesquisa como aplicada, de natureza exploratória-descritiva.

O método de pesquisa adotado foi a modelagem e simulação, considerado adequado para representar e testar sistemas reais em ambiente computacional. Chwif e Medina (2014) destacam que a os modelos podem ser de três tipos distintos: simbólico, icônico ou diagramado; matemático ou analítico; e modelos de simulação. No caso desta tese, trabalhou-se com o último tipo, o qual busca capturar com mais fidelidade as características de um sistema real, recriando-os por meio computadorizado, por meio de um ciclo de vida de um modelo de simulação (Bertrand; Fransoo, 2002; Chwif; Medina, 2014).

As etapas metodológicas seguiram múltiplas referências: (i) o protocolo ODD (Overview, Design Concepts, and Details), proposto por Grimm *et al.* (2006) e atualizado por Onggo e Foramitti (2021); (ii) as fases de identificação do sistema, modelagem conceitual, implementação computacional e análise experimental, conforme Miltroff *et al.* (1974), Montevechi *et al.* (2010), Robinson (2004) e Sargent (2013); e (iii) a caracterização de agentes com base em tipos, atributos e comportamentos, conforme Macal e North (2009) e Huang *et al.* (2022). Tais definições foram apresentadas na seção 2.2.

A modelagem híbrida adotada nesta pesquisa é classificada como Tipo E, conforme a taxonomia de Mustafee, Harper e Fakhimi (2022), por integrar simultaneamente os paradigmas da SED e da SBA em um único modelo interdependente. A implementação foi realizada no software de simulação AnyLogic PLE 8.9.7®, incluindo a integração de: funcionalidades de geolocalização, por meio da API do OpenStreetMap (OSM); criação de agentes via SBA e fluxos de processos discretos via SED; inserção das equações de tempos percorridos, pontos de partida e chegada e do indicador de acessibilidade; e algoritmo de aprendizado de máquina com paradigma de aprendizado por reforço. Também se informa a utilização do software Microsoft Excel Office LTSC Professional Plus 2021® para tabulações diversas e do software Minitab 19.1® para gráficos e análises estatísticas.

A SED foi utilizada para representar o fluxo operacional do sistema de transporte, incluindo paradas e embarques, enquanto a SBA modelou o comportamento individual dos passageiros e veículos em tempo contínuo. A combinação dessas abordagens permitiu a construção de um modelo dinâmico e realista da operação do transporte público.

Com base na classificação proposta por Bertrand e Fransoo (2002) na seção 2.2.1, o modelo SED adotado no *framework* é do tipo axiomático-descritivo, pois parte da definição conceitual do sistema, da caracterização do objeto de estudo e da identificação das variáveis-chave, sem propor otimizações específicas. No que se refere à SBA, a simulação foi do tipo interativa, uma vez que os agentes são autônomos e interagem tanto entre si quanto com o ambiente, conforme as definições de Macal (2016) na seção 2.2.2.

Para a análise do objeto de estudo simulado, adotou-se o indicador de acessibilidade aos pontos de transporte como principal métrica de desempenho, conforme justificado na revisão teórica na seção 2.1. Esse indicador expressa de forma quantitativa a facilidade com que os indivíduos alcançam pontos da rede, considerando aspectos espaciais, temporais e de custo. Conforme Ingram (1971), a acessibilidade quantifica a atratividade de uma estação com base na interação entre a oferta de transporte e o esforço exigido para acessá-la, seja esse representado por tempo, distância ou custo monetário.

A implementação do aprendizado de máquina foi realizada por meio de algoritmos de aprendizado por reforço internamente no software AnyLogic®. Essa integração permite incorporar algoritmos inteligentes diretamente nos modelos de simulação, ampliando sua capacidade de resposta a ambientes dinâmicos.

A Figura 6 ilustra cada etapa para cada uma das tecnologias e abordagens incorporadas na tese. Em conjunto, a seção 4 explana cada uma das etapas no desenvolvimento do protocolo de pesquisa, sendo corroborada e justificada pela literatura da área.

Figura 6 - Incorporação das tecnologias e abordagens no método de pesquisa

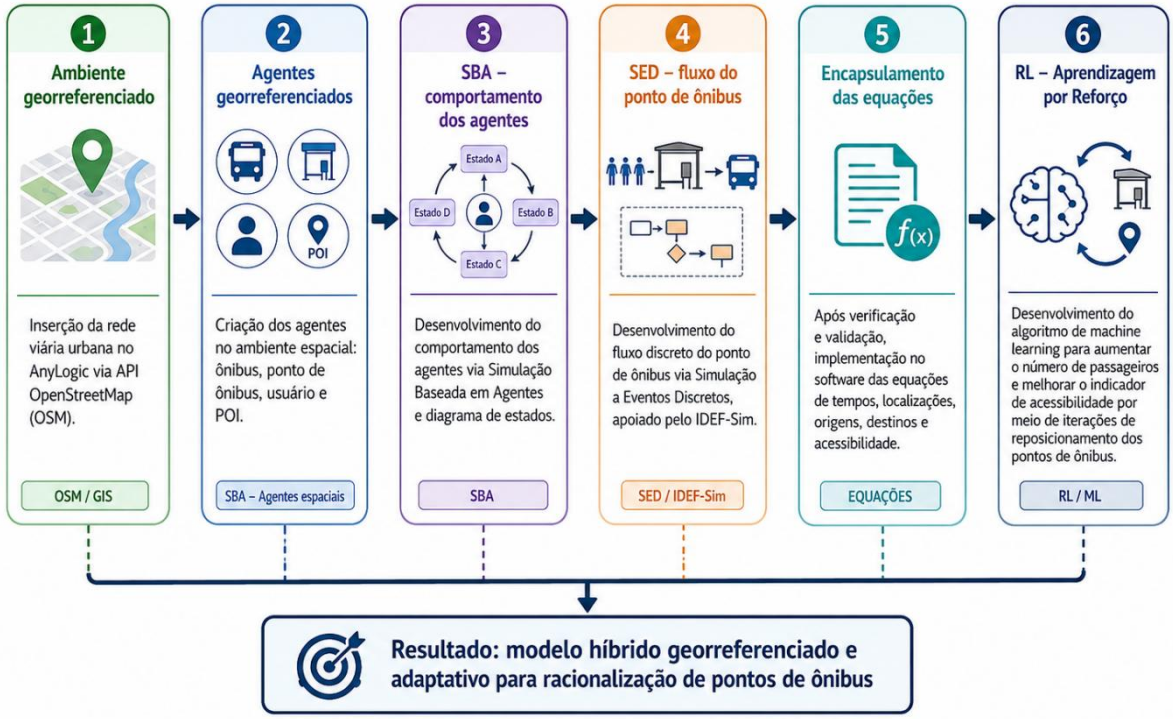

Fonte: Elaborado pelo autor (2026).

4 DESENVOLVIMENTO DO PROTOCOLO DE PESQUISA (FRAMEWORK MSH EM TRANSPORTE PÚBLICO)

Conforme argumentado na seção 1.2, a diversidade de variáveis e parâmetros dificulta a definição de um modelo de referência único para modelagem e simulação híbrida (Brailsford *et al.*, 2019). Diante disto, o método de pesquisa estrutura-se em um protocolo original de modelagem e simulação híbrida (MSH) aplicado ao transporte público urbano. Esse protocolo constitui o núcleo metodológico da tese, articulando três etapas (concepção, implementação e análise) que orientam desde a formulação.

A etapa de concepção representa a principal contribuição deste *framework*, ao definir as possibilidades de inserção de dados e modelagem no contexto da MSH em transporte público. A etapa de implementação contempla o desenvolvimento computacional do modelo, estruturando agentes, processos e fluxos no ambiente de simulação, de acordo com o modelo conceitual elaborado bem como validar a emulação. Por fim, a etapa de análise e experimentação visa aplicar os cenários de *machine learning* e avaliar os indicadores de desempenho definidos, alinhando-se às práticas consolidadas na literatura.

4.1 Concepção

Nessa etapa, o ambiente real é abstraído por meio de um modelo conceitual, utilizando técnicas diagramáticas que facilitam a representação lógica e operacional do sistema (Bateman *et al.*, 2013). O grau de detalhamento do modelo é um ponto crítico pois níveis excessivos podem demandar elevado esforço de coleta e parametrização sem ganhos proporcionais em precisão. Por outro lado, um detalhamento superficial pode omitir aspectos essenciais do sistema simulado.

A Figura 7 ilustra os passos propostos e os autores que subsidiaram cada um deles. Já o Quadro 15 resume cada etapa e suas principais características. Lembra-se que todo o *framework* foi baseado e se restringe para a pesquisa de uma MSH para transporte público, necessitando de adaptações ou reestruturações para outras áreas de pesquisa com MSH.

Figura 7 - Etapa de Concepção do Framework Proposto

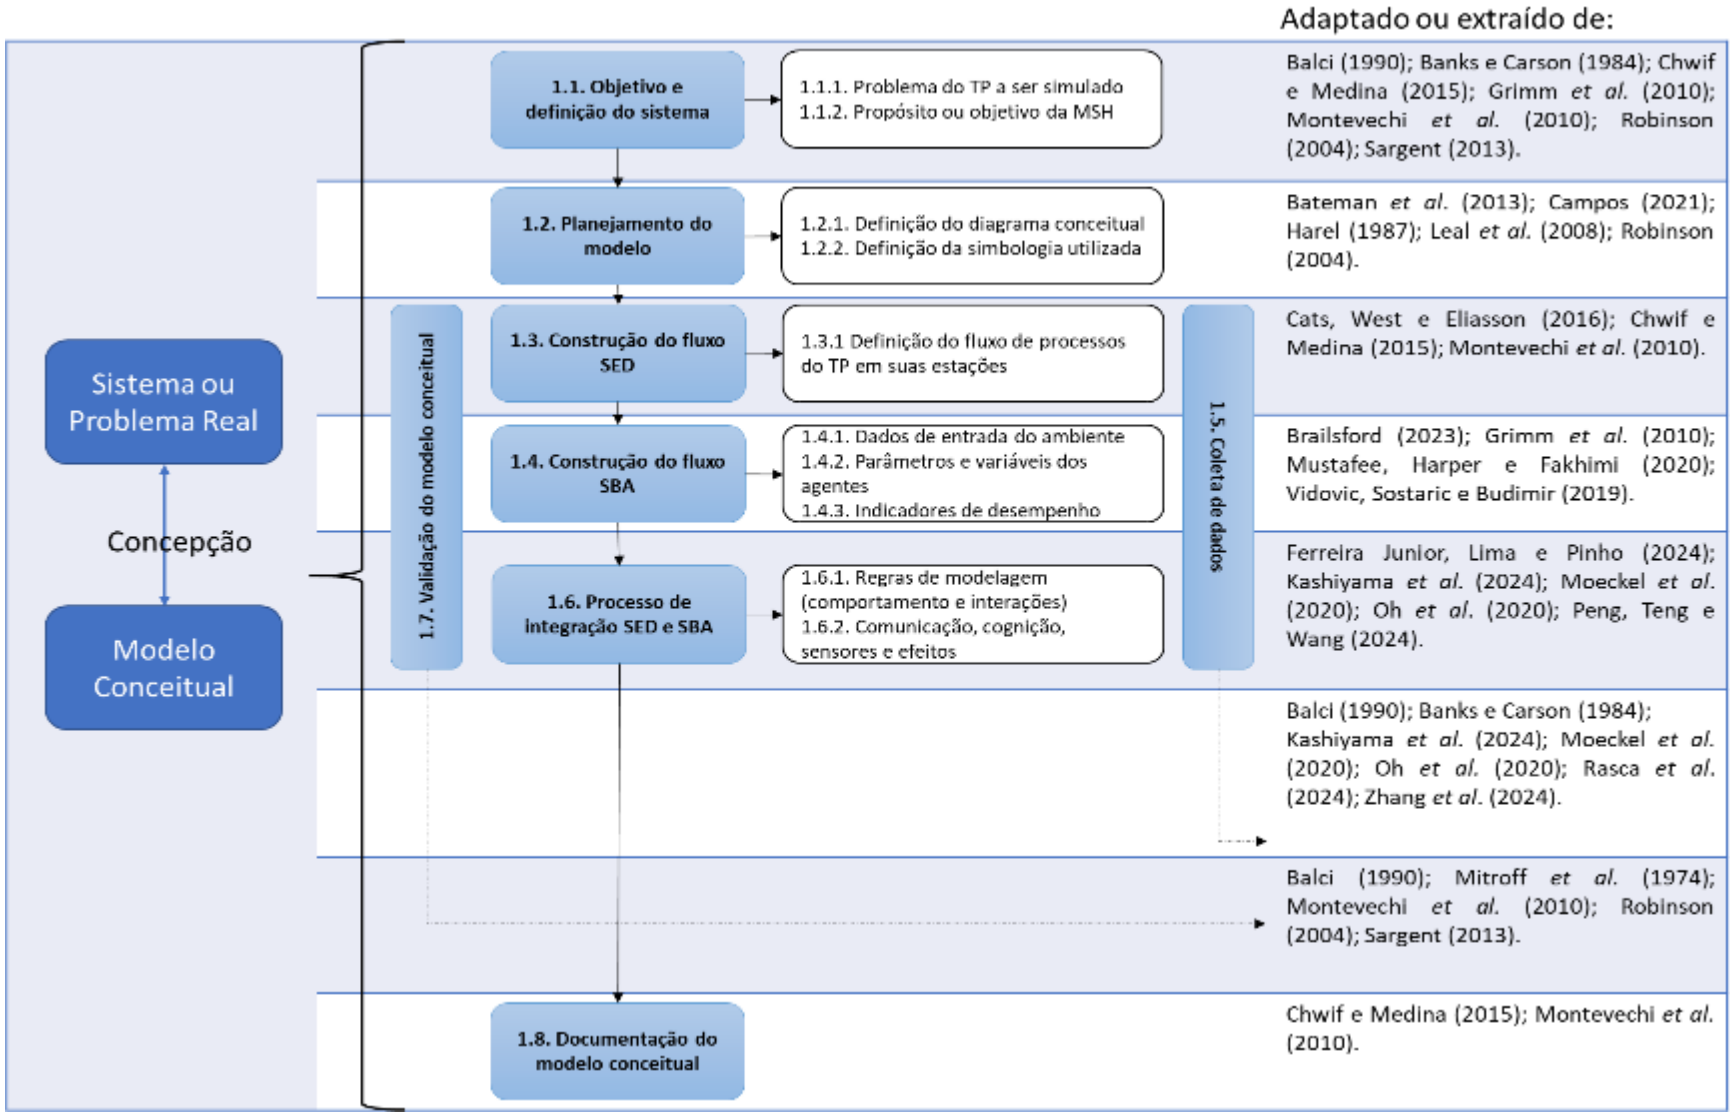

Fonte: Elaborado pelo autor (2026).

Quadro 15 - Resumo das etapas de Concepção do Framework Proposto

N.	Etapa	Descrição	Proposição na tese
1.1	**Objetivo e definição do sistema**	Definir problema e propósito da modelagem e simulação. Reconhecer que há um desafio no ambiente real o qual necessita ser entendido, simulado e melhorado. Definir quais os agentes e entidades compõe o sistema estudado.	Racionalizar a posição dos pontos de ônibus conforme o indicador de acessibilidade em um objeto de estudo, por meio de aprendizado de máquina. Utilizar como diretrizes o GIS do local em conjunto com os POIs, estações de embarque e desembarque e personas desenvolvidas pelos dados censitários.
1.2	**Planejamento do modelo**	Elaborar ou definir modelo diagramado, que representa, de forma lógica e estruturada, o problema estudado.	Utilizar as simbologias IDEF-Sim para o fluxo SED e o Diagrama de estados para o fluxo SBA.
1.3	**Construção do Fluxo SED**	Determinar os eventos que demandam tempo e requerem a transformação de uma entidade ao longo de etapas, conectando-os em um fluxo de processos.	Plotar o comportamento do ônibus no TP fazendo-o chegar a uma estação, aguardar o embarque e desembarque de passageiros e se locomover para a estação seguinte.
1.4	**Construção do Fluxo SBA**	Indicar atributos, variáveis e parâmetros para os agentes que compõe o modelo.	Determinar os comportamentos e informações dos agentes usuários, veículos de transporte e dos POIs, via algoritmos e/ou equacionamentos, por meio de parâmetros e variáveis.
1.5	**Coleta de dados**	Definir principais métricas para inserção no fluxo SED e SBA do modelo, incluindo também indicadores de desempenho a serem metrificados ao final. Utilizar dados de entrevistas, de arquivos, de surveys e outros disponíveis para cada tipo de agente.	Incorporação de dados referentes às construções dos agentes, como dados censitários, posição geográfica dos pontos de ônibus e POIs, velocidade e capacidade dos veículos, número de usuários no objeto de estudo, tempos e distâncias propícias para embarque e desembarque dos usuários, entre outros elementos.
1.6	**Processo de integração SED e SBA**	Estabelecer e garantir coerência nas conexões entre os modelos SED e SBA, assegurando que os agentes interajam tanto com o ambiente quanto entre si. Formatar a comunicação e os efeitos gerados pelos desdobramentos de ações dos agentes.	Desenhar no modelo conceitual as conexões e relações entre os agentes e os eventos. Indicar a decisão do agente usuário tomar um TP para se locomover até determinado POI, se deslocar ao ponto de ônibus, adentrar e desembarcar em outro ponto de ônibus e tomar decisões durante todos estes processos.
1.7	**Validação do modelo conceitual**	Assegurar que o modelo proposto representa o ambiente real em forma diagramada por meio de: validação com especialistas; rastreamento da lógica do comportamento e de suas transições nos diagramas; verificação das hipóteses e teorias que fundamentam o modelo e os seus objetivos; e a revisão colaborativa e sistemática dos elementos do modelo conceitual.	Questionar com especialistas se o modelo conceitual é semelhante com a atual estrutura do objeto de estudo. Verificar se a conexão dos eventos e dos agentes está em consonância com a literatura da área.
1.8	**Documentação do modelo conceitual**	Plotar e salvar em arquivos virtuais e/ou físicos o modelo validado.	Diagramar o modelo conceitual final em formato de imagem na tese.

Fonte: Elaborado pelo autor (2026).

O passo 1.4 (Construção do fluxo SBA) trata do desenvolvimento dos agentes do modelo. A partir da RSL, o principal agente determinado é o usuário, composto por um conjunto de personas (Rasca *et al.*, 2024). São consideradas variáveis como modo de transporte preferencial, destinos prováveis, sensibilidade ao deslocamento e cronograma de atividades, conforme Figura 8. A partir desses dados, constrói-se a população sintética e os planos de viagem, conforme sugerem Kashiyama *et al.* (2024), Simoni *et al.* (2019) e Zhang *et al.* (2024).

Figura 8 - Possibilidades de agentes, parâmetros e variáveis para etapa da SBA

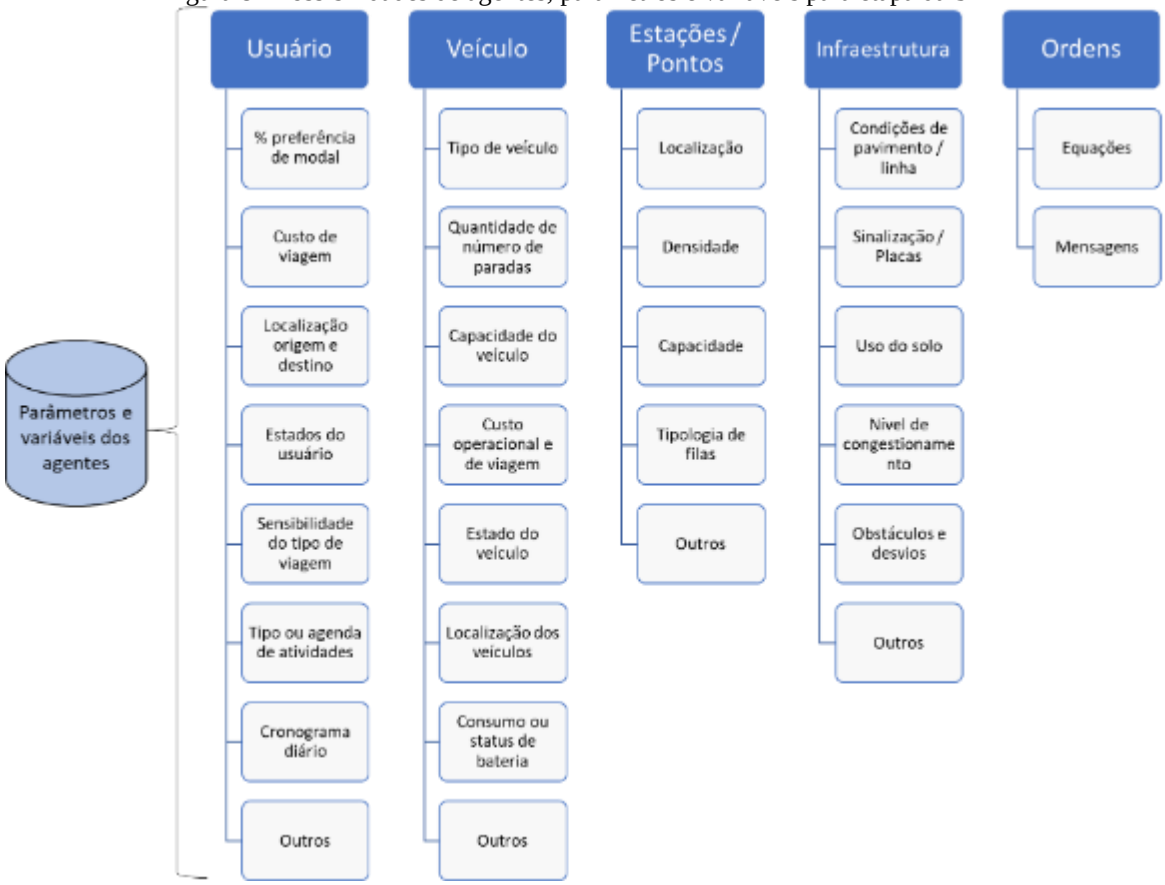

Fonte: Elaborado pelo autor (2026).

Informações e dados podem ser coletados de diversos meios para compor os demais agentes: (i) tipos de veículos e suas capacidades por meio de dados públicos, da empresa de transporte, coleta manual, observações; (ii) tipos de estações e pontos por meio de localização por dados públicos ou georreferenciamento, observações e entrevistas com usuários; (iii) infraestrutura por meio do ambiente em GIS, POIs georreferenciados e sensores de tráfego; (iv) ordens, por meio de formatação de envio de mensagens ou equacionamentos diversos para compor e comunicar os demais agentes. Nesta pesquisa utilizaram-se os dados da literatura da área, conforme RSL, dados disponíveis em sítios virtuais públicos, como IBGE Cidades (2025,

online) e dados reais de embarques no sistema de transporte público urbano por ônibus da cidade objeto de estudo.

A validação conceitual tem como objetivo verificar se a estrutura lógica do modelo, suas premissas, entidades, relacionamentos e mecanismos de funcionamento representam adequadamente o sistema real que se pretende estudar, antes da implementação computacional. Segundo Sargent (2020), essa etapa é fundamental para garantir que o modelo conceitual seja consistente com os objetivos da pesquisa e com o conhecimento disponível sobre o fenômeno analisado. Neste trabalho, a validação conceitual foi conduzida por meio de três abordagens complementares: validação face a face realizada junto a especialistas avaliando a coerência da estrutura do modelo, dos agentes e dos fluxos representados; *tracing*, acompanhando detalhadamente a sequência lógica dos estados, transições e interações dos agentes para verificar a consistência dos comportamentos especificados no modelo conceitual; e por comparação com a literatura, confrontando os elementos do modelo, os parâmetros adotados e as relações representadas com estudos previamente publicados sobre acessibilidade urbana, transporte coletivo e simulação baseada em agentes. A combinação dessas técnicas permitiu aumentar a confiabilidade do modelo conceitual antes de sua implementação computacional, conforme recomendado por Sargent (2020).

Conclui-se que a etapa de concepção exerce papel central no *framework* de modelagem híbrida proposto, ao estabelecer a base conceitual do sistema. Ao definir os agentes, fluxos, dados de entrada e interações fundamentais, essa fase assegura coerência e solidez à implementação computacional subsequente.

4.2 Implementação

Com o modelo conceitual estruturado e validado, inicia-se a etapa de implementação, na qual os diagramas conceituais são convertidos em códigos no ambiente computacional, neste caso, o software AnyLogic®. Modelam-se fluxos, comportamentos e estados definidos para os agentes e entidades do sistema, mantendo a coerência com as estruturas previamente estabelecidas na concepção. A Figura 9 ilustra os passos da etapa de implementação, com base nas referências teóricas utilizadas para sua formulação. O Quadro 16 descreve detalhadamente cada uma dessas etapas e como elas serão incorporadas ao objeto de estudo desta tese.

Figura 9 - Etapa de Implementação do Framework Proposto

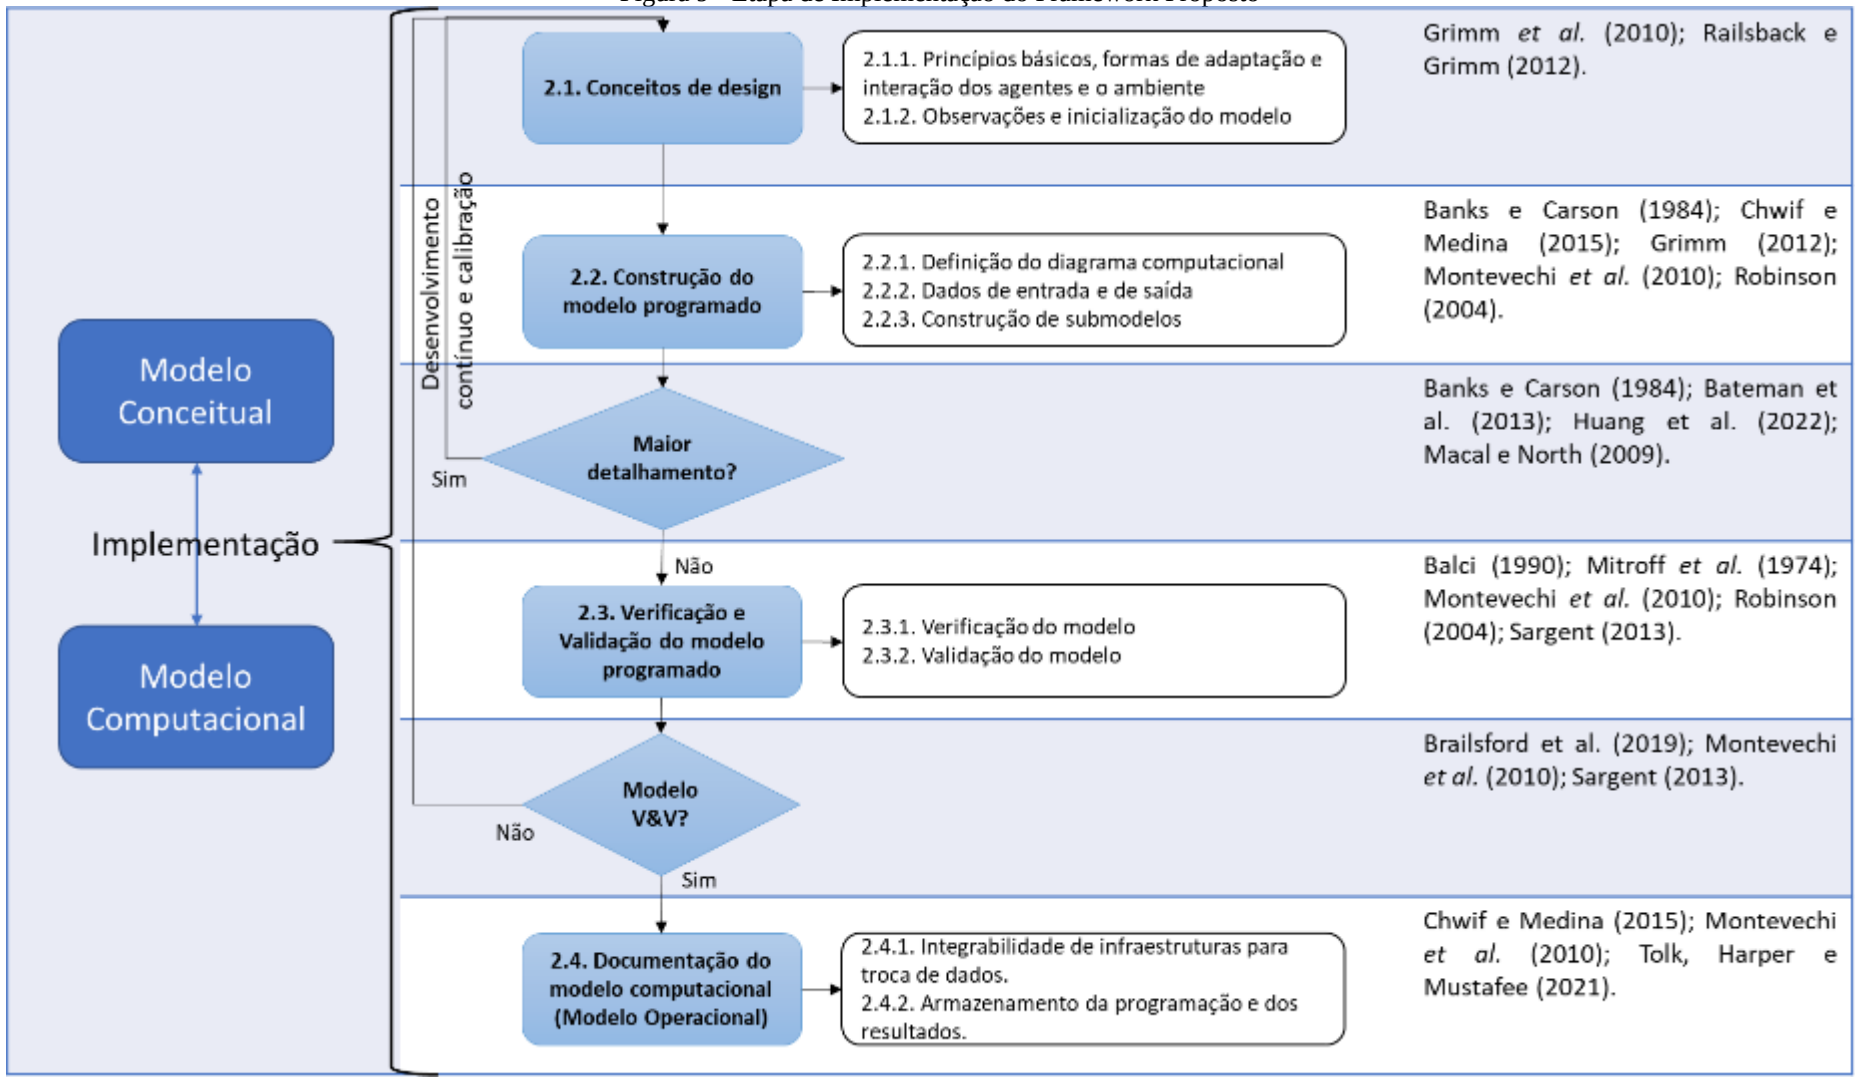

Fonte: Elaborado pelo autor (2026).

Quadro 16 - Resumo das etapas de Implementação do Framework Proposto

N.	Etapa	Descrição	Proposição na tese
2.1	**Conceitos de Design**	Descrever detalhadamente o modelo, sua organização, interações com o ambiente e com outros agentes, comportamentos adaptativos e regras de decisão que o regerão computacionalmente. Estabelecer os parâmetros iniciais do modelo em cada um dos agentes. Decidir o software a ser utilizado conforme preâmbulos conceituais.	Definir software, parâmetros, regras de transição de estados, cálculos internos e integração de submodelos executadas pelo modelador, de forma alinhada às recomendações metodológicas da literatura e aos dados coletados.
2.2	**Construção do modelo programado**	Desenvolver a estrutura de programação no software, codificando-o conforme o modelo conceitual.	Inserir no AnyLogic®: ambiente GIS; agentes e POIs; dados de personas e de rotas dos veículos; georreferenciamento dos pontos de ônibus; encapsulamento de todos os algoritmos para a correta integração do modelo.
2.3	**Maior detalhamento e calibração**	Refinar de forma progressiva o modelo computacional. Decidir nível de detalhe, ajustes nas estruturas dos agentes e iterações sucessivas de calibração.	Calibrar os parâmetros livres do modelo para que suas saídas reproduzam, com precisão aceitável, os comportamentos observados no sistema real.
2.4	**Verificação e validação do modelo programado**	Garantir que o modelo computacional foi implementado de maneira correta. Assegurar que o modelo computacional representa de forma adequada o sistema real para os objetivos propostos.	Verificar por meio de análise da animação e da consistência lógica da programação. Validar por meio de análise face a face e comparação estatística (testes de hipóteses).
	Modelo V&V?	Avaliar semelhança dos indicadores de desempenho do modelo computacional quali e/ou quantitativos perante técnicas de V&V para com o ambiente real.	Comparar dados reais do objeto de estudo com os simulados, como tempo de viagem, número de passageiros atendidos e ocupação dos veículos.
2.5	**Documentação do modelo computacional**	Documentar o modelo computacional, seus algoritmos e enfatizar os aspectos de compatibilidade com os conceitos, interoperatividade com as interações e Integrabilidade de infraestruturas.	Descrever todo o passo a passo da construção do modelo computacional na tese, a fim de permitir que os modelos sejam reutilizáveis, compreensíveis e validados por pesquisadores de diferentes áreas.

Fonte: Elaborado pelo autor (2026).

De acordo com Grimm *et al.* (2006), a etapa de conceitos de design do protocolo ODD descreve os mecanismos responsáveis pela dinâmica interna dos modelos baseados em agentes. Essa etapa compreende onze conceitos complementares (princípios básicos, emergência, adaptação, objetivos, aprendizagem, predição, sensoriamento, interação, estocasticidade, coletivos e observação) que, em conjunto, explicam como os agentes percebem o ambiente, executam decisões e geram os padrões emergentes observados no sistema simulado (Grimm *et al.*, 2006; Barbieri, 2016).

Dentro desta primeira etapa, um aspecto central da etapa de implementação é a integração de dados geoespaciais. Para isso, utilizou-se a Application Programming Interface (API) do AnyLogic® em conjunto com a base do OpenStreetMap (OSM), possibilitando o carregamento de dados georreferenciados relativos às estações de ônibus e aos pontos de

interesse (POIs). Essa integração espacial foi alinhada à lógica comportamental representada nos diagramas de estado dos agentes, como ônibus e passageiros.

Outro elemento de cuidado do *framework* proposto é a inserção dos pontos de ônibus e dos POIs por georreferenciamento. O uso do georreferenciamento em cidades brasileiras apresenta desafios relevantes, como a escassez de Sistemas de Informação Geográfica (SIG) municipais estruturados, ausência de bases cartográficas atualizadas e problemas na padronização dos endereços (Mendes; Ferreira, 2019; Silveira; Oliveira; Junger, 2017).

A etapa de verificação e validação (V&V) é fundamental para assegurar a credibilidade e robustez do modelo de simulação. Como afirmam Sargent (2013) e Brailsford *et al.* (2019), a ausência de V&V compromete a confiabilidade do modelo como ferramenta de apoio à decisão, ou seja, essa etapa deve ser rigorosamente conduzida, utilizando técnicas como análise da consistência lógica, comparação estatística com dados reais e validação com especialistas. Entre os tipos mais comuns, ressaltam-se: testes estatísticos; rastreamento trace; visualização da animação; comparação com modelos alternativos; *debugging*; análise de sensibilidade, comparação com dados reais; entre outros (Sargent, 2013).

Para tanto, nesta tese, foi utilizada no AnyLogic® a função de otimização baseada em calibração de parâmetros, aproximando o número de usuários que desejam ir via ônibus a algum POI para valores próximos aos dados reais, seguindo a estrutura proposta por Li *et al.* (2024). Posterior a isto, foi utilizada a técnica de validação estatística de teste ANOVA, para avaliar a hipótese de semelhança do número de usuários por linha real *versus* o simulado em *n* rodadas/réplicas com tamanhos amostrais distintos, conforme estrutura proposta por Montgomery e Runger (2013).

Conclui-se que a etapa de implementação possui papel central no *framework* de modelagem híbrida proposto, por operacionalizar computacionalmente as estruturas definidas na concepção. A integração entre paradigmas SBA e SED, aliada ao uso de dados georreferenciados e de técnicas rigorosas de V&V, confere robustez ao modelo e sustenta a análise de cenários e a formulação de recomendações no campo da mobilidade urbana.

4.3 Análise e Experimentação

Após a modelagem e validação do modelo computacional, inicia-se a etapa de análise e experimentação. Essa fase tem por objetivo estudar, executar os experimentos e interpretar os resultados obtidos nas simulações, conforme orientam Robinson (2004) e Sargent (2020). Cada novo experimento deve ser fundamentado em uma revisão concisa da literatura e devidamente

justificado, de modo a garantir coerência metodológica com os objetivos da pesquisa e evitar análises descontextualizadas. Para esta grande fase, o *framework* proposto elenca a sequência de passos ilustrada na Figura 10 com a definição dos autores base e explicada no Quadro 17 em maiores detalhes.

Quadro 17 - Resumo das etapas de Análise do Framework Proposto

N.	Etapa	Descrição	Proposição na tese
3.1	**Introdução de outras áreas temáticas**	Incluir técnicas de pesquisa operacional, otimização e ciências de dados, algoritmos de meta-heurística, inteligência artificial e outros.	Programar o algoritmo de aprendizagem de máquina por reforço do tipo *Q-Learning* tabular, para a posição geográfica dos pontos de ônibus com base no indicador de acessibilidade.
3.2	**Definição do projeto experimental**	Planejar quais cenários, variáveis e combinações serão testados no modelo de simulação. Definir o escopo e os fatores experimentais que serão manipulados para investigar o comportamento do sistema modelado.	Elaborar o experimento internamente ao software com alterações das variáveis e parâmetros dos agentes conforme literatura e incorporando resultados do aprendizado de máquina.
3.3	**Execução dos experimentos**	Gerar dados simulados que possam refletir, com fidelidade, o comportamento do sistema real sob condições controladas e replicáveis	Executar cada experimento proposto pela modelo fatorial e exportar os dados para software estatístico para análise.
3.4	**Análise estatística**	Avaliar o desempenho do sistema modelado, identificar tendências, pontos críticos e oportunidades de melhoria	Aplicar análises estatísticas de boxplot e testes de hipóteses para determinação de melhores parâmetros e resultados.
	Mais rodadas?	Realizar múltiplas replicações com diferentes sementes aleatórias para obter estimativas confiáveis das variáveis de desempenho.	Definir intervalo de confiança do modelo e faixa de aceite do percentil de variáveis ou parâmetros chave do modelo para definir número de amostras e rodadas.
3.5	**Solução/ Entendimento**	Traduzir os achados do modelo para o contexto prático, formulando recomendações operacionais ou estratégicas que possam ser implementadas no sistema real.	Descrever na tese as opções viáveis para melhoria do posicionamento dos pontos de ônibus, de forma qualitativa.

Fonte: Elaborado pelo autor (2026).

Tolk, Harper e Mustafee (2021) definem a multidisciplinaridade como cooperação entre disciplinas, sem integração de saberes. A interdisciplinaridade envolve aplicação cruzada de métodos, enquanto a transdisciplinaridade ultrapassa limites disciplinares ao integrar sistematicamente conhecimentos distintos em uma nova base epistemológica. É nessa perspectiva transdisciplinar que se fundamenta o *framework* proposto nesta tese, ao unir MSH, ciência de dados e aprendizado de máquina em um sistema coeso.

Figura 10 - Etapa de Análise do Framework Proposto

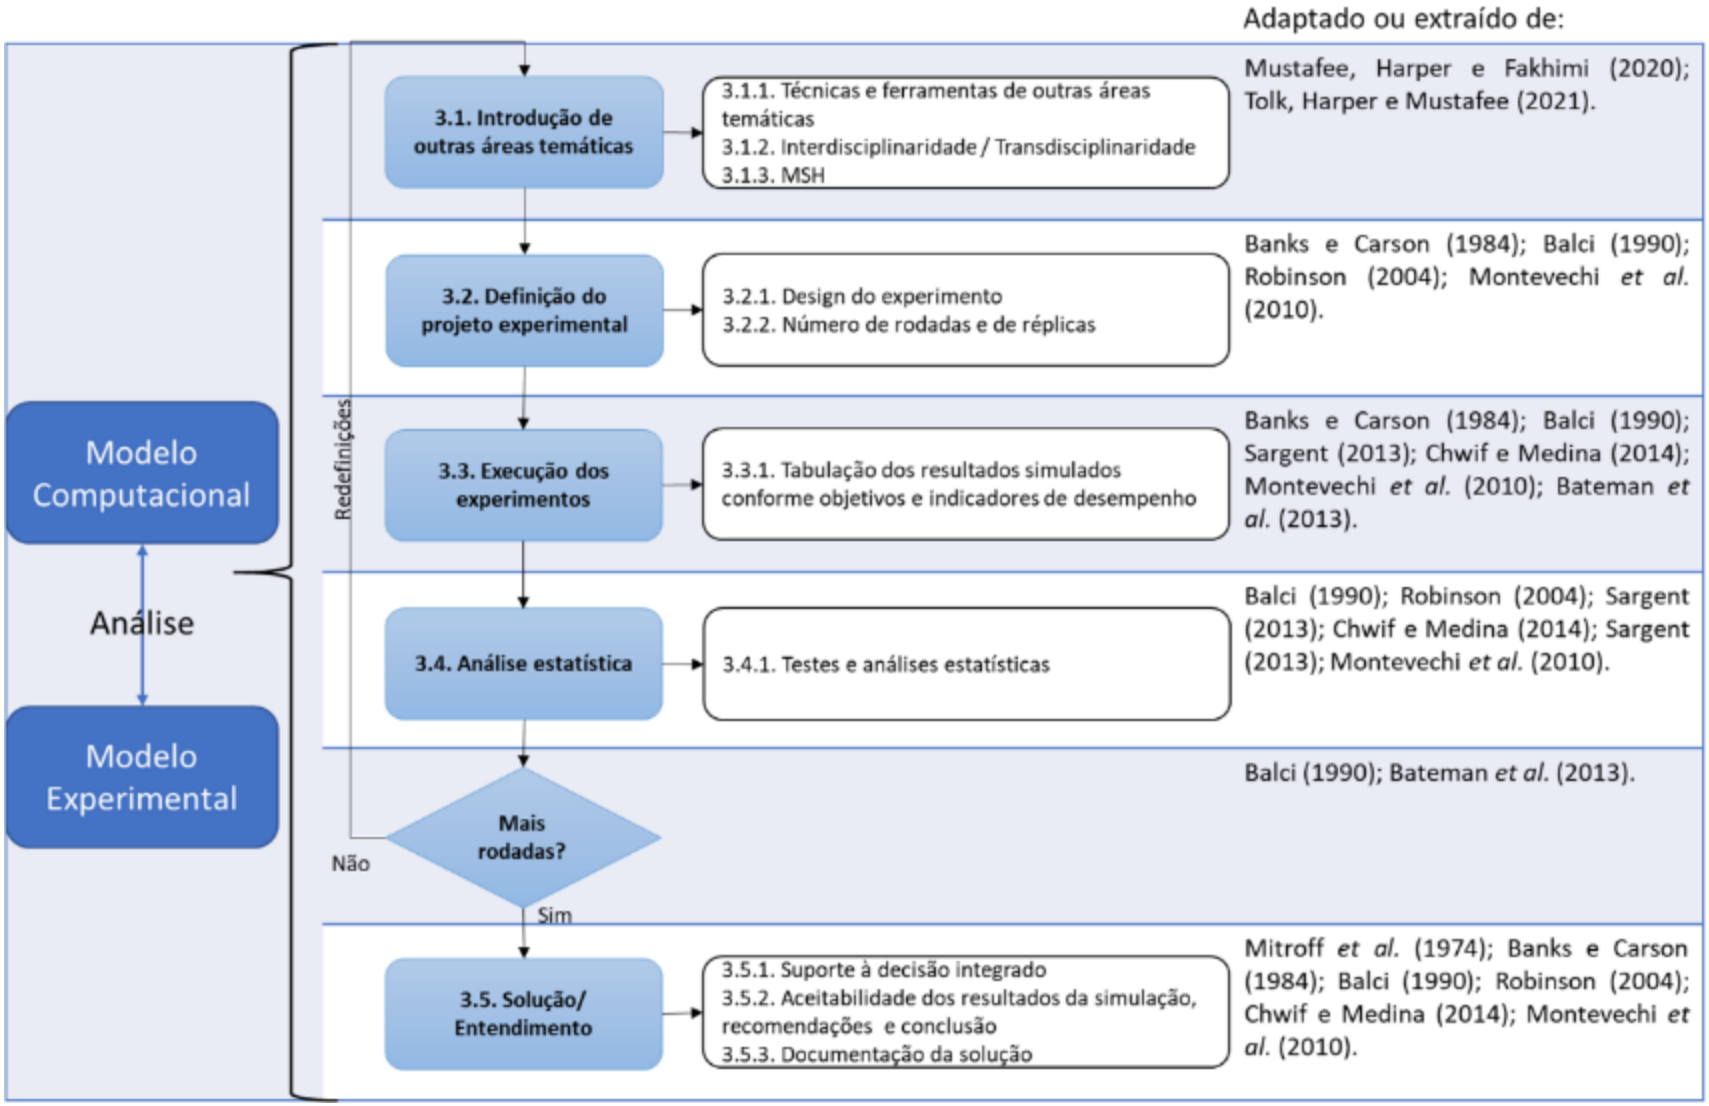

Fonte: Elaborado pelo autor (2026).

A incorporação de técnicas de aprendizado de máquina (ML) em simulações híbridas consolida-se como abordagem promissora para ampliar adaptabilidade, inteligência e capacidade preditiva. Essa integração pode ocorrer em três estágios, tendo foco nesta tese a terceira (Borshchev; Filippov, 2004; Sargent, 2020; Huang *et al.*, 2022):

- Pré-simulação, com a análise exploratória, tratamento e seleção de variáveis relevantes nos dados de entrada;
- Durante a simulação, com a modulação adaptativa do comportamento dos agentes ou regras de decisão em tempo real, por meio de algoritmos previamente treinados;
- Pós-simulação, contribuindo na interpretação automatizada dos resultados e na geração de recomendações com base em aprendizado contínuo.

A literatura aponta duas estratégias de acoplamento entre ML e MSH. No uso interno, algoritmos atuam durante a simulação, ajustando decisões de agentes com base em interações e feedbacks. No uso externo, operam no pré-processamento de dados, calibrando variáveis e parâmetros para maior acurácia. Huang *et al.* (2022) exemplificam esse potencial ao aplicar ML para ajustes dinâmicos em parâmetros operacionais com base em séries temporais e padrões emergentes. Essas aplicações reforçam o papel do ML como mecanismo de inteligência adaptativa, elevando o realismo dos modelos híbridos frente à dinâmica dos sistemas reais.

Sobre a função de recompensa adotada no agente de RL pela técnica *Q-Learning* tabular, a mesma foi baseada no indicador de acessibilidade. Essa escolha decorre do fato de que o objetivo da pesquisa não consiste apenas em otimizar parâmetros operacionais do transporte público, mas em racionalizar os benefícios produzidos para os usuários do sistema. Outras alternativas como minimização do tempo médio de viagem, maximização da demanda atendida ou redução de custos operacionais foram consideradas, entretanto, tais indicadores avaliam apenas dimensões específicas do problema.

A acessibilidade foi selecionada por apresentar caráter mais abrangente, refletindo simultaneamente a distribuição espacial da população, a localização das oportunidades urbanas e a configuração da infraestrutura de transporte. Assim, o agente de RL não busca apenas melhorar o desempenho operacional da rede, mas aprender políticas de decisão capazes de ampliar a capacidade de acesso da população aos destinos urbanos relevantes, objetivo que se encontra diretamente alinhado à proposta conceitual desta tese.

Outro aspecto essencial é a execução de múltiplas rodadas de simulação, que introduzem variabilidade estatística e aumentam a confiabilidade dos resultados. Essa prática é crucial em modelos com elementos estocásticos e interações entre agentes, comuns na mobilidade urbana.

Banks e Carson (1984) já destacavam a importância das replicações para reduzir ruído estatístico e garantir validade. Complementarmente, Sargent (2013) aponta a repetição e expansão de experimentos como condição para inferências robustas.

Em resumo, a cada episódio de treinamento, o agente observa o estado corrente da rede de transporte e seleciona ações relacionadas à configuração dos pontos de parada. Essas ações podem reposicionar os pontos em regiões específicas da cidade. Após a execução da ação, o modelo híbrido simula o comportamento dos usuários e do sistema de transporte, produzindo novos indicadores de acessibilidade. A diferença entre os resultados obtidos e os estados anteriores é utilizada para compor a função de recompensa, permitindo que o agente atualize sua política de decisão e aprenda configurações progressivamente mais eficientes da rede.

Dessa forma, a etapa de análise e experimentação consolida-se como o momento em que os resultados da simulação são interpretados com base em critérios científicos, contribuindo para a validação do modelo e a formulação de recomendações fundamentadas. A integração entre modelagem híbrida e aprendizado de máquina, aliada à aplicação rigorosa de métodos estatísticos e replicações experimentais, garante robustez às inferências produzidas e promove uma abordagem analítica transdisciplinar.

Com o protocolo metodológico delineado, compreendendo as fases de concepção, implementação e análise, parte-se para a seção 5, a qual apresenta a aplicação prática deste *framework* em um objeto de estudo real, no contexto da mobilidade urbana por transporte público.

5 MODELAGEM E SIMULAÇÃO DO OBJETO DE ESTUDO

5.1 Concepção do objeto de estudo

A aplicação da pesquisa foi realizada sobre o sistema de transporte público urbano por ônibus do município de Passos, localizado no interior do estado de Minas Gerais. O objetivo foi validar empiricamente o *framework* proposto na Seção 4 desta tese. A escolha do objeto de estudo se justifica por tratar-se de uma cidade de médio porte, com estrutura de transporte baseada em linhas circulares, com baldeações entre trajetos e com disponibilidade pública de dados operacionais.

Segundo dados do IBGE Cidades (2025, online), a cidade possui aproximadamente 116 mil habitantes e uma densidade demográfica de 83,66 habitantes por quilômetro quadrado. As informações utilizadas foram extraídas de fontes acessíveis ao público de forma gratuita, como os sítios eletrônicos da plataforma da Prefeitura Municipal de Passos (Passos, 2025, online; Passos2, 2025, online), da operadora CAF Transportes (2026, online) e do Cadastro Nacional de Endereços para Fins Estatísticos (CNEFE, 2022, online). Por serem plataformas públicas voltadas para a população, tem-se a confiança de sua confiabilidade.

Para a execução da etapa de concepção, seguiu-se o passo a passo descrito na Figura 7 e descritos nas subseções 5.1.1 a 5.1.11.

5.1.1 Objetivo e definição do sistema – Problema do transporte público a ser simulado e Propósito da MSH

Definiu-se o objeto de estudo como a cidade de Passos/MG, utilizando dados reais da administração pública e de sítios governamentais desta cidade brasileira de médio porte. A aplicação neste município busca demonstrar o potencial da MSH como ferramenta de apoio ao planejamento urbano em contextos do Sul Global. A escolha dele decorre de sua representatividade como cidade de médio porte em contexto latino-americano, caracterizada pela ausência de bases estruturadas de dados de mobilidade e de matrizes origem–destino. Tal condição reforça a pertinência metodológica do estudo, ao testar a aplicabilidade do modelo proposto em cenários com escassez de dados sistemáticos (situação predominante na maioria dos municípios brasileiros, conforme Pereira e Herszehhut (2023).

Identificou-se o número de linhas circulares e os respectivos pontos de parada por linha por meio do sítio virtual CAF Transportes (2026, online) do município. Estabeleceu-se o

desenvolvimento de um modelo computacional das múltiplas linhas de ônibus para os usuários do referido município, utilizando o software AnyLogic®. A questão central está em avaliar se tal configuração atende adequadamente às demandas da população e a busca pela racionalização da localização das estações de parada. Para tanto, integrou-se o modelo com algoritmos de aprendizado por reforço, tendo como critério de avaliação o indicador de acessibilidade das estações, visando aumentar a cobertura, o acesso e o número de usuários do sistema.

5.1.2 Planejamento do modelo – Definição do diagrama conceitual e simbologia

Para esta simulação, optou-se pela adoção combinada dos diagramas IDEF-Sim e de Estados. Segundo Leal *et al.* (2008), o IDEF-Sim é uma metodologia voltada à modelagem conceitual de sistemas com base na lógica de simulação, derivada da família IDEF (Integrated DEFinition), com foco na representação de eventos discretos. Já o Diagrama de Estados, de acordo com Campos (2021) e Harel (1987), é uma ferramenta gráfica que descreve os diferentes estados de um agente ou entidade em um sistema de simulação, bem como as transições entre eles, possibilitando também a representação de hierarquia, concorrência e comunicação.

A escolha por essa abordagem segue recomendações da literatura recente (Pessoa *et al.*, 2025; Silva, Lima e Alves, 2024; Castillo *et al.*, 2022a; Bae *et al.*, 2022; Ferreira Junior, Lima e Pinho, 2024). Já sua simbologia foi padronizada de acordo com os autores supracitados, sendo ilustrados na Figura 11 e na Figura 12.

Figura 11 - Simbologia IDEF-Sim

Elemento	Símbolo	Descrição
Entidade		Elementos a serem processados ou que irão sofrerem transformações no sistema (inputs a serem transformados).
Junções		Postos ou locais de trabalho onde a entidade sofrerá alguma ação.
Fluxo de entidade		Movimento de entrada e saída de entidades nas funções, indicando o percurso do processo.
Recursos		Elementos utilizados para movimentar ou executar ações na entidade dentro das funções (inputs transformadores).
Controles		Regras de ações de entidades ou de funções.
Regras de fluxos paralelos ou alternativos	& Regra E X Regra OU o Regra E/OU	Após esta junção, as rotas do fluxo de processo devem ser executados juntos; Após esta junção, as rotas do fluxo de processo devem divergir e buscar alternativas; Após esta junção, é permito que as rotas de fluxo de processo convirjam ou divirjam.
Movimentação		Deslocamento de uma entidade com tempo, espaço ou recurso físico definidos.
Informação explicativa		Caixa de explicações extras ao modelo.
Fluxo de entrada no sistema modelado		Ponto de partida do modelo, criando as entidades ou as inserindo no fluxo de um ambiente externo ao diagramado.
Ponto final do sistema		Fim da rota ou do fluxo do processo modelado.
Conexão com outra figura		Divide ou conecta o atual diagrama com outro distinto.

Fonte: Adaptado de Leal *et al.* (2008).

Figura 12 - Simbologia do diagrama de estados

Elemento	Símbolo	Descrição
Caixa de Estado		Identifica um período de tempo no qual o objeto ou agente está esperando ou executando uma ação.
Estado inicial		Ponto de início do diagrama ou de subdiagramas.
Final		Ponto de fim do diagrama ou de subdiaramas.
Transição ou fluxo		Representa a troca de um estado para o outro.
Condicional		Decisor de rota do processo ou fluxo, de acordo com argumento.

Fonte: Adaptado de Campos (2021) e Harel (1987).

5.1.3 Construção do fluxo SED

Foram definidos como eventos principais: a chegada e a saída dos ônibus nas estações de embarque e desembarque; e as operações de entrada e saída de passageiros nos ônibus. Especificamente, a entidade ônibus, ao se aproximar de um ponto de parada, entra em estado de espera em uma fila até que possa estacionar. Em seguida, são disparados os eventos de desembarque, seguido pelo embarque de novos passageiros, ambos sujeitos a tempos de serviço previamente parametrizados. Após a conclusão dessas operações, o ônibus retoma seu trajeto em direção à próxima estação ou segue para a garagem, conforme a lógica da linha programada.

A construção do fluxo SED foi fundamentada em dados e estruturas propostos por Liu *et al.* (2021), Challapalli (2024), Zhukov e Moroz (2021), Ferreira Junior, Lima e Pinho (2024) e Schmitt *et al.* (2021). Foram adotados os seguintes parâmetros: tempo de embarque e desembarque dos passageiros modelado por uma distribuição com valores mínimo de 1,5 segundos e máximo de 3,7 segundos, conforme AlHadidi e Rakha (2019), incorporando-os em uma triangular com moda de 2,0 segundos (Triang(1,5; 2,0; 3,7)) para este estudo; e filas de espera para ônibus e para passageiros foram consideradas de capacidade infinita, conforme Schmitt *et al.* (2021), e a fim de evitar bloqueios operacionais artificiais na simulação. O fluxo completo é representado graficamente pelo diagrama IDEF-Sim ilustrado na Figura 13.

Figura 13 - IDEF-Sim do agente ônibus na estação de parada

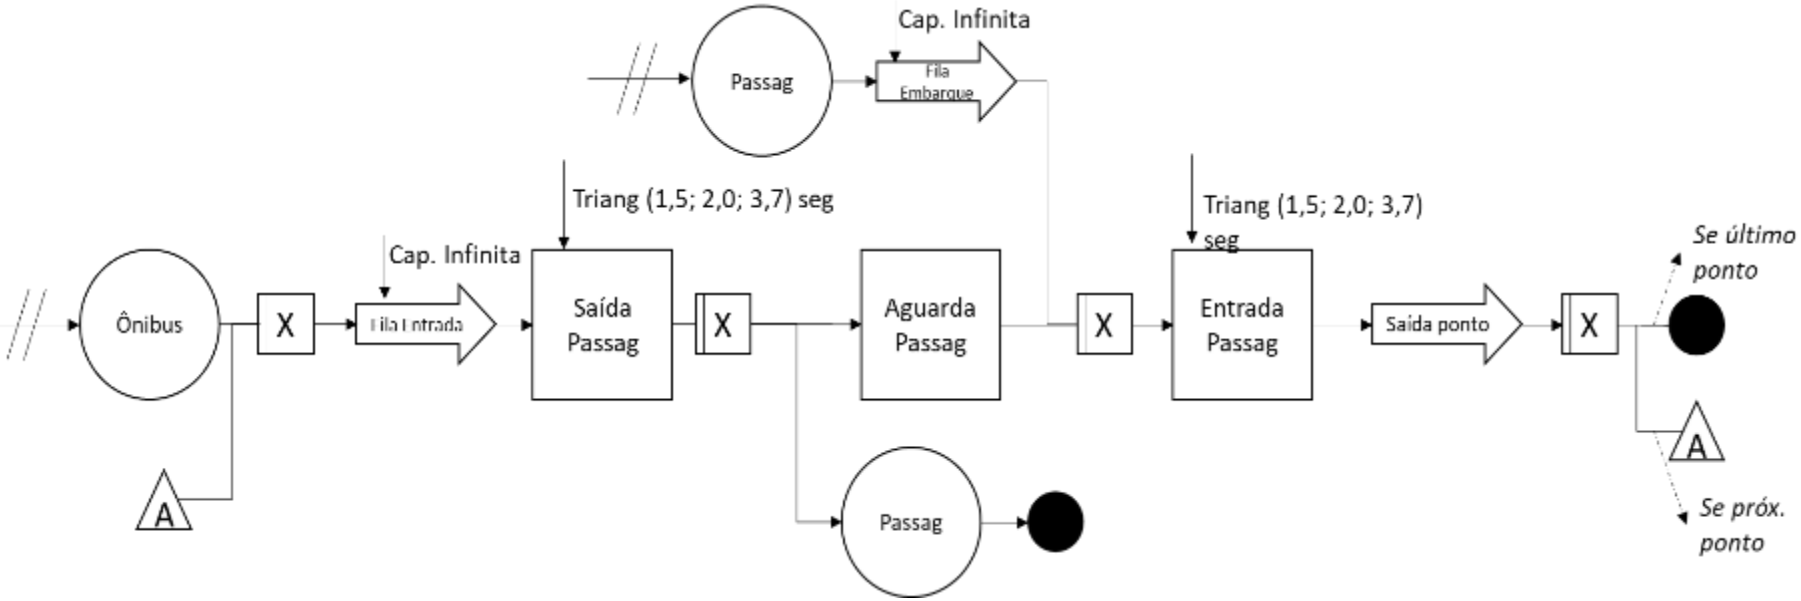

Fonte: Elaborado pelo autor (2026).

5.1.4 Construção do fluxo SBA – Agente Ponto de ônibus

Esta fase envolve a definição dos agentes a serem encapsulados, conforme discutido na Seção 2.2.2 e ilustrado na Figura 5. Foram selecionados quatro agentes principais, dentre os cinco propostos na Figura 8: passageiro (usuário); ônibus (veículo); ponto de ônibus (estação); e POIs, divididos em residência (casa), posto de trabalho, educação (escola) e outros responsável por guiar os planos de viagem dos passageiros. Todos os agentes operam dentro de um ambiente georreferenciado, por meio da API GIS do software AnyLogic®, com localizações fixas ou móveis conforme suas naturezas.

A modelagem inicia-se com o agente "Ponto de ônibus", conforme as etapas definidas na Figura 5 e referenciadas por Macal e North (2009) e Huang *et al.* (2022). Este agente representa os pontos de parada georreferenciados e suas funcionalidades de embarque e desembarque. No escopo desta tese, sua escala foi definida pelo número de pontos disponíveis na cidade, não sendo necessário incluir dimensões físicas (largura, altura ou comprimento), dada a natureza conceitual do modelo.

As características operacionais deste agente incluem filas de espera de capacidade infinita, tanto para os ônibus quanto para os passageiros, conforme definido previamente no fluxo SED (seção 5.1.3). Ambas as filas seguem a lógica FIFO (*first-in, first-out* – primeiro que entra, primeiro que sai), aplicada simultaneamente aos dois tipos de agentes no ponto de parada.

A principal variável de entrada deste agente corresponde à sua posição geográfica, obtida a partir de dados da empresa CAF Transportes (2026, online), que disponibiliza a localização das cinco linhas circulares da cidade. Os dados foram convertidos em coordenadas geográficas e tabulados no MsExcel® com as colunas do número da linha, número do ponto de ônibus, endereço e as coordenadas de latitude e de longitude.

As interações do agente ponto de ônibus ocorrem com os agentes ônibus e passageiros, conforme descrito no fluxo SED (Figura 13), além de sua integração com o ambiente GIS. Por se tratar de um ponto fixo com coordenadas pré-definidas, não foi necessária a calibração do modelo para este agente. A validação das regras de fila FIFO foi confirmada com base em observações *in loco* e validação por especialistas. O Quadro 18 resume os principais atributos e comportamentos encapsulados.

Quadro 18 - Resumo do agente Ponto de ônibus

Fase	Etapa	Descrição
Pré-Análise	Aplicações e Propostas	Representar as localizações dos pontos de ônibus; Executar ações de embarque e desembarque.
	Escala	Quantidade de pontos em cada rota (linha) de ônibus
	Resolução	Não se aplica
Definição do agente	Tipos	Agente individual; Comportamento autônomo; Interações com agentes e ambiente; Sem adaptabilidade.
	Características	Fila de entrada de ônibus no ponto do tipo FIFO; Fila de embarque do passageiro do tipo FIFO; Coordenada geográficas para cada ponto em cada rota.
Regras de modelagem	Comportamento e Interação	Entrada e saída do agente ônibus no ponto; Entrada e saída do agente passageiro no ponto; Localização no ambiente GIS.
Ajustes do modelo	Verificação e Validação	Observações de filas em pontos reais; Correspondência aos dados de arquivos para localização dos pontos.
	Calibração	Indireta, por meio de dados tabulados.

Fonte: Elaborado pelo autor (2026).

5.1.5 Construção do fluxo SBA – Agente ônibus

O segundo agente modelado é o “Ônibus”, responsável por representar os veículos em deslocamento na rede viária urbana, realizando embarques e desembarques ao longo de suas rotas. Foram atribuídos quatro ônibus por linha, com partidas programadas a partir da garagem e tempo entre partidas de 40 minutos, conforme dados da CAF Transportes (2026, online). A modelagem não considera resolução física (dimensões do veículo), por não ser requisito para os objetivos deste estudo.

Conforme o Quadro 8, os ônibus são modelados como agentes individuais e dinâmicos, com deslocamento contínuo no ambiente viário e interação direta com os agentes “ponto de ônibus” e “passageiro”. Apesar de não serem adaptativos, sua capacidade para 40 passageiros sentados condiciona a possibilidade de novos embarques.

A lógica de comportamento do agente “ônibus” é descrita no diagrama de estados apresentado na Figura 14. A jornada se inicia na garagem, cuja localização foi obtida por dados públicos (Passos, 2025, online). O primeiro estado é de movimentação (“movendo para próximo ponto”), com deslocamento por vias mapeadas pelo OSM até a primeira estação da linha. Ao chegar, o agente transita para o estado “no ponto de ônibus”, integrando-se ao fluxo de eventos SED (Figura 13). Após executar embarque e desembarque, o ônibus retoma o diagrama, deslocando-se à próxima estação ou retornando à garagem, conforme o fim da rota.

Figura 14 - Diagrama de estados do agente ônibus

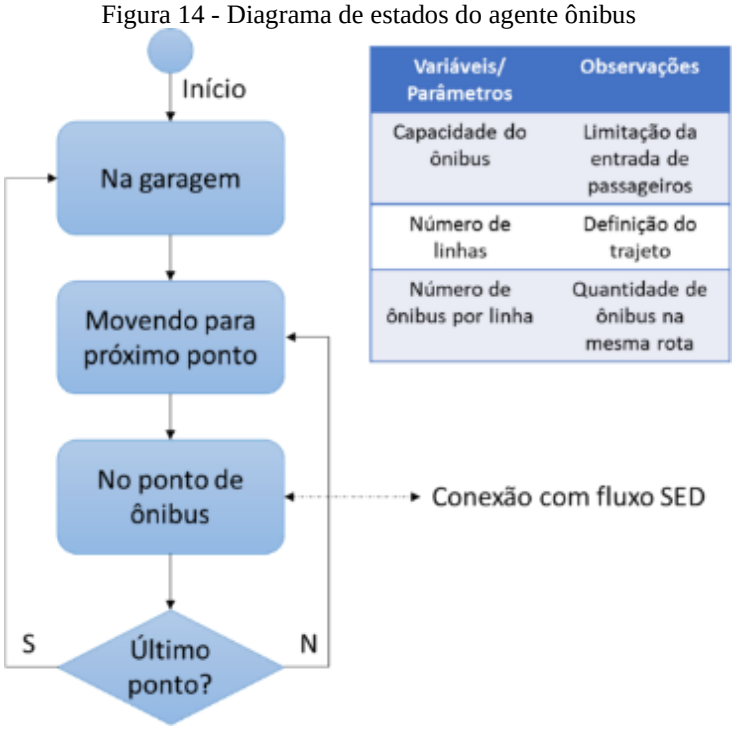

Fonte: Elaborado pelo autor (2026).

Os principais parâmetros do agente “ônibus” são: (i) capacidade de 40 passageiros, com embarque bloqueado quando lotado (dados da empresa); (ii) velocidade média de 14,6 km/h, conforme Toro-Gonzalez, Cantillo e Cantillo-Garcia (2020); (iii) número de linhas igual ao real (cinco), associado ao agente “ponto de ônibus”; (iv) número de veículos por linha: quatro ônibus por rota em dias úteis, com frequência de 40 minutos nas partidas; (v) horários de operação: das 5h00 às 23h15, segundo dados da CAF Transportes (2026, online).

Alguns parâmetros listados na Figura 8, como custo operacional e consumo de combustível, não foram incorporados ao modelo, em função do escopo e dos objetivos específicos desta pesquisa. Tais variáveis poderão ser incluídas em futuras extensões ou validações do protocolo proposto.

A validação do agente “Ônibus” foi conduzida com base em dados documentais da empresa CAF Transportes (2026, online) e em observações *in loco* dos padrões operacionais. O Quadro 19 sintetiza os principais atributos e comportamentos modelados.

Quadro 19 - Resumo do agente ônibus

Fase	Etapa	Descrição
Pré-Análise	Aplicações e Propostas	Veículo de deslocamento dentro da rede viária; Percurso entre um ponto de ônibus ao outro dentro de sua rota; Recebe usuários no embarque e o faz o desembarque em outro ponto.
	Escala	4 ônibus em cada uma das 5 linhas.
	Resolução	Não se aplica.
Definição do agente	Tipos	Agente individual; Comportamento dinâmico; Interações com agentes e ambiente; Com uma adaptabilidade sobre capacidade.
	Características	Horário de funcionamento entre 05h00mim e 23h15min; Partida da garagem e sequência dada pela rota de paradas; Velocidade: 14,6 km/h; Capacidade: 40 passageiros.
Regras de modelagem	Comportamento e Interação	Entrada e saída do agente ônibus no ponto; Entrada e saída do agente passageiro no ponto; Movimentação no ambiente GIS.
Ajustes do modelo	Verificação e Validação	Observações *in loco* comportamento; Dados de arquivos para horário e quantidade de agentes.
	Calibração	Indireta, por meio de dados tabulados.

Fonte: Elaborado pelo autor (2026).

5.1.6 Construção do fluxo SBA – Agente Pontos de Interesse

O terceiro agente modelado refere-se aos “Pontos de Interesse” (POIs), cuja função é interagir com os agentes passageiros, orientando a geração de seus planos de viagem. Foram instituídos quatro POIs para destino dos usuários, sendo eles: residências (casas); locais de trabalho; educação (escola); e outros para computar os demais, conforme exemplificado no Quadro 11 e apresentado por Rasca *et al.* (2024), Zhang *et al.* (2024) e Prédhumeau e Manley (2023). Como nos demais agentes fixos, dimensões físicas não foram consideradas, por não serem relevantes ao objetivo da simulação.

Para caracterização dos parâmetros destes agentes, foram utilizados dados do Cadastro Nacional de Endereços para Fins Estatísticos referentes ao ano de 2022 (CNEFE, 2022, online), que compreende domicílios e estabelecimentos georreferenciados. Inicialmente, foram extraídos 63.765 registros associados ao município de Passos/MG deste sítio virtual. Tais dados foram tabulados via MsExcel® com as colunas com o número do POI, seu tipo e suas coordenadas de latitude e longitude. Foram ainda filtrados para apenas o contexto urbano, excluindo coordenadas rurais.

Os agentes POIs são classificados como estáticos e autônomos, com interação exclusiva com os passageiros e localização fixa no ambiente GIS. Por não possuir dinâmica comportamental, não foi necessária a calibração; a validação foi realizada por conferência cruzada dos endereços coletados. O Quadro 20 resume suas principais características.

Quadro 20 - Resumo do agente Pontos de Interesse

Fase	Etapa	Descrição
Pré-Análise	Aplicações e Propostas	Gerar Pontos de Interesse para os planos de origem e destino dos usuários.
	Escala	Quantidade de POIs na zona urbana.
	Resolução	Não se aplica.
Definição do agente	Tipos	Agente individual; Comportamento estático e autônomo; Interações com agente passageiro; Sem adaptabilidade.
	Características	Localização por coordenadas GIS.
Regras de modelagem	Comportamento e Interação	Geração de plano de viagens com o agente usuário; Localização no ambiente GIS.
Ajustes do modelo	Verificação e Validação	Dados de arquivos sobre cada tipo de POI e observações dos autores.
	Calibração	Indireta, por meio de dados tabulados.

Fonte: Elaborado pelo autor (2026).

5.1.7 Construção do fluxo SBA – Agente Passageiro

O agente Passageiro representa indivíduos da população urbana cujas decisões de mobilidade influenciam o desempenho do sistema de transporte coletivo. Sua inclusão na MSH permite representar, em nível microscópico, a interação entre comportamento individual, infraestrutura urbana e operação do transporte público, possibilitando a análise de acessibilidade, escolha modal e utilização da rede de ônibus.

A população sintética foi construída a partir da população urbana estimada do município de Passos/MG, composta por aproximadamente 112 mil habitantes (IBGE Cidades, 2025). Os agentes foram gerados de forma probabilística, incorporando características sociodemográficas e comportamentais derivadas de bases oficiais e da literatura especializada. Incorporou-se ainda o filtro de 95% de habitantes urbanos sobre a população total, conforme EPTV 1 (2024, online). Como o objetivo do modelo está centrado na representação funcional dos deslocamentos, não foram consideradas características físicas ou visuais detalhados dos indivíduos.

O agente é classificado como heterogêneo, autônomo e interativo. Sua heterogeneidade decorre da atribuição probabilística de atributos individuais, enquanto sua autonomia está associada à capacidade de decidir sobre deslocamentos, utilização do transporte coletivo e seleção de rotas. Além disso, os agentes interagem continuamente com ônibus, pontos de parada, pontos de interesse e com o ambiente georreferenciado, permitindo o desenvolvimento de padrões coletivos de mobilidade.

A caracterização sociodemográfica baseou-se em dados censitários do IBGE (IBGE Cidades, 2025, online) e foi estruturada a partir da distribuição etária da população de Passos/MG, sintetizada na Tabela 1. Essa estrutura permitiu representar diferentes perfis

populacionais e associá-los a comportamentos específicos de mobilidade, conforme recomendações de Rasca *et al.* (2024), Kashiyama *et al.* (2024) e Simoni *et al.* (2019).

Tabela 1 - Atributo idade do agente Passageiro

Idade			Homens	Mulheres	Total	%
100	**ou**	**mais**	3	9	12	0,01%
95	**a**	**99**	24	67	91	0,08%
90	**a**	**94**	103	177	280	0,25%
85	**a**	**89**	316	463	779	0,70%
80	**a**	**84**	664	873	1.537	1,37%
75	**a**	**79**	1.147	1.394	2.541	2,27%
70	**a**	**74**	1.716	2.056	3.772	3,37%
65	**a**	**69**	2.403	2.778	5.181	4,63%
60	**a**	**64**	2.951	3.307	6.258	5,59%
55	**a**	**59**	3.401	3.805	7.206	6,44%
50	**a**	**54**	3.557	3.890	7.447	6,65%
45	**a**	**49**	3.606	3.885	7.491	6,69%
40	**a**	**44**	4.053	4.382	8.435	7,54%
35	**a**	**39**	3.987	4.094	8.081	7,22%
30	**a**	**34**	4.201	4.294	8.495	7,59%
25	**a**	**29**	4.201	4.238	8.439	7,54%
20	**a**	**24**	4.208	4.338	8.546	7,63%
15	**a**	**19**	3.645	3.433	7.078	6,32%
10	**a**	**14**	3.457	3.299	6.756	6,04%
5	**a**	**9**	3.431	3.451	6.882	6,15%
0	**a**	**4**	3.396	3.236	6.632	5,92%
TOTAL			**54.470**	**57.469**	**111.939**	
%			**48,66%**	**51,34%**	**100%**	

Fonte: Adaptado de IBGE Cidades (2025, online).

Ainda para a caracterização do agente passageiro, foram incluídos algumas classificações e parâmetros. Inicialmente cada passageiro foi alocado em um agente POI do tipo residência, parametrizando sua latitude e longitude de origem. Após isto foram elencados três tipos de passageiros: a população entre 5 e 18 anos foi denominada no tipo estudante, com destino dedicado ao POI de escola; a população entre 18 e 60 anos foi designada como tipo trabalhador, deslocando-se para o destino POI posto de trabalho; a população do tipo idosos, acima de 60, se locomovem para o destino POI do tipo outros; por fim, sem classificação e sem deslocamento, há a população com menos de 5 anos. Para cada um destes é armazenado a localização georreferenciada de seu destino. O Quadro 21 indica outros parâmetros e variáveis inclusos no agente passageiro.

Por fim, há o último parâmetro comportamental foi adicionado, incorporando o fato de o agente passageiro desejar ou não utilizar o sistema de transporte público por ônibus, sendo este uma das variáveis para calibração do modelo computacional. Lembra-se aqui, conforme objetivo do estudo, que foram considerados apenas dois modos de transporte, a caminhada e modo de transporte por ônibus.

Quadro 21 - Parâmetros e variáveis do agente Passageiro incorporados no objeto de estudo

Parâmetro	Valor	Fonte	Finalidade
Taxa de evasão escolar	0,5%	IBGE Notícias (2024, online).	Determinar estudantes inativos.
Taxa de desemprego	3,8%	Agência Minas (2025, online).	Determinar trabalhadores inativos.
Idosos Restritos ao domicílio	16,5%	Rodrigues *et al.* (2019) e Scimago (2016).	Determinar idosos inativos.
Velocidade a pé	N(5,04; 0,792)km/h	Liberto *et al.* (2020).	Deslocamento pedonal dos passageiros.
Distância máxima até o ponto	300m	Schmitt *et al.* (2021) e Ferreira Junior, Lima e Pinho (2024).	Distância máxima de deslocamento do passageiro para decidir ir ao ponto de embarque.
Distância máxima de transferência entre pontos de linhas distintas	100m	Hipótese operacional.	Distância máxima de deslocamento do passageiro para decidir ir ao ponto de transferência entre linhas.
Tempo mínimo de viagem	5min	Hipótese operacional.	Tempo mínimo para decisão do passageiro para trocar deslocamento pedonal para transporte por ônibus da origem até o destino.

Fonte: Elaborado pelo autor (2026).

Para representar o comportamento do agente, foram elaborados dois diagramas de estados. O primeiro, ilustrado na Figura 15, modela o processo de geração da matriz OD. Inicialmente todos os agentes passageiros são inseridos em um dos agentes POIs do tipo casa. Posterior, conforme regras, os tipos estudante, trabalhador e idoso incorporam um destino aleatório do tipo escola, trabalho e outros, respectivamente. Tal comportamento visa estruturar e armazenar de forma georreferenciada os pontos de origem e destino para todos que irão se locomover e também o tempo de deslocamento pedonal.

Já a Figura 16 modela o processo de locomoção do agente passageiro. Inicialmente, o agente recebe sua viagem da matriz OD recém desenvolvida de acordo com seu tipo (trabalhador, estudante ou idoso) e avalia a possibilidade de utilização do ônibus conforme restrições espaciais, temporais e probabilísticas. Caso a escolha do modo de transporte seja positiva, o usuário desloca-se ao ponto de embarque, realiza a viagem e desembarca no destino final ou em ponto intermediário de transferência, repetindo o processo quando necessário.

Após atingir o ponto de interesse, assume-se que o pressuposto a origem e o destino são constantes, ou seja, há a ida e há a volta do agente passageiro pelo mesmo roteiro apenas invertendo o ponto de partida, conforme trabalho de Zachos, Damoulas e Girolami (2024), descritos na Equação 2. Ao final da jornada, todos os agentes retornam ao domicílio. Os fluxos implementados permitem representar simultaneamente decisões individuais de mobilidade e restrições operacionais do sistema de transporte público.

Figura 15 - Diagrama de estados para Matriz OD do agente Passageiro

Variáveis/ Parâmetros	Observações
Idade	Distribuição etária via dados sociodemográficos
Latitude e Longitude da casa	Dados georreferenciados da localização da casa de cada agente
Latitude e Longitude do trabalho	Dados georreferenciados da localização do trabalho dos agentes tipo trabalhador com deslocamento.
Latitude e Longitude do escola	Dados georreferenciados da localização da escola dos agentes tipo estudante com deslocamento.
Latitude e Longitude do outros	Dados georreferenciados da localização dos outros POIs dos agentes tipo idoso com deslocamento.
Velocidade pedonal	N(5,04; 0,792) km/h.
Tempo de deslocamento	Cálculo do tempo de locomoção da origem ao destino.
Taxa de desemprego	3,8% do agente passageiro do tipo trabalhador.
Taxa de ausência escolar	0,5% do agente passageiro do tipo estudante.
Taxa de restrição de locomoção	16,5% do agente passageiro do tipo idoso.
Matriz OD	Coletânea de dados para formação da matriz com tipo de passageiro, georreferenciamento da origem e destino e tempo de deslocamento a pé entre eles.

Fonte: Elaborado pelo autor (2026).

Figura 16 - Diagrama de estados do passageiro para deslocamento com ônibus ou a pé

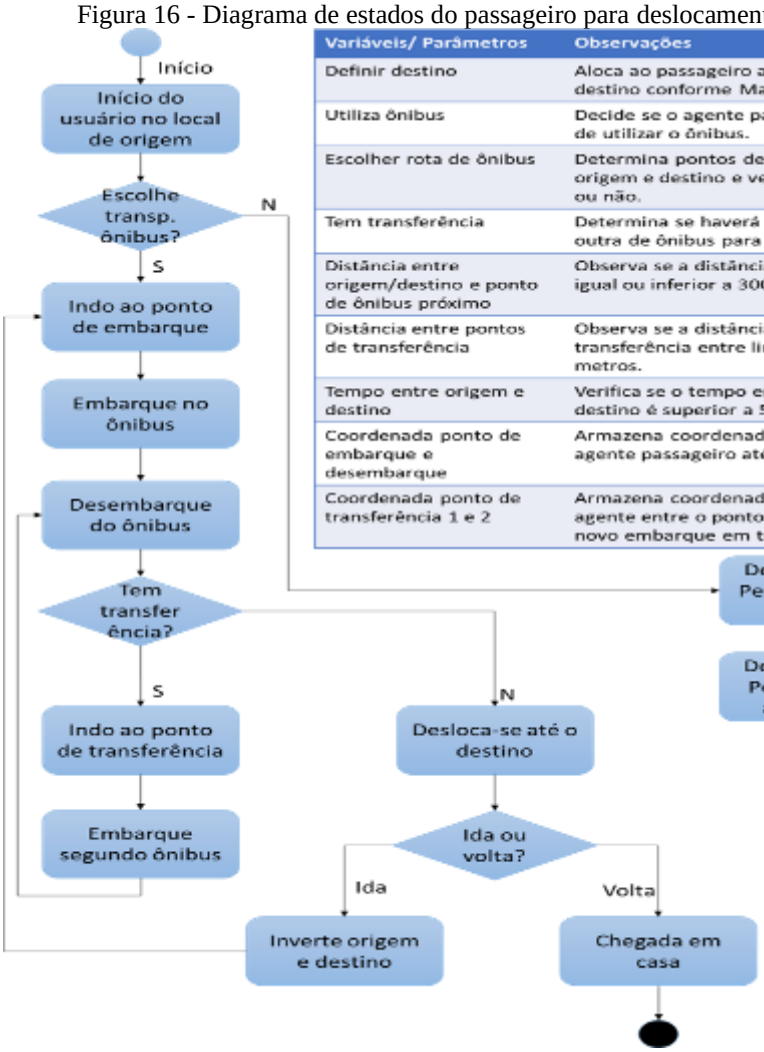

Variáveis/ Parâmetros	Observações
Definir destino	Aloca ao passageiro as coordenadas de origem e destino conforme Matriz OD.
Utiliza ônibus	Decide se o agente passageiro tem ou não o desejo de utilizar o ônibus.
Escolher rota de ônibus	Determina pontos de ônibus mais próximos da origem e destino e verifica se estão na mesma linha ou não.
Tem transferência	Determina se haverá transferência entre uma linha e outra de ônibus para chegar ao seu destino.
Distância entre origem/destino e ponto de ônibus próximo	Observa se a distância do POI de origem/destino é igual ou inferior a 300 metros ao ponto de ônibus.
Distância entre pontos de transferência	Observa se a distância dos pontos de ônibus de transferência entre linhas é igual ou inferior a 100 metros.
Tempo entre origem e destino	Verifica se o tempo entre o POI de origem e o POI de destino é superior a 5 minutos para ir de ônibus.
Coordenada ponto de embarque e desembarque	Armazena coordenadas para locomoção pedonal do agente passageiro até o ponto de ônibus.
Coordenada ponto de transferência 1 e 2	Armazena coordenadas para locomoção pedonal do agente entre o ponto de desembarque e o ponto de novo embarque em transferências entre linhas.

Fonte: Elaborado pelo autor (2026).

$$M = A_{++} = \sum_{i=1}^{I} A_{i+} = \sum_{j=1}^{J} A_{+j} \quad \text{Eq. (2)}$$

Onde: M é o agente; A é a matriz OD para cada agente; I a origem; e J o destino.

O agente Passageiro constitui o componente mais complexo do modelo, concentrando a maior parte das regras comportamentais e interações entre os subsistemas de SBA e SED. Sua validação conceitual foi realizada por face a face, técnica de *tracing* e comparação com evidências reportadas na literatura e na RSL realizada nesta pesquisa. Embora os parâmetros adotados tenham sido fundamentados em bases oficiais e estudos anteriores, futuras investigações podem incorporar levantamentos empíricos específicos, como pesquisas origem-destino e surveys de preferência declarada, visando refinar a representação comportamental dos usuários e ampliar a capacidade preditiva do modelo. O Quadro 22 sintetiza os principais atributos e regras do agente passageiro.

Quadro 22 - Resumo do agente Passageiro

Fase	Etapa	Descrição
Pré-Análise	Aplicações e Propostas	Persona com variabilidade comportamental. Toma decisão em seguir plano de viagens por meio de ônibus para viagens descritas em matriz OD segundo tipo de agente. Entende suas decisões em interação com outros agentes e com o ambiente.
	Escala	População urbana da cidade de Passos/MG.
	Resolução	Não se aplica.
Definição do agente	Tipos	Agente heterogêneo; Comportamento dinâmico e autônomo; Interações com todos os demais agentes e com o ambiente; Adaptável ao ambiente e às interações.
	Características	Atributos: idade; taxas de educação, trabalho ou reclusão; localização de POI de origem por residência e do POI de destino para escola, trabalho ou outros com georreferenciamento; determinação de locomoção por distância até o ponto de embarque; determinação de desejo de utilizar o transporte público por ônibus; avaliação de rota por ônibus com ou sem transferência entre linhas; retorno à origem após chegada ao destino.
Regras de modelagem	Comportamento e Interação	Embarque, desembarque e deslocamento com o agente ônibus; Decisão sobre ir ou não ao ponto de ônibus por distância e tempo de deslocamento; Movimentação no ambiente GIS.
Ajustes do modelo	Verificação e Validação	Dados da literatura, *tracing* e análise de especialistas.
	Calibração	Indireta, por meio de dados tabulados.

Fonte: Elaborado pelo autor (2026).

5.1.8 Coleta de dados

A construção dos agentes e dos parâmetros do modelo demandou a integração de múltiplas fontes de informação, conforme recomendado por Rasca *et al.* (2024), Liu *et al.*

(2021), Brailsford *et al.* (2019) e Macal (2016), que destacam a necessidade de combinar diferentes bases de dados para representar sistemas complexos de mobilidade. Foram utilizados dados públicos obtidos em bases governamentais e institucionais, incluindo informações demográficas, socioeconômicas, geográficas e operacionais disponibilizadas pelo IBGE, pela Prefeitura Municipal de Passos e pela concessionária responsável pelo transporte coletivo urbano.

Além das informações utilizadas na construção dos agentes, foram incorporados dados operacionais reais referentes à demanda do sistema de ônibus urbano. Esses registros foram fornecidos pela empresa operadora e compreendem o período de agosto a novembro de 2025. A escolha desse intervalo buscou minimizar efeitos sazonais associados a férias escolares, feriados prolongados e movimentações atípicas de final de ano, permitindo obter um retrato mais representativo da demanda média em dias úteis.

Os registros continham informações diárias de embarque por linha de ônibus e por categoria tarifária. Para os objetivos deste estudo, os passageiros foram agrupados em três segmentos: trabalhadores (dados sobre embarques pagos em dinheiro, cartão popular e vale-transporte), estudantes (dados sobre cartões estudantis) e idosos (dados sobre cartões de gratuidade para idosos). Essa classificação permitiu compatibilizar os dados observados com os perfis de agentes representados no modelo de simulação.

Inicialmente, foram removidos dos registros os finais de semana e feriados, mantendo-se apenas dias úteis de operação. Em seguida, realizou-se uma análise exploratória dos dados por meio de diagramas boxplot e gráficos de dispersão, com o objetivo de identificar observações atípicas que pudessem distorcer a caracterização estatística da demanda, conforme preceitos de (Montgomery; Runger, 2013). Os procedimentos foram executados no software Minitab® para cada linha de ônibus e para cada categoria de usuário.

A Figura 17 apresenta, a título de exemplo, os resultados obtidos para a Linha 1. Observa-se a presença de valores discrepantes associados a eventos excepcionais de operação ou demanda. Tais observações foram avaliadas e removidas quando caracterizadas como desvios não representativos do comportamento regular do sistema. Após essa etapa, foram calculadas as médias e os desvios-padrão amostrais dos embarques por linha e por perfil de passageiro.

Figura 17 - Boxplot e gráfico de dispersão dos dados de embarque da Linha 1

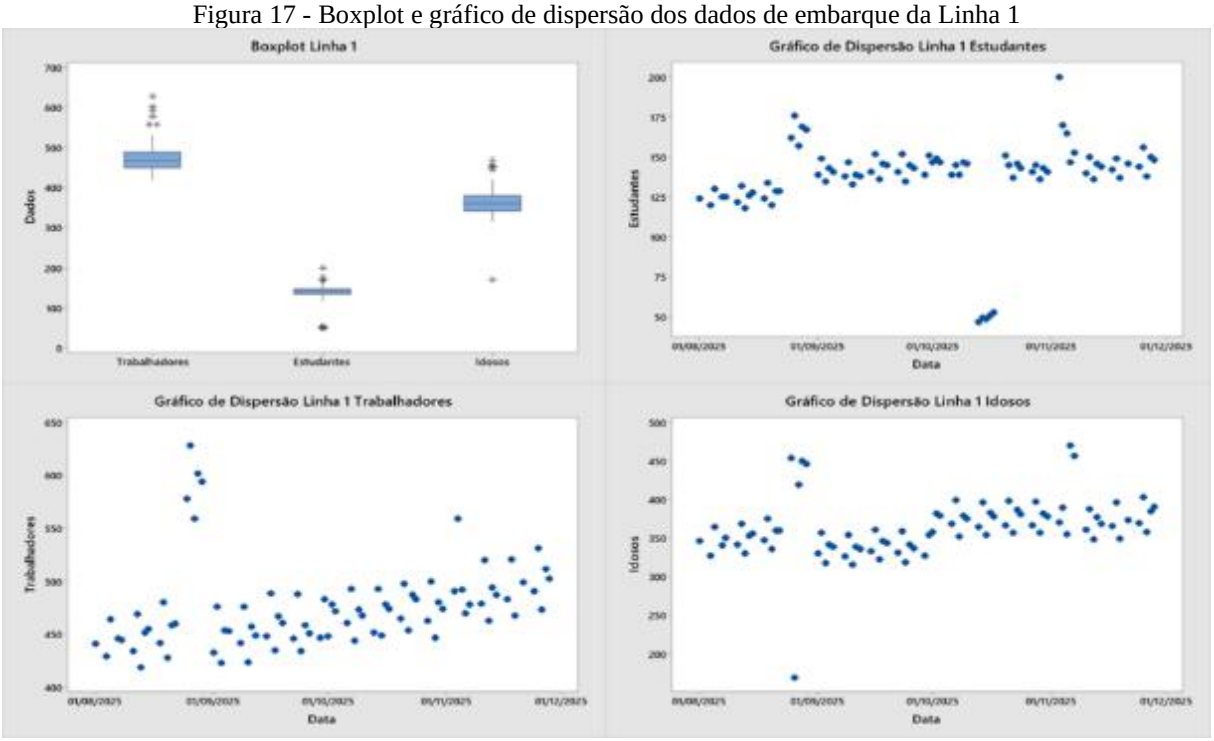

Fonte: Elaborado pelo autor (2026).

A Tabela 2 exemplifica a base de dados consolidada para a Linha 1 após os procedimentos de tratamento estatístico. Já a Tabela 3 apresenta as estatísticas descritivas finais para todas as linhas e categorias de usuários. Esse conjunto de informações constituiu a principal referência empírica utilizada nas etapas posteriores de calibração e validação do modelo computacional, descritas na seção 5.2.

Tabela 2 - Exemplo de dados após filtros para a Linha 1

N.	Trabalhadores	Estudantes	Idosos
1	419	118	316
2	423	120	317
3	424	120	318
4	428	122	322
5	429	124	326
6	433	124	327
7	434	125	327
...	...	...	...
72	499	157	396
73	500	162	396
74	503	165	397
75	512		398
76	520		399
77	521		403
78	531		419
Média	466,76	140,69	359,95
Desvio Padrão amostra	24,16	9,78	22,78

Fonte: Elaborado pelo autor (2026).

Tabela 3 - Média e Desvio Padrão Amostral do número de usuários por linha

		Linha				
Tipo	**Estatística**	**1**	**2**	**3**	**4**	**5**
Trabalhadores	Média	466,76	546,33	205,59	547,87	295,59
Trabalhadores	Desvio Padrão Amostral	24,16	65,22	14,72	97,41	21,08
Estudantes	Média	140,69	258,19	181,48	92,00	60,12
Estudantes	Desvio Padrão Amostral	9,78	53,87	24,20	20,64	16,11
Idosos	Média	359,95	494,58	181,77	438,64	280,82
Idosos	Desvio Padrão Amostral	22,78	83,27	13,90	78,51	26,39

Fonte: Elaborado pelo autor (2026).

5.1.9 Processo de integração SED e SBA

A convergência entre agentes, ambiente e processos também foi construída ao longo das etapas anteriores. Adicionalmente, foi incorporado o indicador de desempenho de acessibilidade (A_i), conforme Ingram (1971) e Bracarense e Ferreira (2018), cuja formulação adaptada para esta tese é apresentada na Equação 3.

$$A_i = \sum_j^n \frac{f(c_{ij})}{O_j} \qquad \text{Eq. (3)}$$

Onde A_i representa a acessibilidade da estação i em relação aos agentes ou POIs j; O_j corresponde à oportunidade associada ao destino (neste estudo, os POIs ponderados por tipo de agente); c_{ij} é o custo de deslocamento entre i e j, expresso em tempo (minutos), ; e $f(c_{ij})$ é a função de impedância que reduz a acessibilidade conforme o custo aumenta. O termo n indica o número total de agentes e POIs considerados no modelo. Assim, o ponto mais acessível é aquele que apresenta a menor soma agregada de esforço para ser alcançado.

Neste trabalho, propõe-se que o algoritmo de aprendizado de máquina (mais especificamente técnicas por reforço) utilize o valor do indicador de acessibilidade de Ingram (1971) como variável dependente ou função de recompensa, a ser minimizada em relação a um conjunto de variáveis explicativas que representam atributos físicos, operacionais e socioespaciais dos pontos de ônibus existentes. Cada ponto de parada será tratado como uma instância do modelo, e seu escore de acessibilidade servirá como base para treinamento, calibração e validação dos algoritmos.

Dessa forma, o modelo computacional vem a ser capaz de aprender padrões espaciais e operacionais que contribuem para elevados níveis de acessibilidade, possibilitando tanto a identificação de pontos ineficientes quanto a proposição de novas localizações que otimizem ou melhorem o acesso da população aos serviços de transporte coletivo. Ao incorporar tal indicador à lógica de aprendizado da máquina, busca-se aliar o rigor teórico dos modelos

clássicos de acessibilidade à capacidade adaptativa e exploratória das técnicas contemporâneas de inteligência artificial.

5.1.10 Validação do modelo conceitual

A validação conceitual foi conduzida conforme as recomendações de Sargent (2020), utilizando-se as técnicas de face a face, *tracing* e comparação com dados e conhecimentos previamente estabelecidos na literatura. O objetivo dessa etapa foi verificar se a estrutura lógica do modelo, suas premissas, entidades, relacionamentos e fluxos representavam adequadamente o sistema real de transporte coletivo urbano estudado.

A validação face a face foi realizada junto a especialistas com conhecimento em mobilidade urbana, transporte coletivo e modelagem de sistemas. Os diagramas conceituais, fluxos de processos e mecanismos de interação entre os agentes foram apresentados e discutidos, permitindo avaliar a coerência da estrutura proposta com o funcionamento observado do sistema real. As observações obtidas foram utilizadas para ajustes e refinamentos do modelo conceitual antes da implementação computacional.

A técnica de *tracing* foi empregada para verificar qualitativamente a sequência lógica dos eventos e das interações representadas. Foram analisados os percursos dos diferentes tipos de agentes, desde sua criação e caracterização nos respectivos POIs, passando pelos deslocamentos na rede urbana, processos de embarque e desembarque, possíveis transferências entre linhas e chegada aos destinos finais. Esse procedimento permitiu identificar inconsistências lógicas e confirmar a aderência dos fluxos modelados aos comportamentos esperados.

Por fim, realizou-se a comparação do modelo conceitual com informações provenientes da literatura especializada, da RSL e das bases de dados utilizadas na pesquisa. As entidades, variáveis, relações e processos incorporados aos componentes da SBA e SED foram confrontados com estudos anteriores e dados empíricos disponíveis, aumentando a confiabilidade da representação conceitual proposta.

5.1.11 Documentação do modelo conceitual

Com base em todas as definições, estruturas e relações discutidas, a Figura 18 apresenta uma versão consolidada do modelo conceitual, integrando, em um único diagrama, elementos do IDEF-Sim e do Diagrama de Estados. Essa convergência permite representar, de forma

holística, tanto o fluxo de processos discretos quanto os comportamentos dinâmicos dos agentes, assegurando maior coerência à modelagem proposta. Conclui-se, assim, a etapa de concepção do modelo de simulação híbrida (MSH), utilizada como referência na aplicação desenvolvida neste estudo.

5.2 Implementação do objeto de estudo

5.2.1 Conceitos de Design

A etapa de conceitos de design descreve os mecanismos comportamentais e estruturais que governam o funcionamento do modelo híbrido. Conforme disposto Grimm *et al.* (2006) na seção 4.2, essa etapa contempla onze conceitos responsáveis por explicar como os agentes percebem o ambiente, tomam decisões, interagem entre si e produzem os padrões emergentes observados durante a simulação.

No primeiro item, princípios básicos, o modelo representa o sistema de transporte público urbano de Passos/MG por meio da integração entre SBA, SED, RL e o indicador de acessibilidade. A SBA é responsável pela representação dos usuários, ônibus, pontos de parada e pontos de interesse, enquanto a SED modela os processos operacionais de embarque, desembarque, transferência e circulação dos veículos.

O ambiente de simulação é constituído por uma rede viária georreferenciada obtida a partir do OpenStreetMap. Sobre essa infraestrutura encontram-se distribuídos os agentes Passageiro, Ônibus, Ponto de Ônibus e os pontos de interesse (Casa, Trabalho, Escola e Outros), os quais interagem continuamente durante a execução da simulação. A dinâmica temporal combina deslocamentos contínuos sobre a rede urbana e eventos discretos associados às operações do sistema de transporte.

No segundo conceito, de emergência, ressaltam-se os principais fenômenos emergentes do modelo decorrem da interação simultânea entre milhares de passageiros, pontos de ônibus, veículos e destinos urbanos. Embora cada agente execute regras de comportamento simples, as interações coletivas produzem padrões globais observáveis, como níveis de demanda por linha, distribuição espacial dos embarques e desembarques, utilização dos pontos de parada, tempos médios de deslocamento e indicadores de acessibilidade urbana. Esses resultados não são definidos explicitamente pelo modelador, mas surgem da dinâmica do sistema ao longo das execuções da simulação, caracterizando propriedades emergentes típicas de sistemas de transporte urbano.

Figura 18 - Modelo conceitual completo

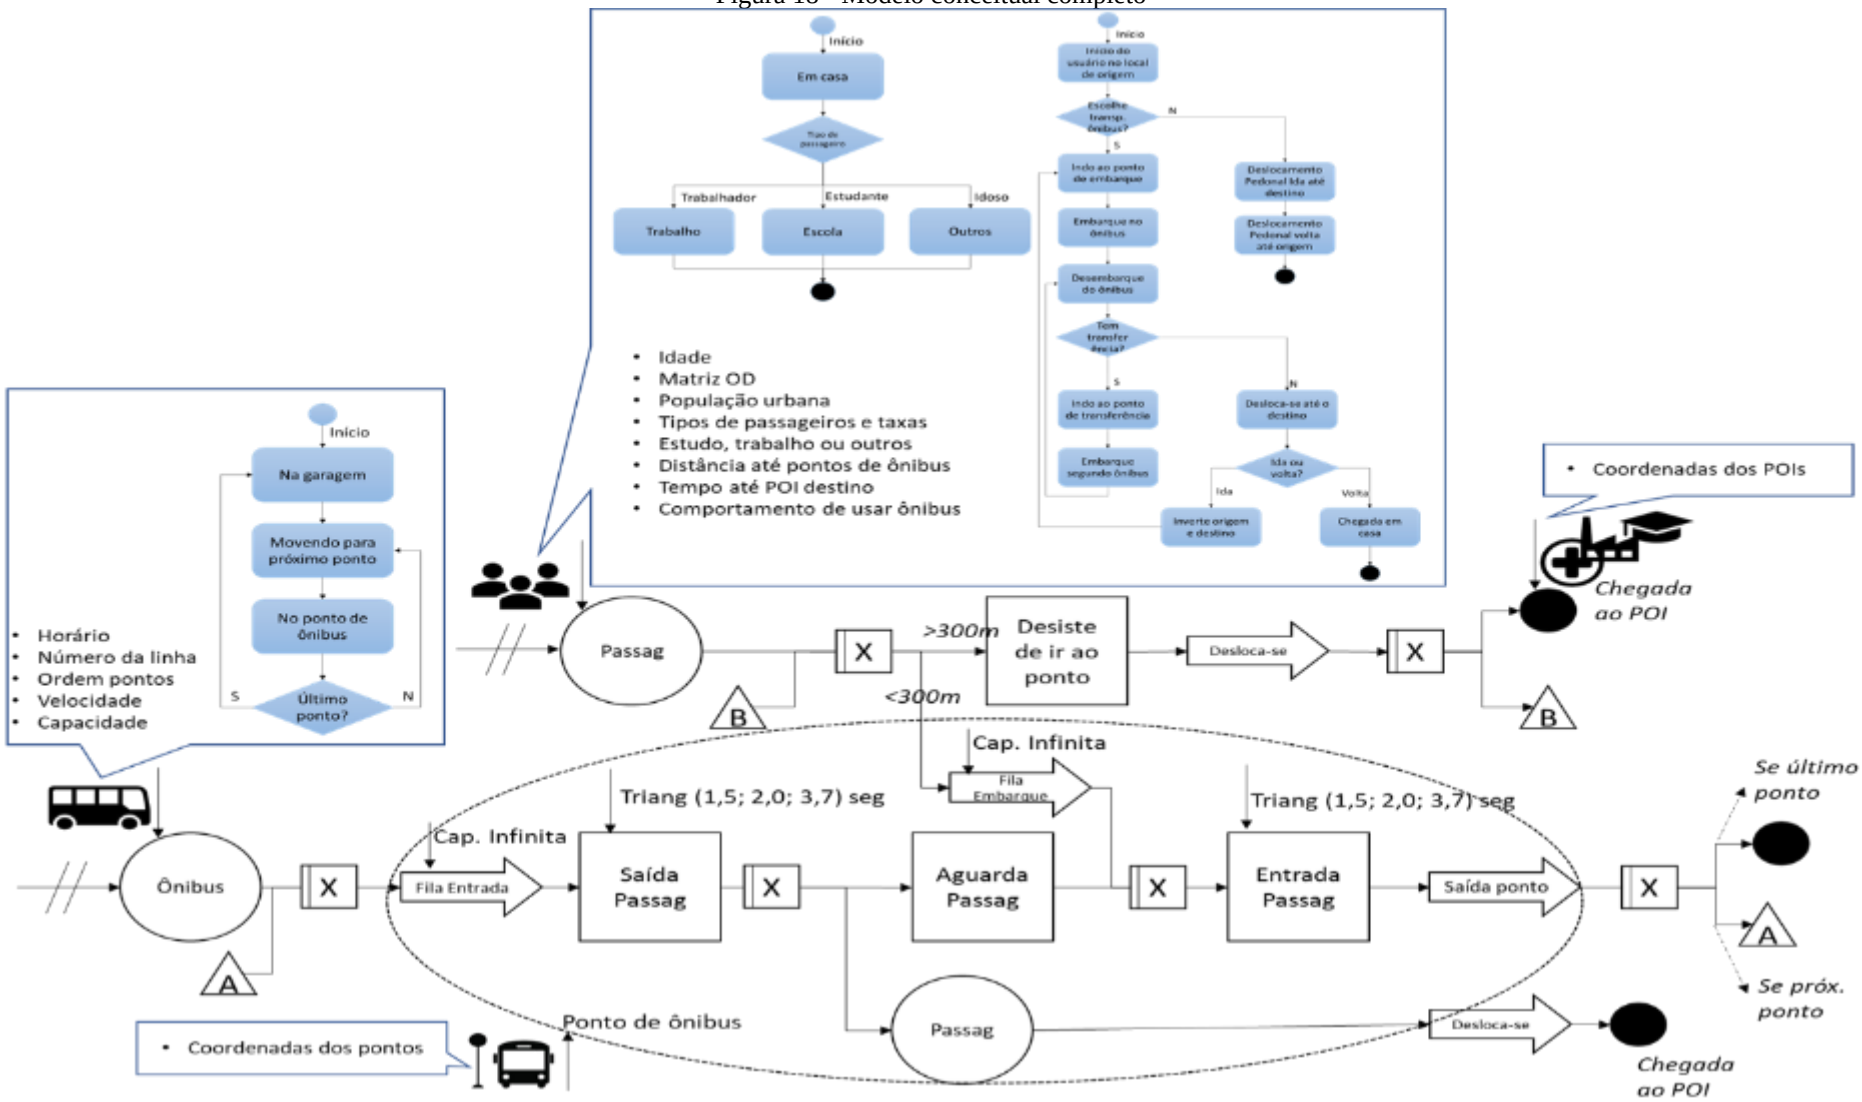

Fonte: Elaborado pelo autor (2026).

Para o terceiro item, de adaptação, os passageiros adaptam suas decisões de deslocamento de acordo com as oportunidades de transporte disponíveis no ambiente. A existência de pontos de embarque, desembarque e transferência determina a viabilidade do uso do transporte coletivo, enquanto as probabilidades de escolha modal associadas a cada perfil de usuário influenciam a decisão final. Quando necessário, os agentes selecionam rotas com transferência visando minimizar a distância percorrida.

Sobre o item de objetivo, quarto elencado por Grimm *et al.* (2006) para a composição do conceito de design, cada agente possui objetivos específicos dentro do sistema. Os passageiros buscam alcançar seus destinos utilizando transporte coletivo ou deslocamento pedonal, enquanto os ônibus percorrem continuamente os itinerários associados às suas linhas. Em nível sistêmico, o modelo procura reproduzir os padrões observados de utilização do transporte coletivo e avaliar os impactos da configuração da rede sobre os indicadores de acessibilidade urbana.

Sobre o item cinco, de aprendizado, o modelo até aqui apresentado não o possui, mas a arquitetura do *framework* foi concebida para permitir a integração com o algoritmo de TL baseado em *Q-Learning*, possibilitando que os agentes pontos de ônibus aprendam políticas de decisão capazes de alterar suas posições georreferenciadas a fim de racionalizar o indicador de acessibilidade observados no sistema.

O sexto elemento desta seção é sobre a predição. Os atuais agentes não realizam previsões explícitas sobre estados futuros do sistema. As decisões são tomadas com base nas informações disponíveis no instante da escolha, considerando a localização dos pontos de ônibus, a existência de rotas viáveis e os parâmetros associados à utilização do transporte coletivo.

Sobre o sensoriamento, os agentes possuem capacidade limitada de percepção do ambiente. Cada passageiro conhece a localização de seus pontos de origem e destino, além dos pontos de ônibus acessíveis dentro dos limites espaciais previamente definidos pelo modelo. A partir dessas informações, identifica possíveis trajetos utilizando transporte coletivo caso esteja apto para isto ou decide se locomover a pé. Já os ônibus percebem apenas os pontos pertencentes à sua linha operacional, enquanto os pontos de parada detectam a presença de passageiros aguardando embarque e de veículos disponíveis para atendimento.

O oitavo item é a interação. As interações entre agentes constituem o principal mecanismo de funcionamento do modelo. Passageiros interagem com pontos de ônibus durante os processos de embarque, desembarque e transferência. Os ônibus interagem com os pontos de parada ao longo de suas rotas, possibilitando o transporte dos usuários entre diferentes

regiões da cidade. Adicionalmente, todos os agentes interagem com o ambiente geográfico representado pela rede viária urbana, que determina os caminhos disponíveis para deslocamento e influencia diretamente os níveis de acessibilidade observados no sistema.

O antepenúltimo elemento refere-se a estocasticidade. Diversos componentes do modelo apresentam natureza estocástica, permitindo representar a variabilidade observada na população e no sistema de transporte real. Entre eles destacam-se a distribuição etária dos passageiros, as condições associadas ao desemprego, analfabetismo e restrição domiciliar, a escolha dos destinos nas categorias trabalho, escola e outros, as velocidades individuais de deslocamento e as probabilidades de utilização do transporte coletivo por perfil de usuário. Esses elementos probabilísticos introduzem heterogeneidade ao comportamento dos agentes, contribuindo para uma representação mais realista dos padrões de mobilidade urbana.

Os parâmetros estocásticos utilizados foram obtidos a partir de dados oficiais, informações operacionais do sistema de transporte público e evidências reportadas na literatura especializada. Dessa forma, as distribuições de probabilidade empregadas no modelo procuram reproduzir características demográficas, espaciais e comportamentais observadas no município de Passos/MG, fornecendo variabilidade suficiente para a realização dos experimentos e análises propostos nesta pesquisa.

Na etapa de coletividade, os principais coletivos do modelo são formados pelos grupos de passageiros classificados como trabalhadores, estudantes e idosos, cada um apresentando padrões específicos de mobilidade e utilização do transporte coletivo. Adicionalmente, durante a execução da simulação formam-se coletivos temporários de passageiros embarcados em um mesmo veículo ou aguardando atendimento em um mesmo ponto de parada.

Por fim, o último elemento proposto por Grimm *et al.* (2006) é a observação. O modelo registra continuamente indicadores operacionais e espaciais para análise posterior, incluindo número de embarques por linha, quantidade de usuários transportados por categoria, utilização dos pontos de parada, tempos de deslocamento, distâncias percorridas e níveis de acessibilidade. Também são monitoradas métricas de calibração, permitindo comparar os resultados simulados com os dados reais coletados no sistema de transporte de Passos/MG e subsidiar os processos de validação e experimentação do modelo.

5.2.2 Construção do modelo programado

O modelo foi implementado no software AnyLogic PLE 8.9.7®, utilizando programação orientada a agentes integrada aos componentes GIS e Process Modeling Library.

Os experimentos computacionais foram executados em computador equipado com processador Intel® Core™ i7-9750H e 16 GB de memória RAM.

O ambiente computacional foi estruturado sobre uma base georreferenciada da área urbana do município de Passos/MG, utilizando o componente GIS Map do AnyLogic® integrado aos dados da plataforma OpenStreetMap. Essa estrutura permitiu representar explicitamente ruas, distâncias, localizações de pontos de ônibus e pontos de interesse urbanos, possibilitando que todos os deslocamentos fossem realizados sobre uma rede espacial real. Incorporou-se a isto a limitação da área urbana da cidade, por meio de ferramenta interna do software denominada *region*.

A primeira etapa da implementação consistiu na criação da população sintética de passageiros, conforme seção 5.1.7. Foram gerados aproximadamente 106.400 agentes, correspondentes à população urbana estimada do município após a exclusão dos setores rurais identificados em EPTV 1 (2024, online). Cada agente recebeu atributos individuais relacionados à idade, localização domiciliar, destino potencial e características comportamentais. A distribuição etária foi construída a partir dos dados do IBGE Cidades (2025, online), sendo implementada por meio de uma distribuição probabilística customizada capaz de reproduzir a pirâmide etária observada no município. A seção 5.2.4 apresenta a comparação estatística para validação desta população sintética sobre a população censitária.

Além do agente passageiro, foram implementadas as populações georreferenciadas representando residências, escolas, postos de trabalho e outros pontos de interesse urbanos. Essas informações foram obtidas a partir do CNEFE (2022, online), tabulados via Microsoft Excel® e exportados para o software AnyLogic®. A Tabela 4 exemplifica tais grupos tabulados. Foi executado o filtro de pertencimento das coordenadas geográficas urbanas, conforme *region*. Ao final do processo de tratamento dos dados, foram mantidos mais de cinquenta mil pontos geográficos distribuídos entre as categorias Casa, Trabalho, Escola e Outros, os quais passaram a compor os destinos potenciais dos agentes principais.

O comportamento dos passageiros foi modelado por meio de diagramas de estados. Inicialmente cada indivíduo era associado aleatoriamente a um domicílio. Em seguida, de acordo com sua faixa etária e características socioeconômicas, o agente passava a selecionar um destino principal. Usuários em idade economicamente ativa eram direcionados preferencialmente para postos de trabalho, estudantes para instituições de ensino e idosos para outros pontos de interesse urbanos. Durante esse processo foram incorporadas taxas de desemprego, analfabetismo e restrição de mobilidade física obtidas em bases oficiais, permitindo representar situações em que determinados indivíduos não realizam deslocamentos.

Tabela 4 - Exemplo dos dados georreferenciados dos POIs e seus tipos

N. POI	Latitude do Endereço	Longitude do Endereço	Espécie de endereço CNEFE	Tipo Encapsulado
1	-20,696811	-46,612545	Domicílio particular	Casa
2	-20,707483	-46,63313	Domicílio particular	Casa
...	...	...	...	...
4211	-20,720331	-46,629169	Estabelecimento de ensino	Escola
4212	-20,719379	-46,581285	Estabelecimento de ensino	Escola
...	...	...	...	...
4243	-20,715839	-46,625878	Estabelecimento de outras finalidades	Trabalho
4244	-20,744348	-46,601699	Estabelecimento de outras finalidades	Trabalho
...	...	...	...	...
4827	-20,715063	-46,616586	Estabelecimento de saúde	Outro
4828	-20,726320	-46,604308	Estabelecimento de saúde	Outro
...	...	...	...	...
57399	-20,712604	-46,622017	Estabelecimento religioso	Outro
57400	-20,723830	-46,685097	Estabelecimento religioso	Outro

Fonte: Elaborado pelo autor (2026).

Os deslocamentos preliminares entre origem e destino foram utilizados para gerar a matriz OD sintética do município. Para cada viagem foram registrados tempo de deslocamento, coordenadas de origem e destino e perfil do usuário, formando a base de dados utilizada nas etapas subsequentes do modelo. A Figura 19 ilustra este primeiro passo de construção com o diagrama de estados e a animação do software de simulação, enquanto a Tabela 5 apresenta um exemplo desta matriz.

Tabela 5 - Exemplo da Matriz OD gerada por simulação

Passageiro	Idade	Tipo	Lat. Origem	Long. Origem	Lat. Destino	Long. Destino	Tempo Desloc. (min)
0	16	Estudante	-20,7088	-46,6237	-20,7247	-46,6121	26,7474
1	79	Idoso	-20,7136	-46,6103	-20,7201	-46,6089	17,25474
2	31	Trabalhador	-20,7069	-46,6044	-20,7206	-46,6094	26,39719
3	8	Estudante	-20,72	-46,6257	-20,727	-46,6134	22,99799
4	25	Trabalhador	-20,7149	-46,6132	-20,7238	-46,6094	14,97469
6	37	Trabalhador	-20,7079	-46,6067	-20,7254	-46,6117	25,4682
7	45	Trabalhador	-20,7153	-46,6076	-20,7046	-46,6025	15,55952
8	12	Estudante	-20,7169	-46,604	-20,7247	-46,6121	18,31997
9	26	Trabalhador	-20,7387	-46,605	-20,7088	-46,6261	46,78819
10	65	Idoso	-20,7336	-46,6203	-20,7152	-46,6153	32,49766
11	8	Estudante	-20,7284	-46,6158	-20,727	-46,6134	2,983218
12	27	Trabalhador	-20,7555	-46,602	-20,7198	-46,6042	43,78803
13	39	Trabalhador	-20,7168	-46,6367	-20,7223	-46,6343	8,268151
14	37	Trabalhador	-20,7152	-46,6272	-20,7288	-46,6096	28,01256
15	54	Trabalhador	-20,7527	-46,5997	-20,7185	-46,6111	48,49712

Fonte: Elaborado pelo autor (2026).

Figura 19 - Fluxo de comportamentos do agente Passageiro para construção da Matriz OD

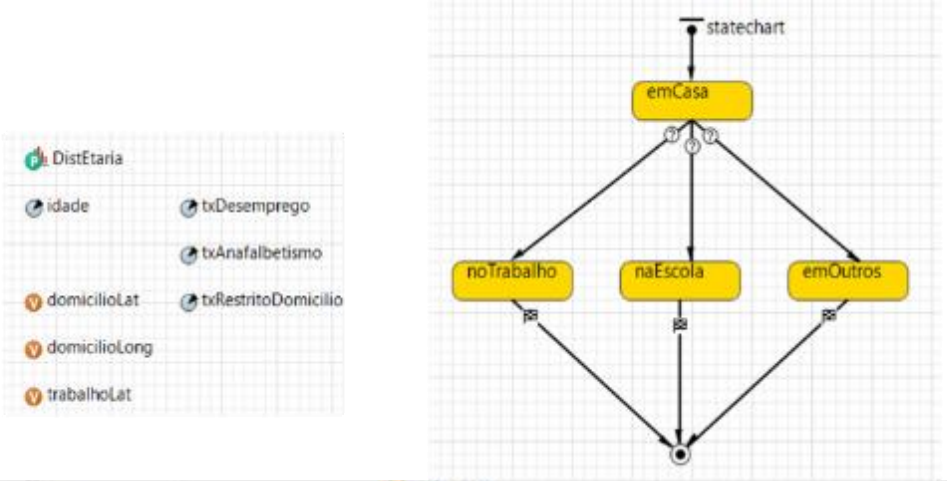

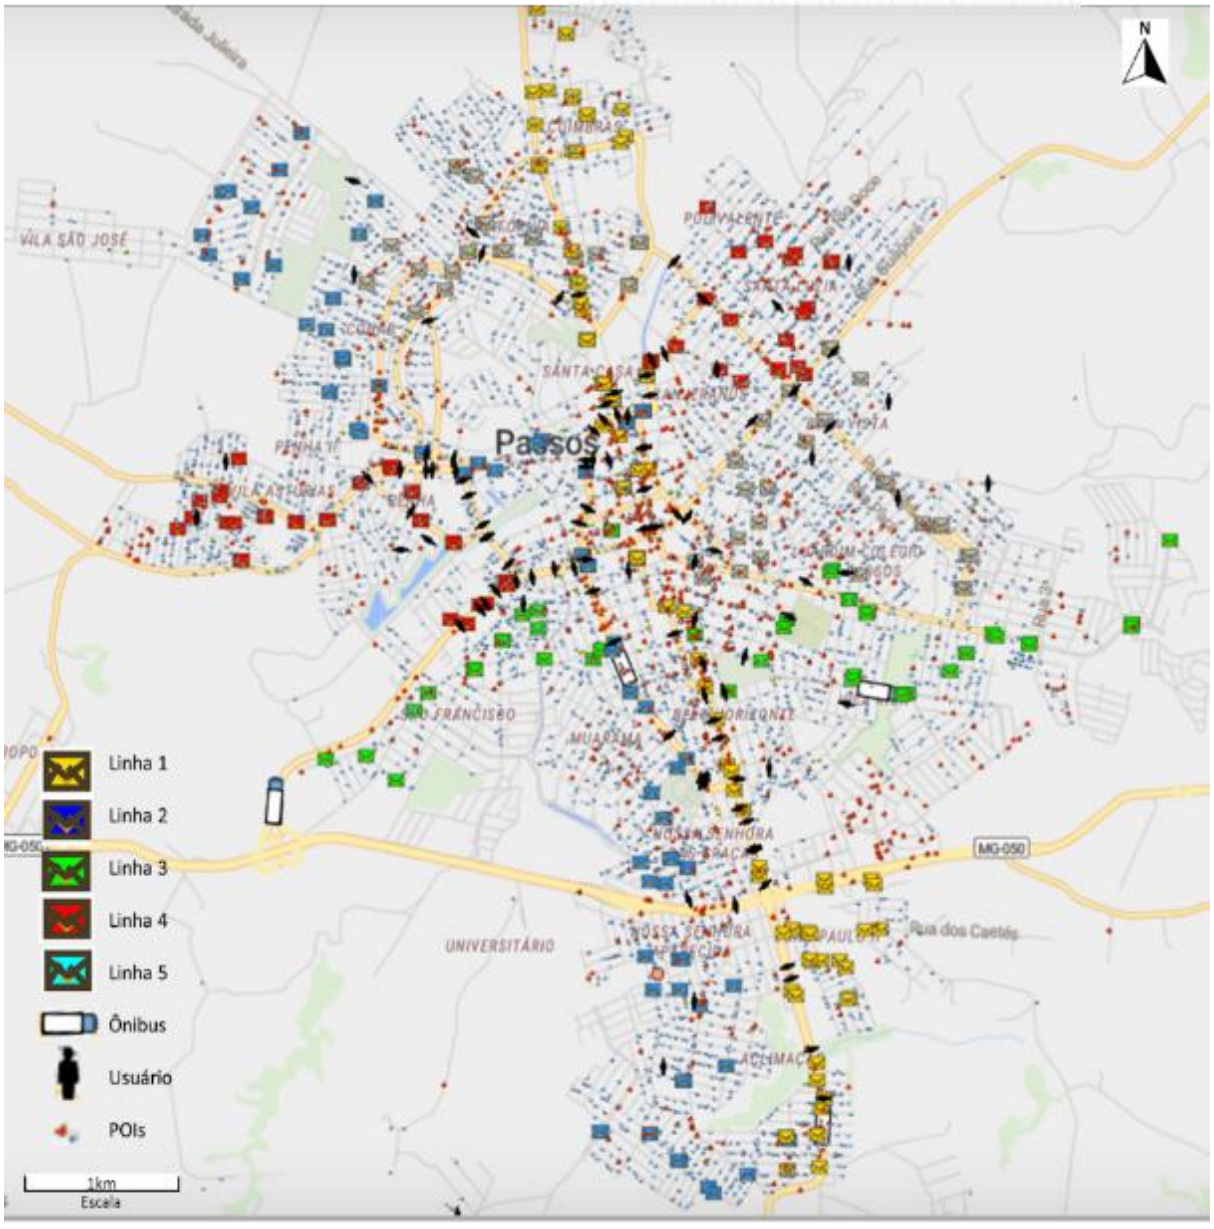

Fonte: Elaborado pelo autor (2026).

Paralelamente à implementação dos usuários, foi construída a infraestrutura do sistema de transporte coletivo. Foram inseridos todos os pontos de parada existentes na rede municipal, utilizando coordenadas geográficas fornecidas pela empresa operadora do sistema. Cada ponto de ônibus recebeu atributos relacionados à linha atendida, posição sequencial na rota e localização espacial. Para facilitar a visualização do modelo, diferentes cores foram utilizadas para representar as cinco linhas de transporte consideradas na pesquisa. A Tabela 6 apresenta um exemplo do arquivo tabulado das linhas com suas respectivas colunas.

Tabela 6 - Exemplo tabulação ponto de ônibus

Linha	N. Ponto	Endereço	Lat	Long
1	1	Rua Opala, 391, Passos/MG	-20,7552	-46,6007
1	2	Praça Coral, 340, Passos/MG	-20,7534	-46,6007
...	...	...	...	...
1	69	Avenida Juca Stockler, 2904, Passos/MG	-20,7503	-46,5988
1	70	Avenida Juca Stockler, 3050, Passos/MG	-20,7519	-46,5986
2	1	Rua Alexandre L. Borsari, Mercearia, Passos/MG	-20,7067	-46,6346
2	2	Rua Amos Donabella Borsari, 354, Passos/MG	-20,7054	-46,6367
...	...	...	...	...
2	67	Rua Hipólita P. Lemos, 415, Passos/MG	-20,7020	-46,6358
2	68	Rua Hipólita P. Lemos, 125, Passos/MG	-20,7043	-46,6371
3	1	Rua Maria Mathias da Silva, MartMinas, Passos/MG	-20,7328	-46,6294
3	2	Rua Memphis, Polícia Ambiental, Passos/MG	-20,7327	-46,6269
...	...	...	...	...

Fonte: Elaborado pelo autor (2026).

O componente da SED foi incorporado neste agente ponto de ônibus. Para cada parada foi implementado um fluxo operacional contendo filas, tempos de espera, embarque e desembarque de passageiros. Os tempos de permanência dos veículos nos pontos foram representados por distribuições triangulares, reproduzindo as informações apresentadas na seção 5.1.4. Durante o embarque e desembarque, os passageiros eram temporariamente encapsulados dentro do agente ônibus, permitindo representar adequadamente a dinâmica do transporte coletivo. A Figura 20 ilustra os blocos de ações do software AnyLogic® desenvolvidos para este trecho.

O agente Ônibus foi modelado por meio de um diagrama de estados responsável pela circulação contínua dos veículos entre os pontos pertencentes a cada linha. Cada veículo possui atributos relacionados à velocidade operacional, identificação da linha, posição atual na rota e próximo ponto de parada. A movimentação dos ônibus foi implementada por meio de diagramas de estados compostos pelos estados de garagem, deslocamento para o próximo ponto da linha e chegada no ponto de embarque/desembarque. A Figura 21 ilustra esta construção e suas variáveis e funções.

Figura 20 - Blocos de ação SED para o agente Ponto de ônibus

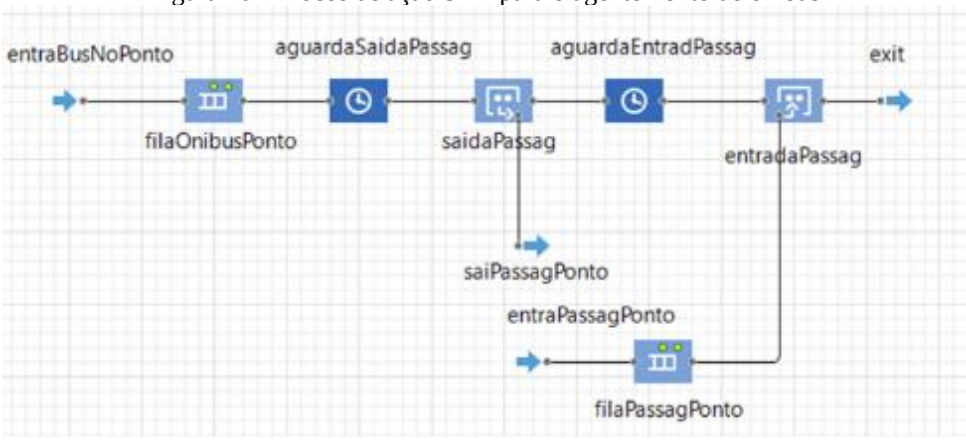

Fonte: Elaborado pelo autor (2026).

Figura 21 - Fluxo de comportamento do agente ônibus

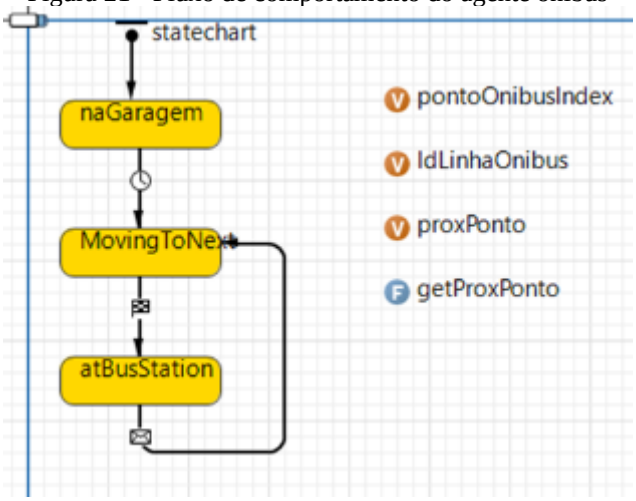

Fonte: Elaborado pelo autor (2026).

A lógica de escolha modal foi implementada em cada agente usuário. Inicialmente o modelo identifica se existe uma rota viável de transporte coletivo considerando restrições espaciais relacionadas à distância entre origem e ponto de embarque, distância entre ponto de desembarque e destino final, bem como possibilidades de integração entre linhas. Foram considerados limites máximos de 300 metros para acesso aos pontos de embarque e desembarque e 100 metros para integração entre linhas. Caso nenhuma rota atendesse simultaneamente essas restrições, o usuário realizava todo o deslocamento a pé. Esses parâmetros foram posteriormente utilizados como restrições operacionais durante o processo de racionalização conduzido pelo algoritmo de RL. Demais detalhes estão na seção 5.1.7.

Quando uma rota era considerada viável, o agente passava a integrar o conjunto de usuários aptos a utilizar o transporte coletivo. Entretanto, nem todos os usuários aptos necessariamente escolhiam o ônibus como modo de transporte. Para representar esse

comportamento, foram implementadas probabilidades específicas de adesão ao transporte coletivo para trabalhadores, estudantes e idosos. Essas probabilidades passaram posteriormente a ser calibradas utilizando dados reais de embarque fornecidos pela operadora do sistema. A Figura 22 ilustra o comportamento incluso no software bem como as variáveis e funções inseridas.

Figura 22 - Fluxo comportamental do Passageiro para deslocamento origem x destino

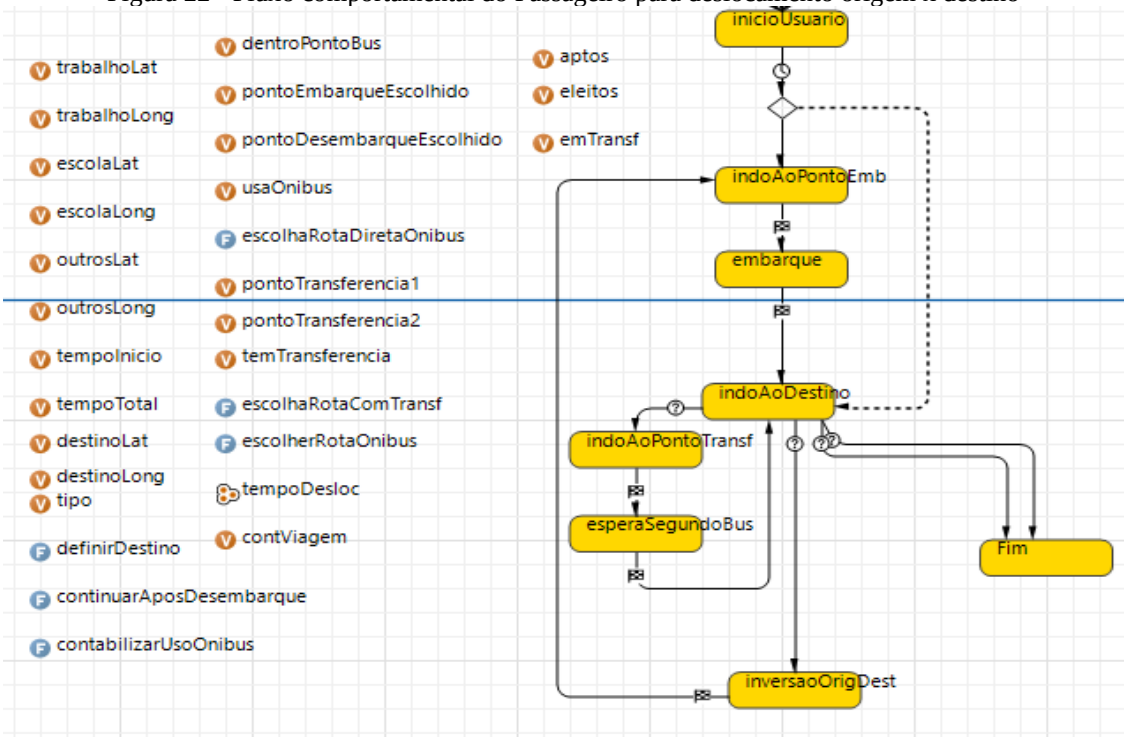

Fonte: Elaborado pelo autor (2026).

Para o agente ônibus foi ainda incorporada a função de múltiplos entes por linha, por meio de saídas a cada 40 minutos com total de 4 ônibus por linha. O modelo também incorporou mecanismos automáticos de contabilização de passageiros por linha e por categoria de usuário.

5.2.3 Calibração e resultados iniciais

Esta etapa teve como objetivo calibrar os parâmetros comportamentais associados à decisão de utilização do transporte público por ônibus, utilizando como referência os dados reais de embarque observados em cada linha do sistema. A calibração buscou ajustar o modelo para reproduzir, de forma aderente, os padrões de utilização identificados no objeto de estudo. Ressalta-se que a validação do modelo, apresentada na Seção 5.2.4, constitui uma etapa

metodologicamente distinta, destinada a verificar se os resultados produzidos após a calibração representam adequadamente o comportamento do sistema real.

Durante a execução da simulação, os embarques realizados eram automaticamente registrados em estruturas de dados específicas, possibilitando a comparação entre os resultados simulados de tipo de passageiros por linha e os dados observados no ambiente real. Essas informações constituíram a base quantitativa utilizada nos procedimentos de calibração, validação e posterior integração do ambiente híbrido com os algoritmos de Aprendizagem por Reforço.

Ao final da etapa de implementação, obteve-se um ambiente híbrido plenamente operacional, integrando população sintética, agentes georreferenciados, infraestrutura urbana, rede de transporte coletivo, operações discretas de embarque e desembarque e mecanismos automáticos de coleta de indicadores. Esse ambiente passou a servir como base para o processo de calibração, fundamentado na distinção entre usuários aptos ao uso do transporte coletivo e usuários efetivos, que efetivamente optam pelo transporte por ônibus. Para a calibração foram utilizadas as médias observadas apresentadas na Tabela 3, contudo recalculadas apenas três dos quatro meses da coleta de dados real (o último mês foi reservado para a validação do modelo).

Como ponto de partida do processo de busca, foram atribuídas probabilidades iniciais de 50% para os três perfis de usuários considerados. A calibração foi formulada como um problema de otimização estocástica, resolvido por meio da integração entre o motor de simulação e o algoritmo genético disponível no AnyLogic®. O objetivo consistiu em determinar o vetor de parâmetros P = {pTrabOnibus, pEstudOnibus, pIdosoOnibus}, correspondente às probabilidades de utilização do transporte coletivo pelos grupos Trabalhador, Estudante e Idoso, respectivamente.

A qualidade das soluções avaliadas foi mensurada por meio da Soma dos Erros Absolutos (SEA), calculada entre os embarques observados no sistema real e aqueles produzidos pelo modelo de simulação. Dessa forma, o processo de calibração buscou identificar a configuração paramétrica capaz de minimizar as discrepâncias entre os resultados simulados e os dados empíricos disponíveis. Define-se formalmente a SEA na equação 4, conforme métricas clássicas de ajuste apresentadas por Montgomery e Runger (2013).

$$\min Z = \sum_{l=1}^{n} \sum_{k=1}^{m} \left| E_{l,k}^{obs} - E_{l,k}^{sim}(P) \right| \qquad \text{Eq. (4)}$$

Onde:

- n: número de linhas de ônibus avaliadas (5 linhas no total);

- m: tipo de usuários (3 tipos no total);
- $E_{l,k}^{obs}$: média do número de embarques reais por linha e por tipo;
- $E_{l,k}^{sim}(P)$: média de embarques simulada para a linha *l* e perfil *k*, dada a configuração do vetor de parâmetros *P*.

A exploração do espaço de soluções foi realizada pelo módulo de otimização do AnyLogic®, que avaliou 500 configurações candidatas dos parâmetros de decisão. A semente aleatória foi mantida fixa em 1, garantindo a reprodutibilidade do experimento. O procedimento demandou aproximadamente quatro horas de processamento computacional e permitiu identificar soluções progressivamente mais aderentes aos padrões observados no ambiente real urbano de Passos/MG. A Figura 23 apresenta a evolução e resultados do processo de calibração.

Figura 23 - Resultados da calibração dos parâmetros probabilísticos de efetivação

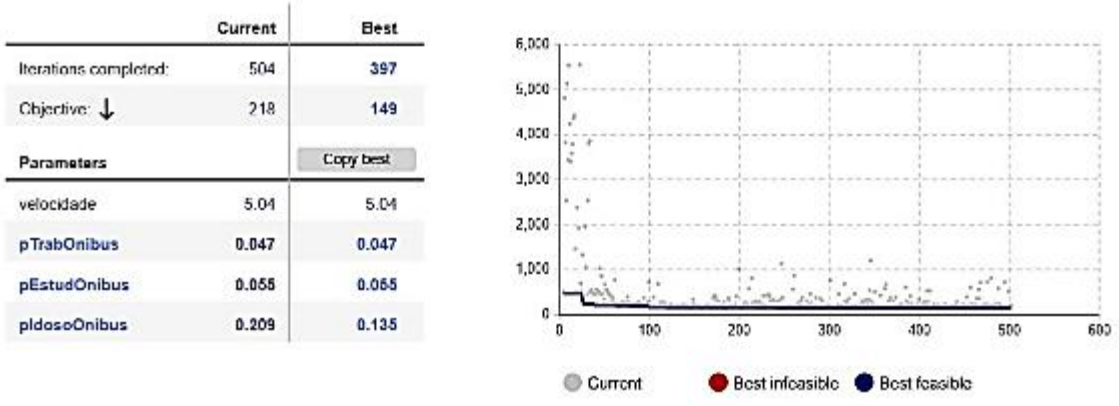

Fonte: Elaborado pelo autor (2026).

A melhor solução foi identificada na iteração 397, apresentando SEA igual a 149. Os parâmetros calibrados resultaram em probabilidades de utilização do transporte coletivo de 4,7% para trabalhadores, 5,5% para estudantes e 13,5% para idosos. Observa-se que o grupo dos idosos apresentou propensão significativamente superior à dos demais perfis analisados, indicando maior dependência relativa do transporte público entre indivíduos dessa faixa etária. Esse resultado é consistente com a menor disponibilidade de alternativas individuais de deslocamento frequentemente observada nesse grupo populacional e a gratuidade da passagem aos mesmos. A validação entre os resultados simulados e os dados observados é avaliada na Seção 5.2.4.

Para o cálculo do indicador de acessibilidade de Ingram (1971), foram determinadas as seguintes relações de variáveis do modelo MSH para com a equação 3 desta tese:

- A_i calcula, por meio de uma somatória, o resultado da acessibilidade para cada um dos pontos de ônibus *i*;
- O_j demonstra a oportunidade do destino, traduzido como o peso relativo de atratividade ou demanda associada ao destino j. No modelo, é calculado pela razão do número de viagens até cada POI sobre o número de viagens totais a todos os POIs. Por exemplo, o agente POI do tipo escola da coordenada geográfica (-20,724707, -46,612065) foi utilizado como origem ou destino na matriz OD por 17.600 pessoas. Como no total houve 2.085.920 utilizações de POIs, esta escola obteve o custo de oportunidade de 0,008438. Já o agente POI do tipo casa de georreferenciado em (-20,730278, -46,606907) foi utilizado apenas 80 vezes, resultando em um custo de oportunidade de 0,038 x 10^{-3}. O indicador é utilizado como divisor, pois, quanto maior o seu valor, melhor para o sistema.
- $f(c_{ij})$ calcula a função de impedância, incorporado ao modelo por meio do tempo médio de deslocamento entre cada ponto e o POI de origem ou destino. A Tabela 7 apresenta um exemplo dos registros produzidos pelo modelo durante as execuções da simulação.

Tabela 7 - Exemplo dos tempos simulados de deslocamento pedonal até ponto de ônibus

Usuário	Idade	Tipo	Latitude de Origem	Longitude de Origem	Linha de Embarque	Ponto de Embarque	Tempo Deslocamento pedonal (min)
1	79	Idoso	-20,713556	-46,610346	2	14	3,75
2	31	Trabalhador	-20,706862	-46,604357	4	40	2,07
3	8	Estudante	-20,720024	-46,625673	4	11	3,05
...	...	...	...	...	...	...	...
10384	36	Trabalhador	-20,720319	-46,620990	4	54	1,64
10385	76	Idoso	-20,754058	-46,605792	2	41	2,87
10386	5	Estudante	-20,726798	-46,619420	3	5	1,08
...	...	...	...	...	...	...	...

Fonte: Elaborado pelo autor (2026).

Complementando o cálculo do indicador, o mesmo foi realizado diretamente em uma função no AnyLogic®, registrando como dados de saída da função, o tipo de usuário (estudante, idoso ou trabalhador), as coordenadas geográficas dos pontos de origem e destino, os pontos de ônibus utilizados para embarque e desembarque e os respectivos tempos de deslocamento pedonal, além do indicador em si. Essas informações foram exportadas e organizadas no software Microsoft Excel®.

Outro elemento relevante, como a matriz OD é gerada estocasticamente em cada execução da simulação, foram realizadas dez replicações independentes utilizando sementes

aleatórias distintas totalizando as 2.085.920 utilizações de POIs acima citadas. Por fim, pontos de linhas distintas, mas com mesmo local geográfico foram agrupados.

A função encapsulada para o indicador de acessibilidade não foi utilizado apenas como medida de desempenho do sistema, mas também como variável de recompensa do algoritmo de RL descrito na seção 5.3.2. Dessa forma, melhorias produzidas pelo agente inteligente refletem diretamente aumentos nos níveis de acessibilidade da população aos serviços urbanos. Esses dados constituem a base para o cálculo do indicador de acessibilidade e para os experimentos subsequentes de racionalização da rede de transporte coletivo.

Para viabilizar a comparação relativa entre os pontos de ônibus, os valores do indicador foram normalizados para o intervalo [0,1] por meio da Equação (5) (Montgomery; Runger, 2013). Nessa escala, valores próximos de zero indicam maior acessibilidade relativa, enquanto valores próximos de um indicam menor acessibilidade.

$$Valor\ normalizado = \frac{(x - x_{min})}{(x_{max} - x_{min})} \qquad \text{Eq. (5)}$$

Onde: x é o valor da acessibilidade por ponto; x_{min} é o menor valor numérico de acessibilidade encontrado; e x_{max} é o maior valor numérico de acessibilidade. A Tabela 8 apresenta um exemplo dos valores normatizados de acessibilidade para os pontos de ônibus da cidade de Passos/MG. A tabulação completa se encontra no Apêndice A.

Tabela 8 - Exemplo do valor de acessibilidade dos pontos de ônibus de Passos/MG

N. Ponto ônibus	Latitude	Longitude	Acessibilidade (x10^9)	Acessibilidade Normalizada
1	-20,75523	-46,6007	1,84	0,8423
2	-20,75341	-46,6007	1,78	0,7957
3	-20,75328	-46,5988	1,68	0,7420
...	...	...	...	...
335	-20,72178	-46,5894	1,25	0,4710
336	-20,72353	-46,5897	1,20	0,4694
337	-20,72282	-46,5962	1,05	0,2304

Fonte: Elaborado pelo autor (2026).

Para melhor visualização, estes dados normalizados foram integrados ao modelo por meio de planilha eletrônica, possibilitando sua projeção espacial sem a necessidade de nova execução da simulação estocástica. A escala cromática adotada variou do verde (maior acessibilidade, valores próximos de zero) ao vermelho (menor acessibilidade, valores próximos de um), favorecendo a interpretação visual direta dos resultados. A Figura 24 ilustra esta representação espacial.

Analisando a Figura 24, evidencia-se maior concentração de pontos de ônibus com elevada acessibilidade nas regiões centrais da cidade, resultado coerente com achados clássicos da literatura baseados em métodos de SIG e modelos heurísticos como Bracarense e Ferreira (2018), Mahmoudi, Saidi e Wirasingue (2024) e Zannat, Adnan e Dewan (2020). Entretanto, a introdução de pesos associados aos POIs amplia a sensibilidade espacial do indicador, revelando áreas não centrais que apresentam níveis elevados de acessibilidade em função da presença de equipamentos urbanos relevantes, especialmente instituições de ensino. Como os agentes do tipo escola receberam coeficientes de impedância superiores aos dos demais grupos, regiões próximas a esses POIs tendem a apresentar valores mais favoráveis do indicador.

Figura 24 - Indicador de acessibilidade simulado no AnyLogic® em escala normalizada

Fonte: Elaborado pelo autor (2026).

Essa visualização permite análises mais refinadas sobre a localização das estações de embarque e desembarque, oferecendo subsídios para decisões relacionadas à redistribuição de paradas, à concentração de estações em áreas estratégicas e à priorização de regiões com maior densidade de oportunidades urbanas. Assim, o método proposto não se limita à mensuração abstrata da acessibilidade, mas fornece suporte empírico para intervenções espaciais no sistema de transporte coletivo.

Após a calibração dos parâmetros comportamentais e a implementação do indicador de acessibilidade, o modelo híbrido passou a representar o ambiente de interação utilizado pela RL. Nesse ambiente, os estados são definidos pelos indicadores espaciais e operacionais da rede

de transporte, as ações correspondem às possíveis modificações na configuração dos pontos de parada e a recompensa é calculada a partir dos níveis de acessibilidade e do número de usuários produzidos pela simulação. A MSH desenvolvida nesta etapa constitui a base computacional necessária para a aplicação do algoritmo *Q-Learning* tabular apresentado na seção 5.3.

5.2.4 Verificação e validação do modelo programado

A credibilidade dos resultados produzidos pelo modelo híbrido depende da realização de procedimentos sistemáticos de verificação e validação. Conforme Sargent (2020), a verificação busca assegurar que o modelo computacional foi implementado corretamente a partir do modelo conceitual, enquanto a validação procura avaliar se os resultados produzidos representam adequadamente o sistema real. Para atender a esses objetivos, foram empregadas técnicas de verificação computacional e validação operacional ao longo do desenvolvimento da pesquisa.

Conforme recomendado por Sargent (2020), a verificação do modelo computacional foi realizada por meio de: *debugging* (depuração); inspeção por pares; e testes de rastreamento (*walkthroughs*). Inicialmente, a lógica de funcionamento dos agentes, os diagramas de estados, os fluxos operacionais da SED e as regras de interação entre os componentes da SBA foram comparados com a RSL e analisados por pesquisadores das áreas de modelagem e simulação e de sistemas de transporte público urbano.

O *debugging* serve especificamente para garantir que o modelo foi construído corretamente, eliminando erros de código, lógica ou sintaxe antes que a simulação seja validada com a realidade. Para tanto, o próprio software AnyLogic® executa esta análise e avalia os pontos de erros do modelo. Como exemplos de erros encontrados, estavam: a falta de dimensão correta em alguns parâmetros relacionados a ônibus; erros nas buscas de tipos de agentes no formato texto em vez do formato numérico; posição de algoritmos de entrada e saída de passageiros do ônibus e dos pontos de ônibus; erros de letras maiúsculas ou minúsculas; ponto e vírgula ao final de ações a serem executadas; entre outros. Ao final, o modelo executou todas as programações propostas, sendo considerado apto para coleta dos resultados ou futuras análises.

A inspeção por pares teve como objetivo identificar inconsistências na implementação computacional, erros de programação, omissões de regras de negócio e incompatibilidades entre o modelo conceitual e o modelo programado. Durante esse processo foram revisadas as estruturas dos agentes Passageiro, Ônibus, Ponto de Ônibus e Pontos de Interesse. Como

resultados, desta inspeção, deferiu-se a compatibilidade entre o modelo conceitual e o programado. O Quadro 23 indica o como foi realizada para cada agente esta inspeção.

Quadro 23 - Resultados qualitativos da verificação por inspeção

Agente	Processo de inspeção	Descrição	Resultado
Passageiro	Comparação entre pirâmide etária real *versus* simulada.	Aderência visual entre ambas, considerando na simulação 50% de cada gênero, conforme Figura 25 que compara os dados coletados no software e dados reais do IBGE Cidades (2025, online).	Considerou-se que a população sintética reproduziu adequadamente a estrutura demográfica do município.
Ônibus	Avaliação das frotas em cada linha circulando pelos pontos de ônibus.	Visualização da animação de quatro ônibus em cada uma das cinco linhas, circulando pelos respectivos pontos utilizando-se da rede viária da cidade.	Considerou-se adequada a formatação deste agente.
Pontos de Interesse	Amostra de posição geográfica no mapa simulado x real.	Comparação da posição de 20 coordenadas geográficas de POIs de tipos distintos simulados com o ambiente real.	Todos foram dispostos corretamente no mapa GIS.
Pontos de ônibus	Amostra de posição geográfica no mapa simulado x real.	Comparação da posição de 10 coordenadas geográficas de POIs de tipos distintos simulados com o ambiente real.	Todos foram dispostos corretamente no mapa GIS.

Fonte: Elaborado pelo autor (2026).

Figura 25 - Comparação qualitativa pirâmide etária simulada (acima) x censitária (abaixo)

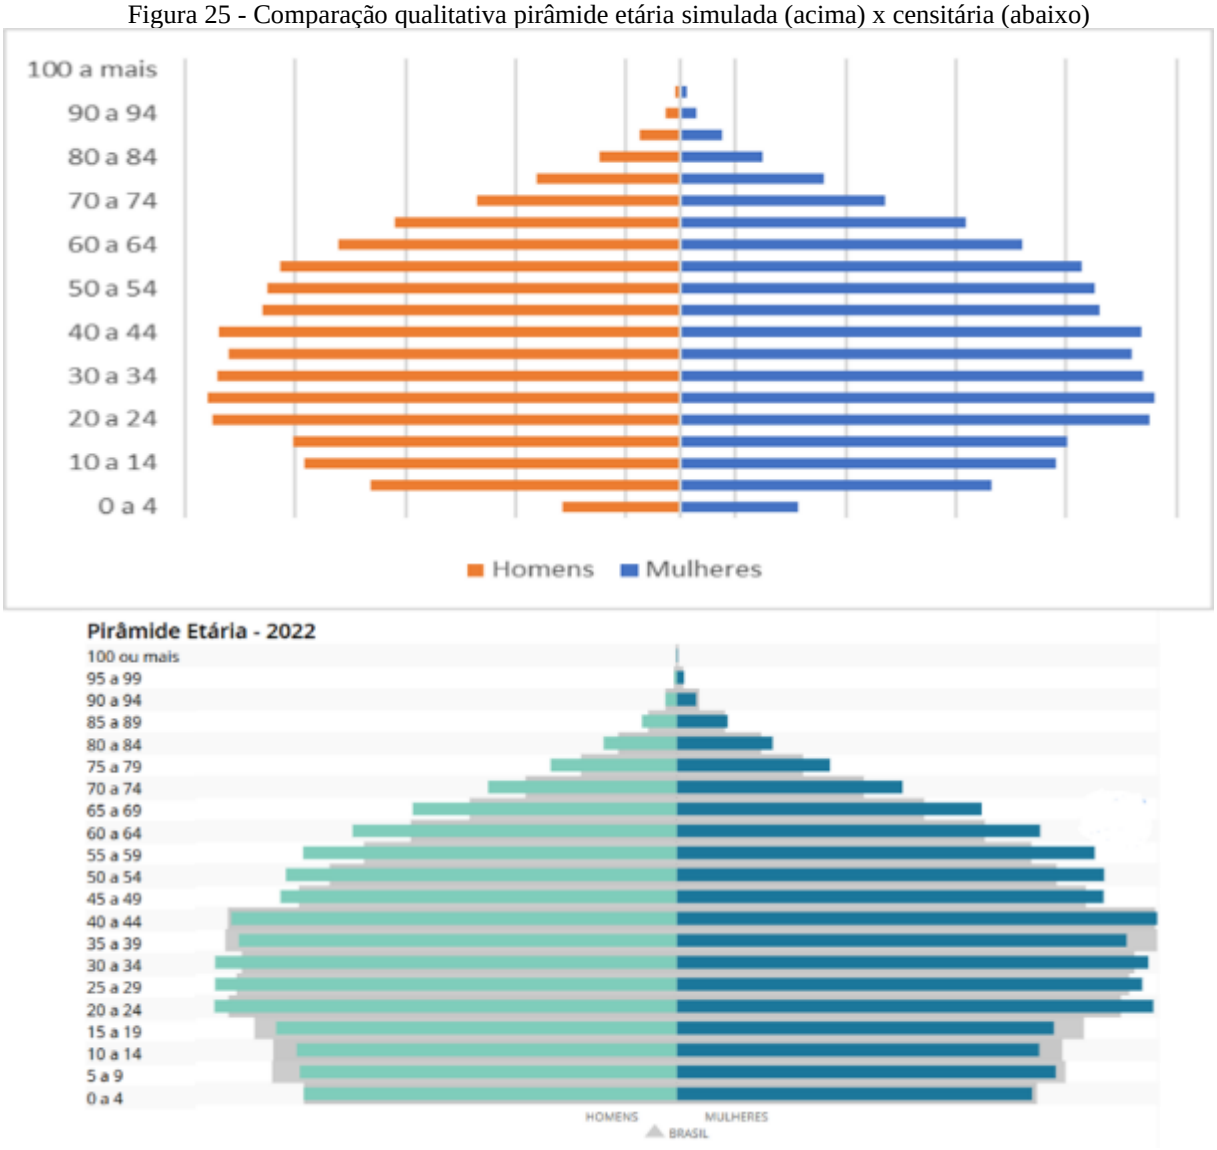

Fonte: Elaborado pelo autor (2026).

Complementarmente, foram realizados testes de rastreamento (*walkthroughs*), consistindo na observação detalhada da trajetória individual dos agentes ao longo da execução da simulação. Esses testes permitiram acompanhar passo a passo o comportamento dos passageiros desde a geração no ambiente, definição dos destinos, deslocamentos pela rede urbana, processos de embarque e desembarque, utilização de transferências e retorno ao ponto de origem. A Tabela 9 demonstra, por meio de extrações do software durante suas emulações, os passos seguidos pelo passageiro em suas rotas. Tais elementos foram obtidos por meio da função *println* do próprio AnyLogic® em etapas específicas da programação.

Conforme demonstra a Tabela 9, notam-se três conjuntos de dados para melhor explanação. Os passageiros 0, 8 e 28 (estudante, trabalhador e idoso, respectivamente), utilizaram-se de transferência (baldeação) entre linhas de ônibus. O usuário 0, por exemplo,

inicia sua jornada de um ponto específico georreferenciado (agente POI tipo Casa) e se desloca para a linha 5 ponto 37 para embarcar em seu primeiro ônibus. Chegando ao ponto 18 da mesma linha, ele desembarca e aguarda o segundo ônibus que é da linha 2 ponto de embarque 17. Por fim, este agente desembarca no ponto 58 e segue a pé para o seu destino. Sua rota é demonstrada na Figura 26 para melhor visualização e verificação.

Figura 26 - Roteiro de viagem feito pelo passageiro 0

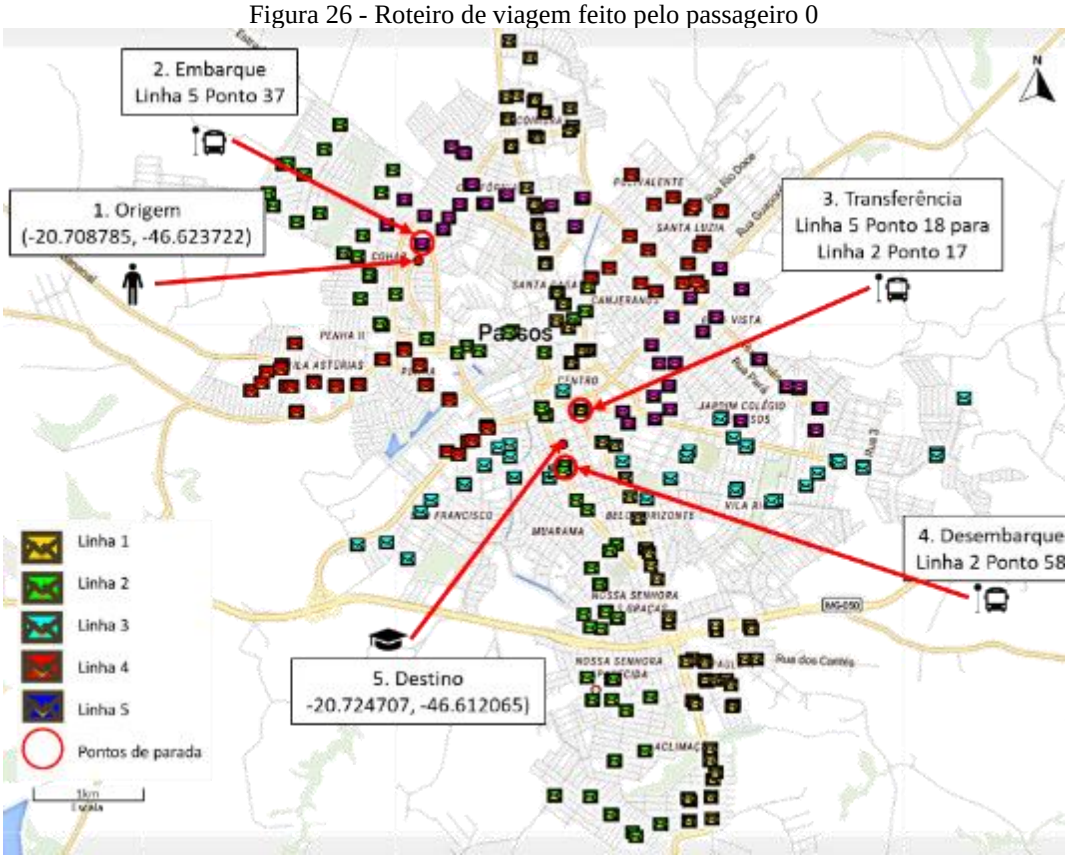

Fonte: Elaborado pelo autor (2026).

Já os passageiros 22, 48 e 63 não precisaram de pontos de transferência entre linhas de ônibus, embarcando e desembarcando na mesma linha para atingir o seu objetivo. Por fim, também a título de exemplificação, os passageiros 42, 38 e 45 não seguiram viagem de ônibus, nem embarcando nem desembarcando. Os resultados obtidos durante os *walkthroughs* demonstraram coerência entre o comportamento esperado e o comportamento efetivamente produzido pelo modelo, não sendo identificadas inconsistências relevantes na lógica de execução. Dessa forma, concluiu-se que a implementação computacional representava adequadamente o modelo conceitual proposto.

Tabela 9 - Exemplo de emulações de viagens AnyLogic®

Passageiro	Idade	Tipo	Latitude de Origem	Longitude de Origem	Linha de Embarque	Ponto de Embarque	Linha de Transferência 1	Ponto de Transferência 1	Linha de Transferência 2	Ponto de Transferência 2	Linha de Desembarque	Ponto de Desembarque	Latitude de Destino	Longitude de Destino
0	16	Estudante	-20,708785	-46,623722	5	37	5	18	2	17	2	58	-20,724707	-46,612065
8	26	Trabalhador	-20,738663	-46,60502	2	23	2	12	5	49	5	36	-20,708803	-46,626104
28	66	Idoso	-20,718539	-46,638191	4	63	4	16	3	10	3	35	-20,727455	-46,602592
22	8	Estudante	-20,727956	-46,624476	3	47	n	n	n	n	3	42	-20,727011	-46,613436
48	26	Trabalhador	-20,709555	-46,605371	4	39	n	n	n	n	4	48	-20,720476	-46,611729
63	70	Idoso	-20,72075	-46,587494	5	4	n	n	n	n	5	53	-20,71943	-46,613177
42	11	Estudante	-20,750502	-46,613346	n	n	n	n	n	n	n	n	-20,733008	-46,603411
38	56	Trabalhador	-20,704293	-46,59513	n	n	n	n	n	n	n	n	-20,722374	-46,605553
45	63	Idoso	-20,717282	-46,628676	n	n	n	n	n	n	n	n	-20,723453	-46,603117

Fonte: Elaborado pelo autor (2026).

Já a validação do modelo foi conduzida em duas etapas complementares: validação qualitativa por especialistas; validação quantitativa baseada em dados observados do sistema real.

Na primeira etapa foi empregada a técnica de validação face a face, conforme proposta por Sargent (2020). O modelo conceitual, os diagramas de funcionamento, os fluxos de deslocamento dos usuários, a lógica operacional do transporte coletivo e os resultados preliminares da simulação foram apresentados a especialistas. Os mesmos avaliaram a plausibilidade das hipóteses adotadas, a coerência dos comportamentos simulados e a aderência do modelo às características observadas no município de Passos/MG. Como resultados, consideraram que a estrutura do modelo era compatível com a dinâmica do sistema de transporte público analisado, corroborando a adequação das premissas utilizadas, etapas, hipóteses alocadas pelos pesquisadores e a representação dos processos de mobilidade incorporados à simulação.

Na segunda etapa foi realizada a validação quantitativa do modelo, com o objetivo de avaliar a capacidade do modelo em reproduzir os padrões observados de utilização do transporte coletivo, realizou-se uma Análise de Variância (ANOVA) por meio do Modelo Linear Geral (GLM) (Sargent, 2020; Montgomery; Runger, 2013). A escolha pelo GLM justifica-se pela natureza não-balanceada do experimento, decorrente do tamanho desigual das amostras entre as observações de passageiros reais e os dados gerados computacionalmente. Este método permite avaliar simultaneamente o impacto de múltiplos fatores categóricos sobre uma variável resposta contínua (a contagem de passageiros), controlando rigorosamente a taxa de erro do Tipo I que ocorreria caso fossem realizados múltiplos testes de hipóteses individuais em série.

O modelo estruturado considerou três fatores fixos principais: a linha de ônibus (com 5 níveis: Linha 1 a linha 5); o tipo de passageiro (com 3 níveis: trabalhador; estudante; idoso); e a origem do dado (com 2 níveis: real; simulado), além dos termos de interação de segunda e terceira ordens entre essas variáveis. Foram cadastrados os dados reais do último dos quatro meses de coleta de dados, após os filtros de outliers executados na seção 5.1.8 e também incorporados os dados simulados por 30 vezes no modelo. A formulação matemática do modelo estatístico adotado segue a equação clássica dos modelos lineares fatoriais multivariados, expressa pela Equação 6.

$$Y_{ijkl} = \mu + \alpha_i + \beta_j + \gamma_k + (\alpha\beta)_{ij} + (\alpha\gamma)_{ik} + (\beta\gamma)_{jk} + (\alpha\beta\gamma)_{ijk} + \varepsilon_{ijkl} \quad \text{Eq. (6)}$$

Onde: Y_{ijkl} representa a l-ésima observação de contagem de passageiros; μ denota a média geral do sistema; α_i, β_j e γ_k correspondem aos efeitos principais dos fatores: linha, tipo de usuário e origem do dado, respectivamente; os termos entre parênteses representam as interações duplas e triplas das variáveis; ε_{ijkl} configura o termo de erro aleatório residual.

A hipótese nula H0 postula que não existe diferença estatisticamente significativa entre a média de usuários coletada no ambiente real e a estimada no modelo. Utilizou-se o software Minitab® para o cálculo com nível de significância de 0,05 e resposta baseada no *p-value* (caso menor do que 0,05, rejeita-se a hipótese nula). A Figura 27 ilustra o resultado obtido do teste ANOVA.

Figura 27 - ANOVA Real x Simulado

Análise de Variância

Fonte	GL	SQ (Aj.)	QM (Aj.)	Valor F	Valor-P
Linha	4	57199	14299,7	611,17	0,000
Tipo	2	91662	45830,8	1958,81	0,000
Origem	1	8	8,0	0,34	0,560
Linha*Tipo	8	26363	3295,4	140,85	0,000
Linha*Origem	4	19	4,8	0,20	0,936
Tipo*Origem	2	1	0,3	0,01	0,987
Linha*Tipo*Origem	8	37	4,6	0,20	0,991
Erro	1330	31118	23,4		
Total	1359	371642			

Sumário do Modelo

S	R2	R2(aj)	R2(pred)
4,83708	91,63%	91,44%	91,22%

Fonte: Elaborado pelo autor (2026).

Não foi identificada diferença estatisticamente significativa entre os valores reais e simulados para o fator Origem (*p = 0,560*), fornecendo evidências de aderência do modelo aos dados observados dentro do poder estatístico e das condições do experimento. Mais do que a concordância macroestrutural, a aderência local do simulador foi confirmada pelos elevados *p-value* obtidos nas interações de segunda e terceira ordem: Linha e Origem com *p-value* = 0,936; Tipo e Origem com *p-value* = 0,987; e no cruzamento triplo com *p-value* = 0,991. Tais dados atestam que o comportamento simulado emula a realidade de maneira uniforme em todas as cinco linhas operacionais e em nos três perfis de passageiros. Em contrapartida, os efeitos isolados de "Linha", "Tipo de passageiro" e sua respectiva interação de segunda ordem apresentaram significância estatística (*p-value* = 0,000), o que corrobora que são heterogêneos, algo esperado no sistema de transporte real dentro do ambiente virtual, consolidando o modelo

de simulação como uma ferramenta preditiva altamente fidedigna e cientificamente validada para os propósitos desta tese.

Os resultados obtidos fornecem evidências de que o modelo híbrido desenvolvido apresenta aderência satisfatória ao objeto de estudo, podendo ser utilizado com confiança para os experimentos de racionalização da rede de transporte e para a integração com o algoritmo de Aprendizagem por Reforço descritos na seção 5.3.

5.2.5 Documentação e reprodutibilidade do modelo computacional

Com o objetivo de ampliar a transparência, a rastreabilidade e a reprodutibilidade da pesquisa, o modelo computacional desenvolvido foi disponibilizado em ambiente digital público. A versão executável do modelo encontra-se hospedada na plataforma AnyLogic Cloud®, permitindo a visualização e execução dos experimentos sem necessidade de instalação local do software. Adicionalmente, foi produzido um material audiovisual contendo a descrição da arquitetura do modelo, dos agentes, dos parâmetros e dos principais procedimentos de implementação, disponibilizado por meio de plataforma de compartilhamento de vídeos. Dessa forma, buscou-se garantir que pesquisadores de diferentes áreas possam compreender, reproduzir e expandir o modelo proposto, em consonância com as boas práticas de ciência aberta e pesquisa reproduzível. Os links para acesso aos sítios virtuais se encontram no Apêndice C.

Resumidamente, a arquitetura computacional do modelo foi desenvolvida de forma modular, visando facilitar sua compreensão, replicação e reutilização em futuras pesquisas, conforme Figura 6. O *framework* proposto é composto por seis módulos principais e interdependentes: (i) rede viária georreferenciada; (ii) criação dos agentes georreferenciados para população sintética e matriz origem-destino; (iii) comportamento dos agentes por SBA; (iv) fluxo operacional por SED; (v) cálculo do indicador de acessibilidade atual; e (vi) aprendizagem por reforço para racionalização da rede de transporte. A integração desses módulos permite representar simultaneamente aspectos espaciais, comportamentais, operacionais e decisórios do sistema de transporte público urbano.

O primeiro módulo corresponde à construção da infraestrutura espacial do modelo. Para isso, foi utilizada a API do OSM integrada ao ambiente GIS do AnyLogic®, permitindo a importação automática da rede viária urbana do município de Passos/MG. Essa estrutura constitui o ambiente físico da simulação, servindo de base para a localização dos agentes, execução dos deslocamentos e cálculo das distâncias percorridas ao longo da rede de transporte.

O segundo módulo é responsável pela criação dos agentes georreferenciados que compõem a população sintética e a matriz origem-destino. Nessa etapa foram implantados os agentes POIS do tipo Casa, Trabalho, Escola, Outros e a população de agentes Passageiros, utilizando dados espaciais provenientes de bases oficiais. A distribuição desses agentes sobre a malha urbana permite representar os padrões de mobilidade da população e gerar os deslocamentos necessários para a construção da matriz origem-destino utilizada no modelo.

O terceiro módulo contempla a SBA, responsável pela representação dos comportamentos individuais dos usuários do sistema. Cada passageiro possui atributos demográficos, espaciais e comportamentais que influenciam suas decisões de deslocamento. Por meio de diagramas de estados e regras de decisão, os agentes definem seus destinos, avaliam a viabilidade de utilização do transporte coletivo, selecionam rotas e interagem continuamente com os demais componentes do sistema, produzindo padrões emergentes de mobilidade urbana.

O quarto módulo corresponde à SED, responsável pela representação dos processos operacionais do transporte coletivo. Nesse componente foram implementadas filas, embarques, desembarques, transferências entre linhas e circulação dos ônibus ao longo da rede urbana. A integração entre SBA e SED permite representar simultaneamente o comportamento dos usuários e as restrições operacionais do sistema de transporte, reproduzindo de forma mais realista a dinâmica observada no ambiente real.

O quinto módulo é responsável pelo encapsulamento das equações do modelo e pelo cálculo do indicador de acessibilidade. Utilizando a formulação proposta por Ingram (1971), o modelo calcula continuamente o potencial de acesso da população aos destinos urbanos, considerando a distribuição espacial dos usuários, dos pontos de interesse e da infraestrutura de transporte. Esse indicador atua como principal métrica de desempenho do sistema, permitindo avaliar os impactos produzidos por diferentes configurações da rede de transporte coletivo.

Por fim, o sexto módulo incorpora técnicas de RL por meio do algoritmo *Q-Learning* tabular. Nesse componente, o modelo híbrido passa a atuar como um ambiente de processo de decisão, no qual os estados são representados pelos indicadores espaciais e operacionais da rede, as ações correspondem às possíveis modificações na configuração dos pontos de parada e a recompensa é calculada a partir dos níveis de acessibilidade obtidos após cada interação. Dessa forma, o agente atualiza a função do *Q-Learning*, aprendendo políticas de decisão capazes de racionalizar a localização dos pontos de ônibus, buscando melhorar ou otimizar a acessibilidade da população ao longo dos episódios de treinamento.

5.3 Análise e experimentação do objeto de estudo

5.3.1 Integração da Aprendizagem por Reforço ao Framework Híbrido

Com a consolidação das etapas de construção, calibração e validação estatística do modelo híbrido, viabiliza-se a incorporação de mecanismos de inteligência artificial voltados ao suporte de decisões estratégicas e operacionais no planejamento do transporte público urbano. Conforme vislumbrado na RSL, problemas de otimização de infraestrutura têm sido historicamente abordados por meio de programação matemática linear ou inteira, métodos exatos e algoritmos meta-heurísticos. Contudo, dada a estocasticidade intrínseca, a condicionante espacial e temporal e a natureza eminentemente sequencial do problema da tese, optou-se pela transição para o paradigma da RL.

Esta abordagem diferencia-se ao modelar o sistema como um processo adaptativo, no qual um agente inteligente deduz políticas de controle ótimas por meio de um fluxo contínuo de experimentação e retroalimentação com o ambiente simulado, conforme abordado na seção 2.4. Tal flexibilidade é crucial no contexto da mobilidade urbana, em que intervenções na infraestrutura física geram externalidades espaciais e rearranjos no comportamento dos usuários que se ramificam de forma não-linear ao longo do horizonte temporal de simulação.

Sob essa arquitetura integrada, a MSH desenvolvida na plataforma AnyLogic® passa a operar formalmente como o ambiente de interatividade do agente quantificado. A cada episódio de treinamento, o agente inspeciona o vetor de estado corrente da rede viária, executa tomadas de ação orientadas à reconfiguração geométrica dos pontos de parada e colhe as recompensas associadas, computadas em termos de ganhos ou perdas de acessibilidade espacial e número de usuários. A partir dessa dinâmica sucessiva de amostragem, o algoritmo atualiza os valores estimados da função $Q(s, a)$, utilizados para orientar a seleção de ações em estados discretizados do ambiente, identificando, ao longo dos episódios de treinamento, configurações espaciais com maior recompensa acumulada entre as soluções exploradas.

Esta dinâmica decisória é formalizada sob a estrutura matemática de um Processo de Decisão Markoviano (PDM), delimitado pelos conjuntos fundamentais de estados (S), ações (A), recompensas (R) e política de transição. O espaço de estados (S) sintetiza a configuração instantânea da malha de transporte, agregando atributos espaciais e operacionais dos pontos de embarque e desembarque, bem como os níveis locacionais de acessibilidade. O espaço de ações (A) compreende o portfólio de intervenções físicas permitidas na infraestrutura, especificamente a modificação geográfica das paradas de ônibus. A função de recompensa (R),

por sua vez, é parametrizada pelo gradiente do indicador de acessibilidade de Ingram (1971), mensurado de forma iterativa a cada rodada de interação. O objetivo central do agente reside, portanto, em buscar configurações com melhor desempenho para a utilidade acumulada de longo prazo, manipulando o posicionamento espacial dos nós de parada para racionalizar o indicador de cobertura territorial.

Dentre os algoritmos de RL documentados na literatura, selecionou-se o método *Q-Learning* em sua formulação tabular, associado a uma política de exploração e explotação ε-greedy, conforme proposto por Watkins e Dayan (1992). A escolha metodológica fundamenta-se na robustez conceitual do algoritmo, em sua simplicidade de parametrização e na garantia matemática de convergência para a política ótima quando aplicada a espaços de estados-ações discretizados de forma consistente. Além disto, a estrutura tabular mitiga as oscilações excessivas no gradiente de atualização da política, comuns em aproximadores de função não-lineares, assegurando estabilidade durante a execução estocástica e permitindo uma implementação nativa e transparente na linguagem Java suportada pelo AnyLogic®.

Desse modo, a convergência sinérgica entre a SBA, a SED, a acessibilidade dos pontos de ônibus e a RL estabelece uma arquitetura híbrida inédita. Este modelo integra, em uma única plataforma, o comportamento dos usuários, os processos operacionais das linhas e um algoritmo de aprendizagem adaptativa. Nas seções 5.3.2 a 5.3.5, detalham-se os componentes formais da tomada de decisão, os parâmetros de projeto da tabela Q e a matriz experimental executada para a racionalização da rede de pontos de parada.

5.3.2 Definição do projeto experimental

Para operacionalizar a etapa de RL, a MSH foi integrada a um algoritmo *Q-Learning* tabular, codificado em Java no AnyLogic®. O experimento busca identificar localizações alternativas para os pontos de parada que melhorem simultaneamente a acessibilidade da rede e o número de usuários efetivamente atendidos. Inicialmente, a recompensa considerava apenas a redução do indicador global de acessibilidade fundamentado em Ingram (1971). Essa formulação aproximou pontos dos POIs com maior concentração de oportunidades, mas afastou parte dos usuários de suas paradas de origem. Como o modelo estabelece um limite pedonal de 300 m, alguns agentes deixaram de possuir uma rota viável e, consequentemente, de utilizar o transporte público.

Esse comportamento evidenciou um *trade-off* entre melhoria da acessibilidade locacional e manutenção da demanda atendida. Por essa razão, o processo foi reformulado como

uma racionalização biobjetivo por agregação escalar, na qual a recompensa corresponde à soma do ganho percentual de acessibilidade e do ganho percentual no número de usuários. Os componentes recebem pesos iguais, evitando que a redução do indicador de Ingram seja obtida à custa da perda de cobertura. Adicionalmente, a melhor solução somente pode ser registrada quando o indicador global não é superior ao da rede original e o número de usuários não é inferior ao valor inicial.

Optou-se no projeto experimental por alterar exclusivamente a posição georreferenciada dos pontos de parada, mantendo constantes o número de pontos, a frota, os itinerários, a frequência, a capacidade dos veículos e os demais parâmetros operacionais previamente calibrados. Essa escolha teve como finalidade isolar o efeito da variável locacional sobre a acessibilidade e sobre o número de usuários atendidos, reduzindo a influência de fatores concorrentes que poderiam dificultar a interpretação dos resultados. Assim, a aplicação foi delimitada como uma racionalização locacional sob configuração operacional fixa. Essa decisão, contudo, não restringe o *framework*, que poderá ser utilizado em estudos futuros para avaliar também estas demais variáveis e parâmetros do sistema.

O conhecimento adquirido é armazenado na variável Q, implementada como HashMap<String, double[ ]>. A chave identifica o estado discreto, enquanto o vetor associado contém os valores *Q(s, a)* das cinco ações disponíveis. O estado inclui a linha e o ponto selecionado, a faixa discretizada de acessibilidade e a proporção entre os números atual e inicial de usuários. Essa última dimensão permite diferenciar configurações com acessibilidade semelhante, mas efeitos distintos sobre a população atendida.

O espaço de ações A contém cinco alternativas de deslocamento do ponto: Norte; Sul; Leste; Oeste; ou mantê-lo na posição atual. Cada movimento altera a latitude ou a longitude em *p = 0,002 grau*, correspondendo a aproximadamente 200 a 220 m na área estudada. A nova posição somente é aceita quando permanece no perímetro urbano definido no ambiente GIS. Após cada ação, recalculam-se a acessibilidade dos pontos, o indicador global e o número de usuários atendidos, cujas variações percentuais formam a recompensa.

A aptidão dos usuários decorre das regras espaciais e operacionais do modelo: distância máxima de 300 m entre origem e embarque e entre desembarque e destino; transferências entre pontos separados por até 100 m; e exclusão de viagens cujo deslocamento integral a pé não exceda cinco minutos. Entretanto, a aptidão não implica necessariamente a escolha do ônibus. Para preservar o comportamento calibrado, cada agente decide utilizar o sistema segundo as probabilidades *p = {TrabOnibus; pEstudOnibus; pIdosoOnibus}*, descritas na Seção 5.2.3.

Essa decisão comportamental permanece fixa durante o treinamento. A cada nova configuração espacial, recalcula-se somente a aptidão do agente. Assim, um usuário pode adquirir ou perder acesso à rede em razão do reposicionamento dos pontos, mas sua predisposição calibrada para utilizar o ônibus não é novamente sorteada. As variações na demanda decorrem, portanto, das alterações na infraestrutura, e não de novos sorteios a cada passo.

O treinamento é controlado pelos parâmetros α, γ, ε e p, conforme a Equação 1. Onde: a taxa de aprendizagem α define a intensidade de atualização das estimativas; γ pondera as recompensas futuras; ε regula a política ε-greedy entre exploração e explotação; e p determina a magnitude do deslocamento espacial. Na política ε-greedy, uma ação é selecionada aleatoriamente com probabilidade ε; caso contrário, escolhe-se a ação com maior valor Q. O treinamento inicia com $\varepsilon = 0{,}3$, reduzido ao final de cada episódio por $\varepsilon \leftarrow \varepsilon \times 0{,}9$, até o limite mínimo de 0,02. Essa estratégia privilegia a exploração inicial e amplia progressivamente a explotação do conhecimento adquirido.

A recompensa é calculada com base nas variações percentuais entre o estado anterior e o estado resultante da ação. Como valores menores do indicador de Ingram representam melhor desempenho, o componente de acessibilidade corresponde à sua redução relativa. O componente de usuários representa o crescimento relativo da população atendida. A soma dessas duas variações constitui a recompensa: reduções no indicador e aumentos no número de usuários geram valores positivos; pioras em qualquer dimensão diminuem o retorno. Os pesos iguais representam, nesta aplicação, equilíbrio entre eficiência locacional e cobertura da demanda, embora outras ponderações possam ser avaliadas futuramente.

Adotou-se $\alpha = 0{,}1$, permitindo atualizações graduais e reduzindo a influência de variações pontuais do modelo, e $\gamma = 0{,}9$, preservando a relevância das consequências futuras das ações. Esses valores são compatíveis com Watkins e Dayan (1992) e com os princípios de aprendizagem por Diferença Temporal apresentados por Sutton e Barto (2018). O passo de 0,002 grau produz alterações espacialmente relevantes sem ultrapassar integralmente, em uma única ação, o raio pedonal de 300 m. As restrições de admissibilidade complementam a recompensa e impedem o armazenamento de configurações finais que reduzam a demanda ou piorem o indicador em relação à rede original.

Uma configuração é registrada como melhor solução quando seu desempenho combinado supera o da configuração anteriormente armazenada e, simultaneamente, atende às restrições estabelecidas: indicador global menor ou igual ao da rede original; e número de usuários maior ou igual ao inicial. As coordenadas, os valores de acessibilidade e a quantidade

de usuários da melhor configuração admissível são preservados para restauração ao término do treinamento.

O plano experimental compreende 10 episódios de 2.000 passos, totalizando 20.000 interações. No início de cada episódio, os pontos retornam às coordenadas originais, enquanto a tabela Q mantém o conhecimento acumulado. Em cada passo, seleciona-se aleatoriamente um ponto, identifica-se seu estado, aplica-se uma ação, recalculam-se as duas métricas, determina-se a recompensa composta e atualiza-se *Q(s, a).* A reinicialização espacial reduz a dependência de trajetórias específicas, enquanto a manutenção da tabela permite transferir o aprendizado entre episódios.

Ao final, comparam-se os valores inicial e final do indicador global de acessibilidade, sua variação percentual, os números inicial e final de usuários e as coordenadas originais e racionalizadas dos pontos. Também são registrados os componentes da recompensa e o desempenho combinado da melhor configuração admissível. Para assegurar a replicabilidade, utilizou-se a semente aleatória 1, e a documentação do modelo é apresentada no Apêndice C. A Tabela 10 sintetiza os parâmetros e componentes empregados no *Q-Learning*.

Tabela 10 - Componentes estruturais do experimento *Q-Learning* no AnyLogic®

Estrutura	Descrição	Valor encapsulado
Parâmetro α	Taxa de aprendizagem: controla a velocidade de absorção do erro de Diferença Temporal frente ao histórico.	0,1 (gera um peso de 10% de aprendizagem sobre o erro obtido).
Parâmetro γ	Fator de desconto intertemporal: modula o peso das recompensas futuras de longo prazo sobre as imediatas.	0,9 (gera um peso de 90% para a recompensa futura).
Parâmetro ε	Fator de probabilidade da taxa ε-greedy. Arbitra a transição dinâmica entre exploração (exploration) e explotação (exploitation).	0,3 com decaimento gradativo de 0,9 a cada episódio e mínimo de 0,02.
Parâmetro p	Determina a magnitude escalar e geométrica (em graus decimais) do deslocamento geográfico sofrido pelo ponto a cada passo.	0,002 (representado em torno de variações de 222 metros).
pTrabOnibus, pEstudOnibus e pIdosoOnibus	Probabilidades de utilização do ônibus entre os usuários aptos.	Valores obtidos previamente por calibração
Episódios	Contador cíclico: reinicia o sistema à configuração real primitiva para mitigar vieses de busca.	10 episódios.
Passos	Contador interno: Delimita a sequência finita de transições.	2.000 passos (totalizando 20.000 iterações).
Semente aleatória	Controle da aleatoriedade para replicação.	1

Fonte: Elaborado pelo autor (2026).

Com essa estrutura, a racionalização deixa de ser avaliada exclusivamente pela proximidade entre os pontos de parada e os POIs e passa a incorporar também os efeitos das alterações espaciais sobre a quantidade de usuários atendidos. A função de recompensa

composta permite que o *Q-Learning* diferencie soluções que apresentam ganhos semelhantes de acessibilidade, mas consequências distintas para a cobertura da demanda. Na Seção 5.3.3, os resultados das 20.000 interações são analisados por meio da evolução do indicador global de acessibilidade, do número de usuários, da recompensa e dos deslocamentos espaciais produzidos pelo algoritmo.

5.3.3 Execução dos experimentos

Após a consolidação paramétrica do algoritmo *Q-Learning* Tabular e seu encapsulamento ao software AnyLogic® para MSH, conduziu-se a fase de execução dos experimentos. O objetivo principal desta etapa consistiu em gerar dados simulados capazes de espelhar, com estrito rigor estatístico e fidelidade comportamental, a dinâmica do sistema real de transporte público sob condições controladas, replicáveis e aderentes ao projeto experimental fatorial estabelecido.

Para preservar a robustez metodológica e assegurar que as flutuações nas variáveis de saída fossem blindadas contra ruídos, os experimentos operaram sob o princípio do isolamento de fatores. Desse modo, mantiveram-se invariantes todos os parâmetros estruturais constitutivos do modelo calibrado na seção 5.2.3, compreendendo: a distribuição demográfica da população sintética; as taxas de geração e atração de viagens consolidadas na matriz OD; as características físicas e operacionais das frotas de ônibus (SED); as velocidades operacionais médias; os algoritmos de roteirização; e as regras heurísticas de decisão espacial associadas ao comportamento pedonal dos agentes.

O cenário de referência, representativo da rede de transporte coletivo atualmente observada no município de Passos/MG, foi executado sob o mesmo número de réplicas estocásticas e gerenciamento de sementes pseudoaleatórias que os cenários alternativos. Esta padronização forneceu os vetores base dos níveis de acessibilidade territorial de Ingram (1971), a distribuição espacial primária dos nós de embarque e desembarque, e os fluxos absolutos de passageiros transportados, segmentados por linha e segmentados por tipos dos passageiros.

A estabilização observada no algoritmo *Q-Learning*, após o cumprimento de sua matriz evolutiva de episódios e passos de treinamento, induziu o reposicionamento geográfico racionalizados do agente Ponto de ônibus da rede. A Tabela 11 exemplifica a transição espacial da malha de transporte, contrapondo os vetores de coordenadas de latitude e longitude originais aos arranjos racionalizados resultantes do processo de aprendizagem, computando-se os valores de deslocamento projetados no ambiente GIS da cidade de Passos/MG.

Tabela 11 - Exemplos de localização original x localização racionalizada

Linha	N. Ponto	Latitude Original	Longitude Original	Acessibilidade (10^9)	Melhor Latitude	Melhor Longitude	Melhor Acessibilidade (10^9)	Deslocamento (metros)
1	1	-20,7552	-46,6007	1,57	-20,7492	-46,6027	1,57	696,46
1	2	-20,7534	-46,6007	1,74	-20,7534	-46,6027	1,74	208,38
...	...	...	...	...	...	...	...	...
2	6	-20,7128	-46,6291	1,19	-20,7068	-46,6251	1,19	784,47
2	7	-20,7148	-46,6274	1,12	-20,7148	-46,6274	1,12	0,00
...	...	...	...	...	...	...	...	...
3	20	-20,7270	-46,5895	1,28	-20,7270	-46,5895	1,28	0,00
3	21	-20,7261	-46,5876	1,33	-20,7241	-46,5876	1,33	221,52
...	...	...	...	...	...	...	...	...
4	12	-20,7211	-46,6214	0,974	-20,7211	-46,6214	0,974	0,00
4	13	-20,725	-46,6206	0,913	-20,723	-46,6166	0,913	472,02
...	...	...	...	...	...	...	...	...
5	7	-20,7178	-46,5945	1,10	-20,7178	-46,5945	1,10	0,00
5	8	-20,7143	-46,5983	1,01	-20,7163	-46,5983	1,01	221,52
...	...	...	...	...	...	...	...	...

Fonte: Elaborado pelo autor (2026).

Finalizado o experimento *Q-Learning* e a extração das novas matrizes de coordenadas geográficas dos pontos de parada, o novo arranjo espacial de localização dos pontos de ônibus foi reinserido como parâmetro de entrada estático na MSH de usuários e dinâmica operacional, no referido agente. Na sequência, realizou-se uma nova bateria completa de rodadas de simulação baseada no mesmo modelo de demanda e comportamento pedonal. Ao manter inalteradas as demais variáveis do sistema urbano, mitigou-se a interferência de vieses de amostragem, assegurando que quaisquer divergências observadas nas métricas agregadas fossem atribuídas, por nexo causal exclusivo, às intervenções locacionais induzidas pelo agente de *Q-Learning*.

Para fins de análise comparativa de variância e teste de hipóteses entre o cenário real e o racionalizado, os *outputs* gerados pelas interações dos agentes foram rigorosamente catalogados. O protocolo de coleta de dados concentrou-se no comportamento sistêmico das variáveis dependentes, registrando a evolução dos índices de acessibilidade e o número de usuários efetivamente atendidos transportados por linha (5 linhas urbanas) e tipo (trabalhador, estudante, idoso).

Os dados amostrais resultantes foram estruturados em formato de matrizes e exportados de forma automatizada para planilhas eletrônicas via Microsoft Excel® e submetidos ao processamento analítico no software estatístico Minitab®. Essa rotina analítica viabilizou a aplicação de testes estatísticos e gráficos sobre os resultados consolidados. Tais itens encontram-se estruturados na seção 5.3.4.

5.3.4 Análise estatística

Após a conclusão dos ensaios computacionais e a consequente extração dos dados gerados pelas simulações, procedeu-se à fase de análise estatística descritiva e inferencial. O objetivo central desta etapa consistiu em avaliar o comportamento macroscópico e microscópico do sistema de transporte coletivo urbano operando sob duas configurações de infraestrutura: o cenário simulado com os dados originais; e o arranjo espacial racionalizado obtido por meio do algoritmo *Q-Learning*. Os dados amostrais colhidos no AnyLogic® foram estruturados e processados utilizando o software estatístico Minitab®.

Assegura-se a comparabilidade entre os cenários mantendo inalterados entre as execuções todos os elementos operacionais não associados à variável de decisão. Assim, preservam-se o número de pontos de parada, a quantidade de ônibus, os itinerários, a capacidade dos veículos, a frequência de atendimento e os demais parâmetros calibrados do modelo. Dessa

forma, as diferenças identificadas nos indicadores de acessibilidade e utilização do sistema podem ser interpretadas, no escopo do experimento, como efeitos associados à alteração da distribuição espacial dos pontos de parada, reduzindo-se a influência de fatores concorrentes sobre os resultados.

Para verificar se as variações de volume da captação de usuários e dos níveis de acessibilidade local guardavam significância estatística, estruturou-se um delineamento de teste de hipóteses. Adotou-se um nível de significância de 5% (com intervalo de confiança de 95%), definindo como hipótese nula (H_0) a igualdade estrita dos vetores médios de passageiros transportados entre os cenários analisados.

Considerando a natureza multifatorial do plano experimental, aplicou-se uma análise de variância (ANOVA) por meio do modelo linear geral (GLM), conforme já mencionado na seção 5.2.4. O modelo foi parametrizado contendo três fatores controlados principais e suas respectivas interações: as linhas de transporte público (1, 2, 3, 4, 5); o tipo de passageiros (trabalhador, estudante, idoso); e a origem dos dados (cenário base original *versus* cenário racionalizado via RL). A Figura 28 sintetiza a análise de variância e as saídas analíticas do GLM executado.

Figura 28 - ANOVA Simulação original x Simulação racionalizada

Análise de Variância

Fonte	GL	SQ (Aj.)	QM (Aj.)	Valor F	Valor-P
Linha	4	132520	33130	987,48	0,000
Tipo	2	266710	133355	3974,79	0,000
Origem	1	3564	3564	106,22	0,000
Linha*Tipo	8	28001	3500	104,33	0,000
Linha*Origem	4	13098	3275	97,60	0,000
Tipo*Origem	2	1910	955	28,47	0,000
Linha*Tipo*Origem	8	2396	300	8,93	0,000
Erro	1470	49319	34		
Total	1499	497518			

Sumário do Modelo

S	R2	R2(aj)	R2(pred)
5,79225	90,09%	89,89%	89,68%

Fonte: Elaborado pelo autor (2026).

Os resultados consolidados pelo GLM (Figura 28) revelaram uma elevada robustez explicativa do modelo matemático formulado, evidenciada pelo coeficiente de determinação ajustado (R^2_{aj} = 89,68%). Esse índice atesta que a maior parte da variabilidade associada à taxa

de captação de passageiros é satisfatoriamente elucidada pelos fatores controlados inseridos no experimento.

Aferiu-se que todos os efeitos principais (Linha, Tipo de Passageiro e Origem dos Dados) exercem influência estatisticamente significante sobre a variável de resposta (*p-value < 0,05*). Esse resultado emite evidências empíricas para a rejeição da hipótese nula (H0), comprovando que a reconfiguração espacial provocada pelo algoritmo de inteligência artificial altera o comportamento operacional e o equilíbrio dinâmico do sistema de transporte.

Para além das influências isoladas, o desdobramento das interações de segunda ordem revelou a presença de dinâmicas comportamentais não-lineares e interdependentes no tecido urbano. A interação dupla entre os fatores linha e tipo de passageiro mostrou-se estatisticamente significante, denotando que a distribuição dos perfis de demanda (estudantes, idosos e trabalhadores) não é homogênea ao longo do território, mas condicionada às centralidades conectadas por cada linha.

De igual relevância para o escopo desta tese, a interação entre tipo de passageiro e origem dos dados manifestou significância estatística (*p-value < 0,05*). Esse fenômeno indica que a sensibilidade elástica à caminhada pedonal diante do reposicionamento dos pontos de parada afeta os perfis de usuários de maneiras marcadamente distintas, demandando um diagnóstico visual localizado por meio de diagramas de dispersão e simetria.

Com o intuito de mapear essas assimetrias locacionais, construiu o gráfico do tipo médias e intervalos de confiança de 95% (Figura 29). Este diagrama permitiu comparar as estimativas médias e a incerteza associada a cada combinação de linha, perfil de usuário e cenário.

Figura 29 - Gráfico de médias e intervalos de confiança de 95% entre modelo original e racionalizado

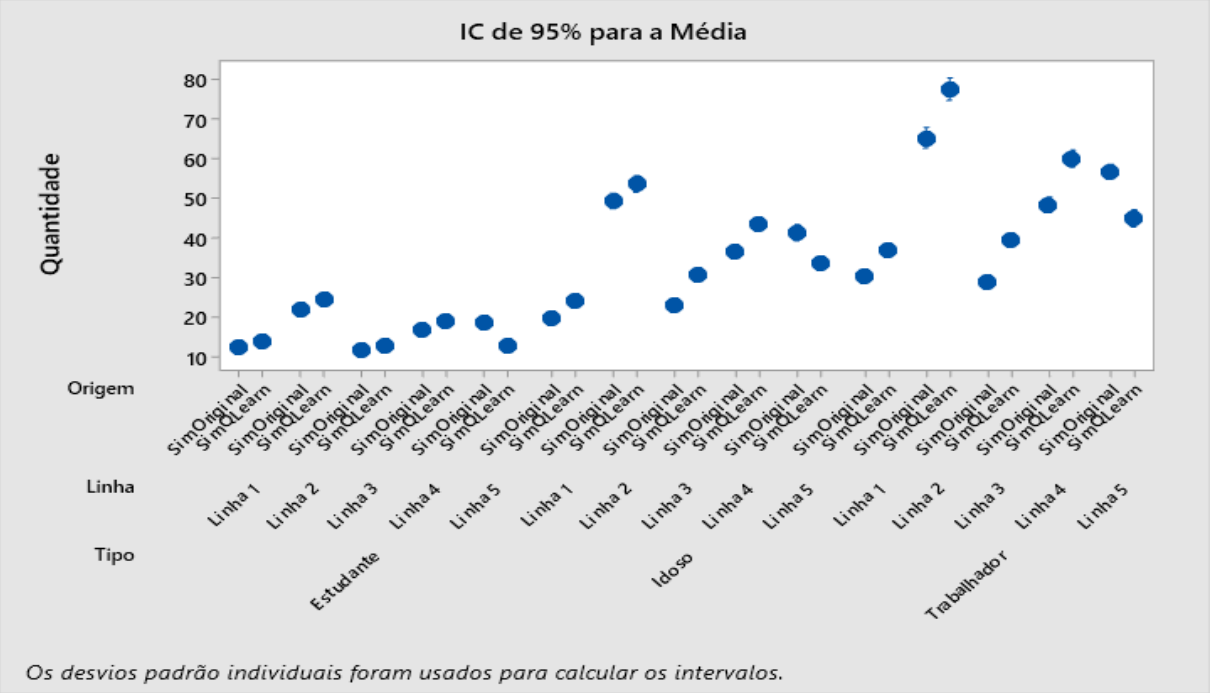

Fonte: Elaborado pelo autor (2026).

A análise do comportamento distributivo indica que em praticamente todas as matrizes pareadas de dados, registrou-se um incremento na média de passageiros transportados após a translação espacial das paradas induzida pelo *Q-Learning*. Para detalhar essas variações quantitativas, a Tabela 12 consolida as médias observadas nos cenários basal e racionalizado, computando os respectivos percentuais de melhoria na captação de demanda. Contudo ressalta-se que a solução aumentou o volume agregado estimado de passageiros, porém não beneficiou todos os grupos de forma uniforme. Embora o volume agregado de passageiros tenha aumentado, os benefícios não foram distribuídos uniformemente entre as linhas. As Linhas 1 a 4 apresentaram crescimento nos três perfis de usuários, enquanto a Linha 5 apresentou redução para trabalhadores, estudantes e idosos. Esse resultado evidencia que a melhoria global pode coexistir com perdas localizadas, reforçando a necessidade de incorporar critérios de equidade espacial e restrições mínimas por linha em futuras formulações da recompensa.

Como complemento à análise da demanda, avaliou-se conjuntamente a evolução do indicador global de acessibilidade e do número de usuários efetivamente atendidos pelo sistema. Após o treinamento do *Q-Learning*, a configuração racionalizada apresentou melhoria de 8,04% no indicador global de acessibilidade e aumento de 12,58% no número de usuários no modelo tabular experimental, em comparação ao cenário-base. Esses resultados demonstram que a função de recompensa composta foi capaz de equilibrar as duas dimensões consideradas,

evitando que a aproximação dos pontos aos POIs fosse obtida à custa da redução da cobertura da população.

Tabela 12 - Comparação entre médias de usuários entre simulações

Linha	Tipo	SimOriginal	SimQLearn	% Melhoria
Linha 1	Trabalhador	304,4	369,8	21,48%
Linha 1	Estudante	124,2	140,8	13,37%
Linha 1	Idoso	196,2	242	23,34%
Linha 2	Trabalhador	653,4	776,2	18,79%
Linha 2	Estudante	219,2	243,8	11,22%
Linha 2	Idoso	494,6	537,4	8,65%
Linha 3	Trabalhador	290,8	395,4	35,97%
Linha 3	Estudante	116,8	127,6	9,25%
Linha 3	Idoso	229,8	308,8	34,38%
Linha 4	Trabalhador	484,8	601	23,97%
Linha 4	Estudante	167	191,6	14,73%
Linha 4	Idoso	367,6	434,6	18,23%
Linha 5	Trabalhador	568,4	450,6	-20,72%
Linha 5	Estudante	188,4	126,6	-32,80%
Linha 5	Idoso	414,8	336,6	-18,85%

Fonte: Elaborado pelo autor (2026).

A melhoria de 8,04% deve ser interpretada considerando o caráter agregado do indicador global, que reúne os resultados de toda a rede, inclusive dos pontos que não sofreram deslocamentos ou apresentaram alterações pouco expressivas. Dessa forma, ganhos locais relevantes tendem a ser atenuados quando consolidados em uma única medida. Paralelamente, o aumento de 12,58% no número de usuários indica que o reposicionamento dos pontos ampliou a quantidade de agentes que permaneceram ou se tornaram aptos a utilizar o transporte público, respeitando os limites pedonais estabelecidos no modelo. Em conjunto, os resultados evidenciam que o processo de aprendizagem não apenas melhorou a relação espacial entre os pontos de parada e as oportunidades urbanas, mas também ampliou a população atendida, corroborando a adequação da recompensa biobjetivo empregada no algoritmo.

Em síntese, as avaliações estatísticas executadas não apenas ratificaram a robustez matemática do *framework* híbrido proposto, mas forneceram subsídios inferenciais sobre a efetividade social da racionalização espacial por inteligência artificial. A estabilização observada entre o rigor analítico da ANOVA, a sensibilidade visual do Boxplot e as variações parametrizadas de médias conferem legitimação científica às conclusões e contribuições tecnológicas apresentadas nesta tese.

5.3.5 Solução e entendimento dos resultados

Após os experimentos computacionais e a obtenção da configuração racionalizada pelo *Q-Learning*, avaliou-se qualitativamente a aplicabilidade das soluções ao sistema real de

transporte coletivo. Embora o RL permita explorar amplo espaço de soluções, as localizações resultantes precisam ser confrontadas com restrições físicas, topológicas, urbanísticas e de segurança viária. Decisões locacionais sobre pontos de parada devem considerar, além da cobertura e das distâncias, a estrutura da rede viária, os trajetos pedonais e as condições de implantação da infraestrutura (Sahu *et al.*, 2021; Zannat; Adnan; Dewan, 2020; Santos; Oliveira; Simões, 2026).

Assim, esta etapa examinou a exequibilidade prática das posições propostas pelo *framework*. O algoritmo modificou 294 dos 337 pontos georreferenciados. A Figura 30 apresenta a distribuição espacial comparativa entre os cenários original e racionalizado.

A escolha do AnyLogic® decorreu de sua conexão aos requisitos de integração do *framework*, e não de uma superioridade sobre outras plataformas. Por exemplo: o Vensim® é especialmente adequado à SD e à análise de relações sistêmicas agregadas; o MATSim®, à SBA de redes multimodais em larga escala; o SUMO®, à microssimulação de tráfego, ao controle semafórico e à análise de emissões; e NetLogo® e Repast®, à construção flexível de modelos baseados em agentes. Sistemas de Informações Geográficas especializados, por sua vez, oferecem recursos mais aprofundados de edição, análise topológica e validação espacial (Abar *et al.*, 2017; Macal; North, 2009; Manser *et al.*, 2020; Ercan *et al.*, 2022).

Para esta tese, entretanto, foi necessário reunir em um mesmo ambiente os comportamentos individuais dos passageiros por SBA, os processos operacionais por SED, a representação georreferenciada da rede e o mecanismo de RL. O caráter multimétodo do AnyLogic® reduziu a necessidade de transferência e sincronização de dados entre diferentes plataformas e permitiu avaliar conjuntamente os efeitos espaciais, comportamentais e operacionais das alterações propostas (Abar *et al.*, 2017; Brailsford *et al.*, 2019; Mustafee; Harper; Fakhimi, 2022; Yang *et al.*, 2021). Essa escolha envolve um *trade-off* entre integração e especialização: o AnyLogic® favoreceu a articulação dos componentes da pesquisa, enquanto ferramentas especializadas poderiam oferecer maior profundidade em tarefas específicas. O *framework*, portanto, não depende da plataforma utilizada e pode ser implementado em outros ambientes ou pelo acoplamento entre softwares, desde que suas fases e mecanismos de interação sejam preservados.

Figura 30 - Localização dos pontos por linha atual (acima) e racionalizado (abaixo)

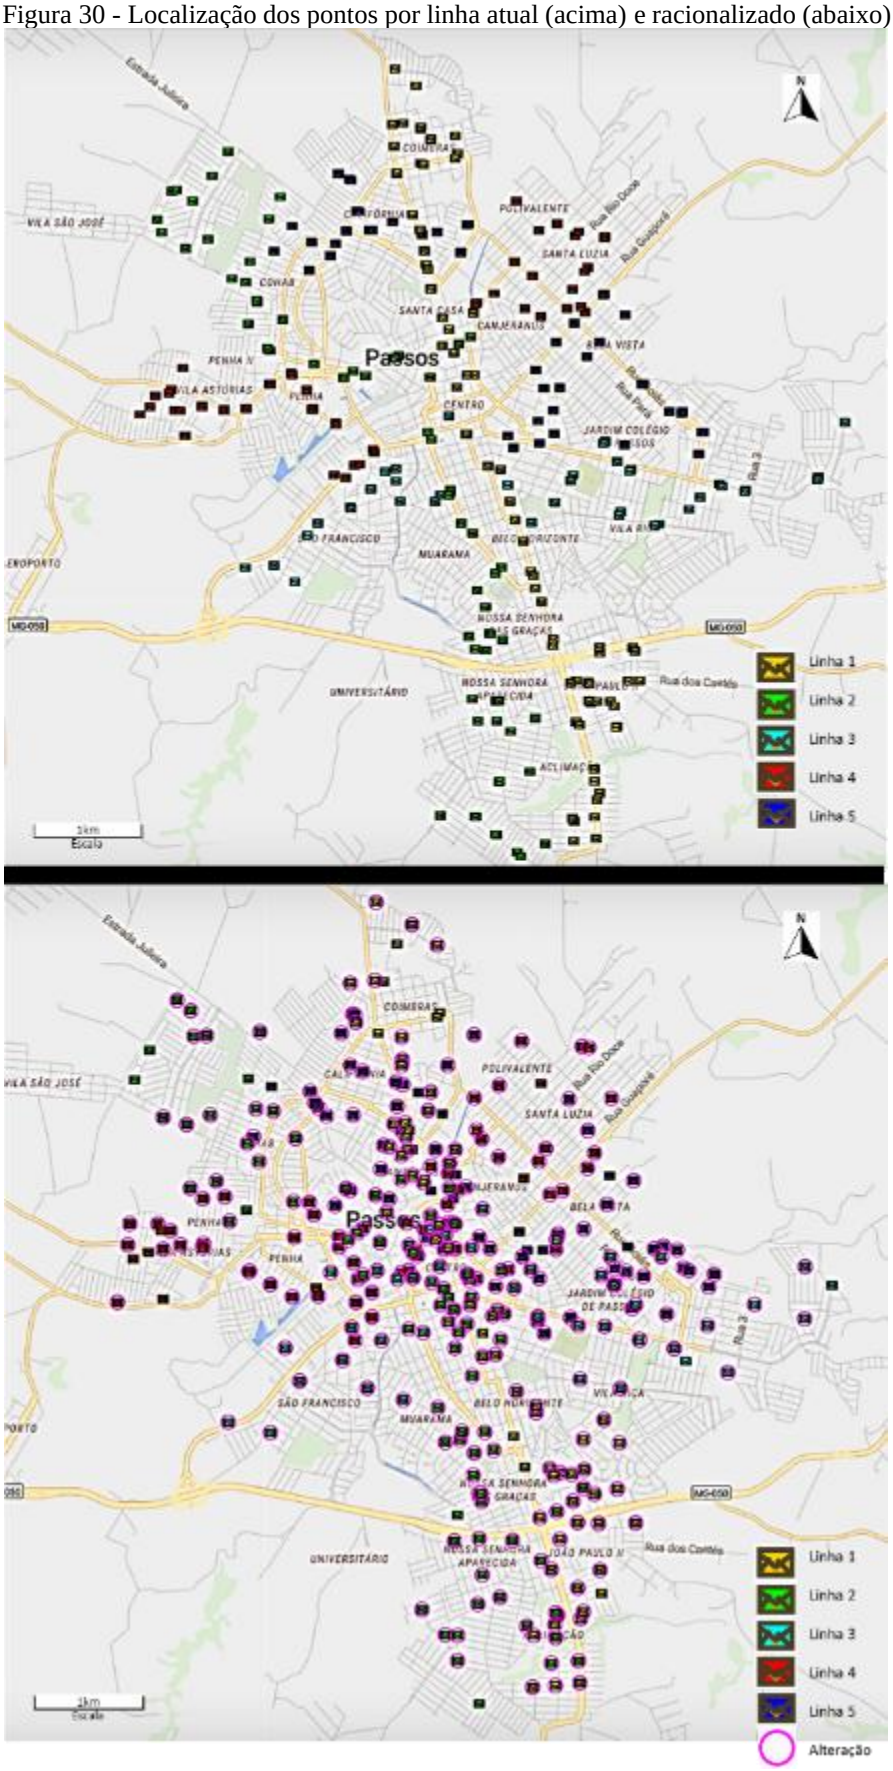

Fonte: Elaborado pelo autor (2026).

Uma limitação observada foi a consistência topológica das novas localizações. As ações do *Q-Learning* alteraram latitude e longitude por incrementos definidos, sem restringir o espaço de ações aos nós ou segmentos válidos da rede viária. Por isso, algumas posições com melhoria na função de recompensa foram situadas em áreas sem ruas, calçadas ou condições físicas adequadas à implantação. Esse resultado demonstra que o desempenho no indicador de acessibilidade, isoladamente, não assegura a viabilidade locacional, sendo necessário considerar infraestrutura pedonal, geometria viária, segurança e condições operacionais do entorno, corroborando com Sahu *et al.* (2021), Zannat, Adnan e Dewan (2020) e Santos, Oliveira e Simões (2026).

As coordenadas produzidas foram, portanto, interpretadas como localizações candidatas e submetidas à avaliação qualitativa. Em futuras implementações, essa limitação poderá ser reduzida pela definição prévia de posições admissíveis, pela projeção automática para o segmento viário mais próximo, pela rejeição de ações fora da rede ou pela inclusão de penalidades de inviabilidade na função de recompensa.

A avaliação dos 294 pontos confrontou as coordenadas sugeridas com atributos da infraestrutura urbana, como largura e geometria das vias, pavimentação, conflitos de tráfego e infraestrutura pedonal. Adotou-se uma matriz com três níveis de viabilidade, exemplificada no Quadro 24:

- Alta: localização com condições de viabilidade de implantação;
- Média: localização passível de implantação após adequações complementares;
- Baixa: localização não recomendada ou tecnicamente inviável nas condições existentes.

Quadro 24 - Exemplo de análise da alteração para os pontos racionalizados

Linha	NPonto	Latitude Original	Longitude Original	Melhor Latitude	Melhor Longitude	Deslocamento	Viabilidade Prática	Observação
1	1	-20,7552	-46,6007	-20,7492	-46,6027	696,46	Alta	Implantação viável
1	7	-20,7423	-46,6009	-20,7363	-46,6009	664,56	Baixa	Posição sem vias
1	32	-20,6998	-46,6138	-20,7078	-46,6138	886,07	Média	Rua estreita

Fonte: Elaborado pelo autor (2026).

O diagnóstico completo encontra-se no Apêndice B. Quando as soluções recaíram sobre lotes privados ou áreas sem acesso veicular, considerou-se a via pública mais próxima como referência para a avaliação da alternativa de implantação, sem tratá-la como nova solução produzida pelo algoritmo. A inspeção remota das seções viárias, realizada com apoio do Google Maps, é exemplificada na Figura 31.

Figura 31 - Análise da nova localização do ponto 1 linha 1

Fonte: Elaborado pelo autor (2026).

A auditoria indicou que 94,22% das posições apresentaram alta viabilidade e 3,06%, média viabilidade, totalizando 97,28% de soluções potencialmente aplicáveis, conforme apresentado no Tabela 13. Apenas 2,72% foram classificadas como de baixa viabilidade. Nesses casos, apesar do desempenho favorável no indicador de Ingram (1971), foram identificadas restrições associadas à geometria viária, à segurança ou à desconexão em relação às vias disponíveis, como exemplificado para o ponto 7 da Linha 1 na Figura 32.

Tabela 13 - Índices de viabilidade qualitativa dos pontos racionalizados

Viabilidade Prática	Quantidade	Percentual
Alta	277	94,22%
Média	9	3,06%
Baixa	8	2,72%

Fonte: Elaborado pelo autor (2026).

Essas ocorrências não invalidam a modelagem, mas delimitam o papel do RL como instrumento de apoio à decisão. O algoritmo identifica configurações favoráveis sob a função de recompensa adotada, enquanto a implementação requer avaliação complementar de especialistas quanto à legislação, à segurança, à infraestrutura e à viabilidade construtiva. A inteligência artificial, portanto, complementa, mas não substitui, o julgamento técnico no planejamento urbano.

Figura 32 - Análise da nova localização do ponto 7, linha 1

Fonte: Elaborado pelo autor (2026).

Como implicações práticas, os resultados permitem recomendar a realização periódica de auditorias locacionais apoiadas por indicadores de acessibilidade; a priorização de investimentos em pontos e infraestrutura pedonal nas áreas com menor cobertura; a incorporação da MSH ao planejamento de rotas e concessões; e o emprego de sistemas inteligentes de apoio à decisão orientados por dados.

Desse modo, o *framework* converte dados espaciais, comportamentais e operacionais em evidências para o planejamento do transporte público. Sua principal contribuição não consiste em substituir a decisão técnica, mas em estruturar a análise de alternativas e antecipar seus efeitos em ambiente virtual. A Figura 33 sintetiza as etapas globais de aplicação do *framework* e os principais resultados obtidos.

Figura 33 - Resumo gráfico do Framework

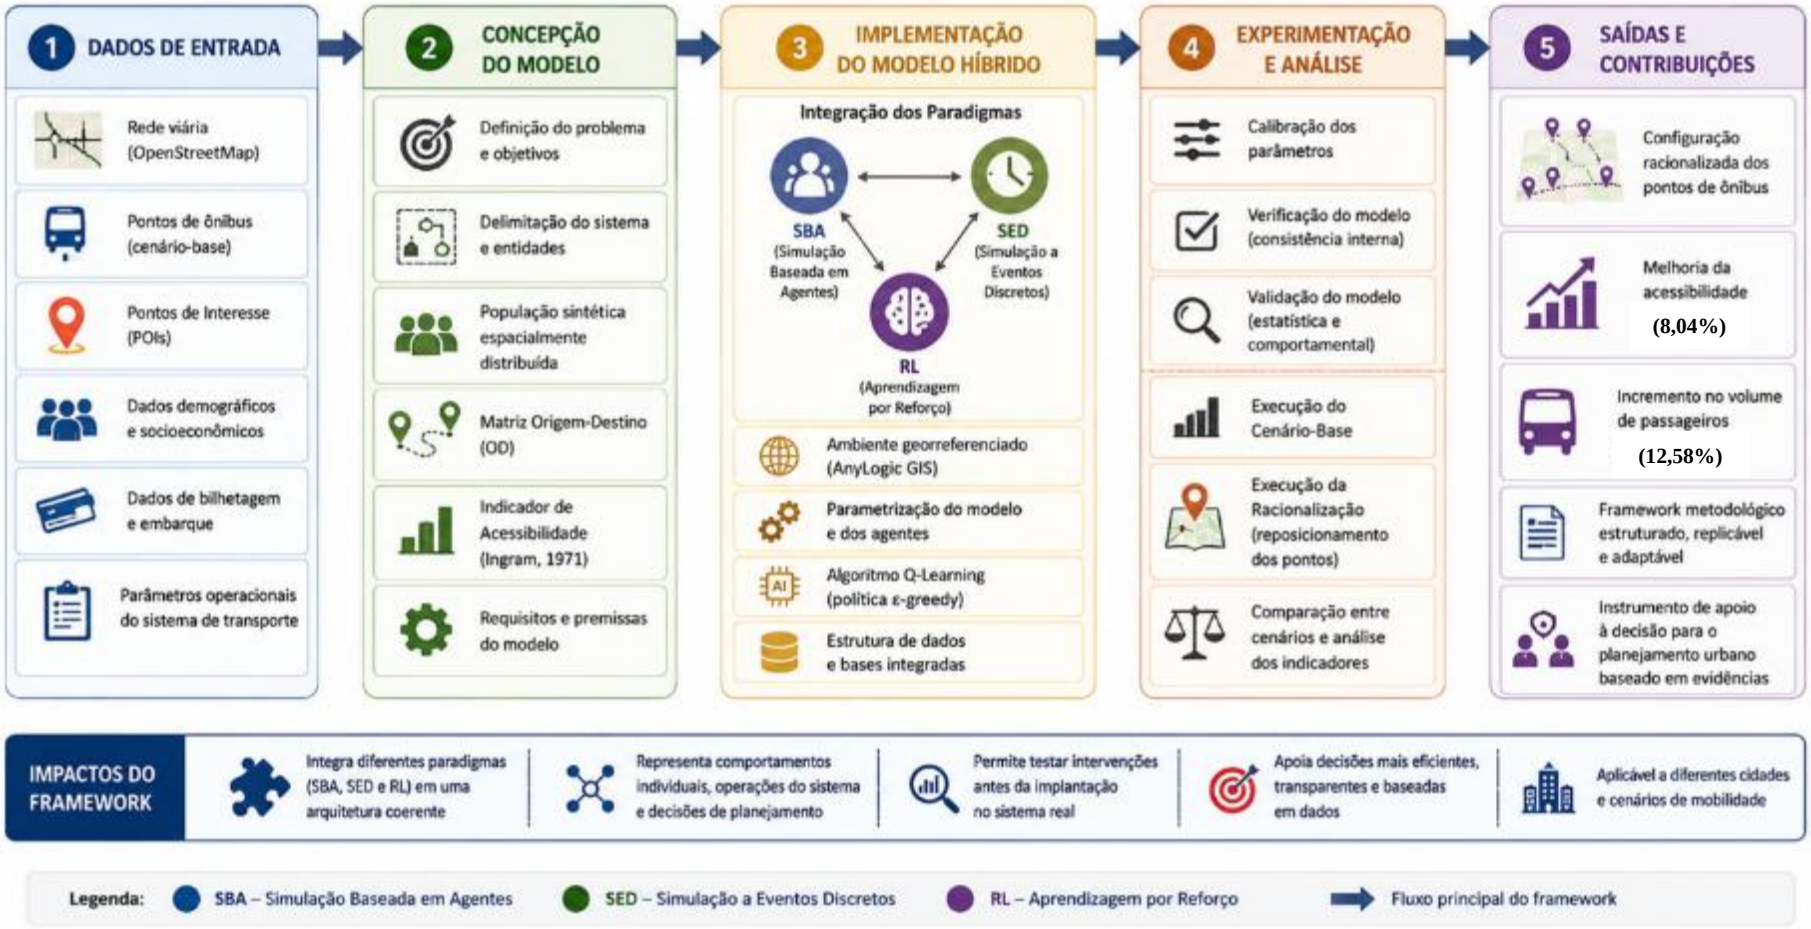

Fonte: Elaborado pelo autor (2026).

6 CONCLUSÕES

A mobilidade urbana permanece como um dos principais desafios das cidades contemporâneas, especialmente diante do crescimento populacional, da expansão territorial e da necessidade de utilização mais eficiente dos recursos destinados ao transporte coletivo. Nesse contexto, a racionalização da localização dos pontos de parada apresenta potencial para ampliar a acessibilidade da população e aperfeiçoar a organização espacial dos sistemas de transporte. Paralelamente, os avanços da modelagem computacional e da inteligência artificial ampliam as possibilidades de experimentação e apoio à decisão em sistemas urbanos complexos.

Esta tese teve como objetivo geral desenvolver um *framework* metodológico de Modelagem e Simulação Híbrida para apoiar a racionalização da localização de pontos de parada do transporte público urbano, integrando Simulação Baseada em Agentes, Simulação a Eventos Discretos e Aprendizagem por Reforço com base em medidas de acessibilidade e utilização do sistema. Considera-se que esse objetivo foi alcançado no escopo estabelecido, mediante a construção de uma estrutura capaz de articular as dimensões comportamental, espacial, operacional e decisória do transporte público.

A pergunta de pesquisa, relacionada à forma de estruturar essa integração, foi respondida pela proposição de um *framework* organizado nas fases de concepção, implementação, análise e experimentação. A estrutura relaciona dados de entrada, agentes, processos, indicadores, procedimentos de verificação e validação e mecanismos de racionalização. Sua contribuição, portanto, não se restringe ao modelo desenvolvido para Passos/MG, mas compreende uma orientação metodológica adaptável a outros sistemas de transporte e contextos urbanos.

Quanto aos objetivos específicos, a Revisão Sistemática da Literatura, conduzida conforme o protocolo PRISMA, sistematizou os fundamentos, as aplicações e as lacunas da Modelagem e Simulação Híbrida em mobilidade urbana. Identificaram-se a escassez de abordagens que integrem explicitamente SBA, SED e RL e limitações recorrentes de documentação, padronização e verificação e validação. Esses resultados forneceram os requisitos conceituais para a elaboração do *framework*.

A arquitetura metodológica foi formalizada pela definição de suas fases, componentes, agentes, interações, indicadores e procedimentos de avaliação. Esse produto organiza conhecimentos dispersos na literatura e estabelece uma sequência coerente para o

desenvolvimento de modelos híbridos de transporte público, favorecendo transparência, replicabilidade e adaptação.

Já a implementação computacional demonstrou a viabilidade de operacionalizar o *framework* em um ambiente híbrido e georreferenciado. O modelo reuniu população sintética espacialmente distribuída, matrizes origem-destino, rede viária obtida pelo OpenStreetMap, pontos de interesse urbanos, decisões individuais dos passageiros e processos relacionados à circulação dos ônibus e à utilização das paradas. Assim, foi possível representar conjuntamente aspectos comportamentais, espaciais e operacionais do sistema.

A validade e a aplicabilidade do *framework* foram avaliadas no transporte público urbano de Passos/MG. Os parâmetros comportamentais e operacionais foram calibrados e comparados com dados reais de embarque e bilhetagem, complementados por procedimentos de verificação, validação estatística e inspeção dos comportamentos simulados. Embora esses procedimentos não assegurem validade universal, fornecem evidências de que o modelo representou de maneira coerente o sistema investigado.

Para analisar os efeitos da racionalização, incorporou-se um algoritmo *Q-Learning* tabular sob política ε-greedy. Sua recompensa foi composta pela soma do ganho percentual no indicador global de acessibilidade e do ganho percentual no número de usuários efetivamente atendidos, com pesos iguais. Dessa forma, cada ação foi avaliada por seus efeitos locacionais e sobre a cobertura da demanda. O algoritmo constituiu uma alternativa de operacionalização da etapa de RL prevista no *framework*, não sendo o produto central da tese nem uma técnica considerada superior às demais apresentadas na revisão teórica.

A configuração racionalizada apresentou melhoria de 8,04% no indicador global de acessibilidade e aumento de 12,58% no número de usuários atendidos, em comparação ao cenário-base. A recompensa composta orientou o aprendizado para soluções que conciliaram eficiência locacional e cobertura da demanda, mitigando o *trade-off* observado na formulação inicial, na qual a redução isolada do indicador poderia afastar usuários de suas paradas. Esses ganhos foram obtidos mediante alteração exclusiva da localização dos pontos, mantendo-se constantes linhas, itinerários, frequências, frota e capacidade dos veículos.

Diante das evidências produzidas, considera-se que a hipótese da pesquisa foi corroborada no contexto analisado. A integração entre SBA, SED e RL permitiu representar, em um mesmo ambiente computacional, as decisões dos passageiros, os processos operacionais e o mecanismo de racionalização dos pontos de parada. A configuração obtida apresentou desempenho superior ao cenário-base nas duas dimensões avaliadas, demonstrando a

capacidade do *framework* de apoiar a identificação de intervenções espacialmente mais favoráveis sem reduzir a cobertura da demanda.

Os impactos da estrutura proposta são predominantemente metodológicos, mas foram reforçados pelos resultados empíricos. O *framework* integra diferentes paradigmas de simulação, explicita as relações entre comportamentos individuais, processos operacionais e decisões locacionais e permite testar intervenções antes de sua eventual implantação. A obtenção simultânea de melhoria na acessibilidade e aumento no número de usuários demonstra que a estrutura também pode produzir evidências quantitativas relevantes para o planejamento.

A aplicação deste *framework* ao longo da pesquisa também permitiu identificar qualitativamente benefícios quando comparado à construção iniciada diretamente pela programação do modelo de simulação. A condução sistematizada pelas etapas de concepção, implementação, verificação, validação e experimentação induziu a explicitação progressiva de elementos que inicialmente não haviam sido previstos, incluindo: parâmetros; variáveis; regras comportamentais e operacionais; e relações necessárias à representação do sistema. O desenvolvimento prévio dessas etapas também favoreceu a identificação e a análise antecipada de constructos, indicadores e equacionamentos que posteriormente precisaram ser incorporados ao modelo computacional. Dessa forma, o *framework* atuou não apenas como uma estrutura de documentação do processo já realizado, mas como um instrumento orientador da própria construção da pesquisa, reduzindo decisões ad hoc e contribuindo para maior rastreabilidade entre o problema investigado, o modelo conceitual, sua implementação computacional e os experimentos realizados.

A escolha do AnyLogic® mostrou-se adequada à operacionalização do *framework* por permitir a integração entre SBA, SED, representação georreferenciada e mecanismos de racionalização em um único ambiente. Essa característica reduziu a necessidade de sincronização entre plataformas e possibilitou avaliar conjuntamente efeitos espaciais, comportamentais e operacionais. Entretanto, ferramentas especializadas em Simulação Dinâmica, microssimulação de tráfego ou Sistemas de Informações Geográficas podem oferecer maior profundidade em tarefas específicas. Assim, o AnyLogic® apresentou aderência aos requisitos da aplicação, mas não superioridade em relação a outros softwares.

A principal contribuição científica da tese reside na proposição de um *framework* metodológico estruturado, documentado e adaptável para o desenvolvimento de modelos híbridos aplicados ao planejamento do transporte público. A pesquisa também demonstra como medidas de acessibilidade e utilização do sistema podem estabelecer a conexão entre análise espacial, simulação híbrida e Aprendizagem por Reforço. Ao transformar as variações dessas

dimensões em sinais de recompensa, o modelo avalia decisões locacionais tanto pela proximidade às oportunidades quanto por seus efeitos sobre a população atendida.

Entre as limitações, destaca-se que o *framework* foi avaliado em um único objeto de estudo. Embora a aplicação tenha empregado dados reais, ambiente georreferenciado, população sintética e procedimentos de calibração e validação, as características de Passos/MG e a disponibilidade de informações restringem a generalização direta dos resultados. O modelo considerou predominantemente os deslocamentos a pé e por ônibus, utilizou matrizes OD simuladas diante da defasagem das bases disponíveis. Mantiveram-se constantes itinerários, frequência, frota e capacidade dos veículos para isolar os efeitos do reposicionamento espacial dos pontos e assegurar comparabilidade entre os cenários original e racionalizado.

Outra limitação refere-se à viabilidade topológica das localizações produzidas. As ações do *Q-Learning* modificaram diretamente as coordenadas dos pontos sem restringi-las automaticamente aos segmentos válidos da rede viária. Consequentemente, algumas posições com desempenho favorável foram situadas em áreas sem ruas, calçadas ou condições adequadas de implantação. Essas posições foram tratadas como localizações candidatas e submetidas à avaliação qualitativa, não podendo ser consideradas imediatamente implantáveis.

O desempenho do *Q-Learning* também foi condicionado pela discretização dos estados e ações, pelos hiperparâmetros, pelo número de episódios e passos e pelo custo computacional. A atribuição de pesos iguais aos ganhos de acessibilidade e usuários representou uma escolha de equilíbrio no escopo da aplicação, mas não foi submetida a uma análise sistemática de sensibilidade. Também não foram realizadas otimização abrangente dos hiperparâmetros ou comparação experimental com outros algoritmos. Portanto, os resultados demonstram a viabilidade da formulação adotada, mas não sua configuração ótima.

Apesar dessas limitações, o *framework* permanece válido como estrutura replicável e adaptável, capaz de incorporar novos agentes, indicadores, algoritmos, restrições e fontes de dados. Para ampliar sua robustez e aplicabilidade, recomendam-se os seguintes trabalhos futuros:

- Aplicação e validação externa: aplicar o *framework* em municípios de diferentes portes, morfologias urbanas e configurações de transporte, avaliando sua transferibilidade. Projetos-piloto envolvendo administrações municipais, operadoras e usuários também poderão verificar a aceitabilidade, a viabilidade de implantação e os efeitos reais das localizações propostas;
- Aprimoramento espacial e topológico: incorporar regras para agrupar, excluir ou reposicionar pontos situados abaixo de uma distância mínima entre si, evitando

redundâncias. Recomenda-se também atribuir características às vias, como largura, pavimentação, sentido de circulação, presença de calçadas, ruas sem saída, rodovias e áreas privadas, restringindo ou penalizando localizações inadequadas;

- Ampliação comportamental e operacional: inserir automóveis, motocicletas, bicicletas, veículos de carga, pedestres e sistemas de micromobilidade, permitindo representar interações no espaço viário. O modelo também poderá incorporar capacidade máxima e lotação dos ônibus, recusa de embarque, filas, cumprimento de horários, atrasos e variabilidade dos intervalos, além de viagens discricionárias relacionadas a lazer, compras, academia, saúde e atividades sociais;
- Aprimoramento dos mecanismos de racionalização: otimizar sistematicamente os hiperparâmetros do *Q-Learning* e avaliar diferentes pesos e formas de normalização para os componentes da recompensa. Recomenda-se também comparar o algoritmo com busca local, *Simulated Annealing*, Algoritmos Genéticos, *Particle Swarm Optimization*, SARSA, DQN, PPO e outras técnicas, considerando qualidade das soluções, estabilidade e custo computacional;
- Ampliação da recompensa e integração de dados dinâmicos: incorporar custos, distância de caminhada, tempo de viagem, emissões, lotação, segurança, equidade socioespacial e viabilidade construtiva. A utilização de GPS, bilhetagem eletrônica, sensores e dados de tráfego em tempo real poderá permitir a atualização contínua dos parâmetros e aproximar o modelo de uma estrutura de gêmeo digital urbano.

REFERÊNCIAS

ABAR, S.; THEODOROPOULOS, G. K.; LEMARINIER, P.; O'HARE, F. M. O. Agent based modelling and simulation tools: a review of the state-of-art software. **Computer Science Review**, v. 24, p. 13-33, 2017. DOI: 10.1016/j.cosrev.2017.03.001.

AGÊNCIA MINAS. 2025. **Minas Gerais mantém taxa de desemprego abaixo da média nacional e avança na geração de empregos**. Disponível em: https://agenciaminas.mg.gov.br/noticia/minas-gerais-mantem-taxa-de-desemprego-abaixo-da-media-nacional-e-avanca-na-geracao-de-empregos. Acessado em: 13/07/2025.

ALBACETE, X.; OLARU, D.; PAÜL, V.; BIERMANN, S. Measuring the accessibility of public transport: a critical comparison between methods in Helsinki. **Applied Spatial Analysis and Policy**, v. 10, n. 2, p. 161-188, 2017. DOI: 10.1007/s12061-015-9177-8.

ALHADIDI, T.; RAKHA, H. A. Modeling bus passenger boarding/alighting times: A stochastic approach. **Transportation Research Interdisciplinary Perspectives**, v. 2, p. 100027, 2019. DOI: 10.1016/j.trip.2019.100027.

AL-HAWARI, R.; QASEM, A. G.; SMADI, H.; ARAUYDAH, H.; THEEB, N. A. The effects of pre or post delay variable changes in discrete event simulation and combined DES/system dynamics approaches in modelling supply chain performance. **Journal of Simulation**, v. 16, n. 2, p. 147-165, 2022. DOI: 10.1080/17477778.2020.1764399.

ALVES, R.; LIMA, R. S.; PINHO, A. F.; HOLGUÍN-VERAS, J. Modelo de simulação baseada em agentes para avaliar políticas de distribuição de cargas urbanas do e-commerce. **Transportes**, v. 27, n. 3, 2019. DOI: 10.14295/transportes.v27i3.2034

ARAÚJO, E. B.; DÁVALOS, R. V. Simulação baseada em agentes para transporte individual particular em um município no litoral de Santa Catarina utilizando o MATSim. *In*: Simpósio de Engenharia de Produção, 20, 2022. **Anais do XX SEP 2022.**

BADAKHSHAN, E.; MUSTAFEE, W.; BAHADORI, R. Application of simulation and machine learning in supply chain management: a systhesis of the literature using the SIM-ML literature classification framework. **Computer & Industrial Engineering**, v. 198, 2024, 110649. DOI: 10.1016/j.cie.2024.110649.

BAE; K. H.; MUSTAFEE, N.; LAZAROVA-MOLNAR, S.; ZHENG, L. Hybrid modeling of collaborative freight transportation planning using agent-based simulation, auction-based mechanisms, and optimization. **Simulation: Transactions of the society for modeling and Simulation International**, v. 98, n. 9, p. 753-771, 2022. DOI: 10.1177/00375497221075614.

BALCI, O. Guidelines for successful simulation studies. *In:* WINTER SIMULATION CONFERENCE, 1990, New Orleans, LA. **Anais do WSC 1990.** DOI: 10.1109/WSC.1990.129482.

BANKS, J.; CARSON II, J. S. **Discrete-event system simulation**. Prentice-Hall: Englwood Cliffs. NJ, 1984.

BARBIERI, J. P. **Análise elementar da complexidade de modelos de simulação discretos e híbridos**. 2023. 92f. Tese (Doutorado em Engenharia de Produção) – Universidade Federal de Itajubá, Itajubá/MG.

BARBIERI, J. P. **Análise da representação do fator humano presente em um sistema de manufatura através da simulação híbrida.** 2016. 102 f. Dissertação (Mestrado em Engenharia de Produção) – Universidade Federal de Itajubá, Itajubá/MG.

BASHABSHEH, M. Comprehensive and simulated modeling of a centralized transport robot control system. **International Journal of advanced computer science and applications**, v. 15, n. 5, 2024. DOI: 10.14569/ijacsa.2024.0150552.

BATEMAN, R. E.; BOWDEN, R. O.; GOGG, T. J.; HARRELL, C. R.; MOTT, J. R. A.; MONTEVECHI, J. A. B. **Simulação de sistemas** – aprimorando processos de logística, serviços e manufatura. Rio de Janeiro: Elsevier, 2013.

BELAROUSSI, R.; DELHOUM, Y. Forecasting daily activity plans of a synthetic population in an upcoming district. **Forecasting**, v. 6, p. 378-403, 2024. DOI: 10.3390/forecast6020021.

BERTRAND, J. W.; FRANSOO, J. C. Modelling and Simulation: operations management research methodologies using quantitative modeling. **International Journal of Operations & Production Management**, v.22, n.2, pp.241-264, 2002. DOI: 10.1108/01443570210414338.

BILALI, A.; ENGELHARDT, R.; DANDL, F.; FASTENRATH, U.; BOGENBERGER, K. Analytical and Agent-Based Model to Evaluate Ride-Pooling Impact Factors. **Transportation Research Record**, 2020. DOI: 10.1177/0361198120917666.

BINSFELD, T.; GERLACH, B. Quantifying the benefits of digital supply chain twins - a simulation study in organic food supply chains. **Logistics**, v. 46, n. 6, 2022. DOI: 10.3390/logistics6030046.

BISHOP, C. M. **Pattern Recognition and Machine Learning**. Springer, 2006.

BORSHCHEV, A.; FILIPPOV, A. From System Dynamics and Discrete Event to Practical Agent Based Modeling: Reasons, Techniques, Tools. *In:* INTERNATIONAL CONFERENCE OF THE SYSTEM DYNAMICS SOCIETY, 22, 2004, p. 25-29. **Anais do 22nd ICSDS 2004.**

BOUNADI, N.; BOUSSALIA, S. R.; BELLAOUAR, A. Optmizing Algerian company's delivery fleet with agent-based model in AnyLogic. **Transport and Telecommunication**, v. 24, n. 4, p. 434-442, 2023. DOI: 10.2478/ttj-2023-0034.

BRACARENSE, L. S. F. P.; FERREIRA, J. O. N. Índice de acessibilidade para comparação dos modos de transporte privado e coletivo. **Revista Brasileira de Gestão Urbana**, v. 10, n. 3, p. 600-613, 2018. DOI: 10.1590/2175-3369.010.003.AO08.

BRAILSFORD, S. Introduction to hybrid simulation modelling, **Operational Research Society Simulation Workshop**, p. 37-45, 2023. DOI: 10.36819/SW23.005.

BRAILSFORD, S. C.; ELDABI, T.; KUNC, M.; MUSTAFEE, N.; OSORIO, A. F. Hybrid simulation modelling in operational research: a state-of-the-art review. **European Journal of Operational Research**, v.278, pp.721-737, 2019. DOI: 10.1016/j.ejor.2018.10.025

BRUNETTI, M.; CAMPUZANO, G.; MES, M. Simulation of the internal electric fleet dispatching problem at a seaport: a reinforcement learning approach. *In*: PROCEEDINGS OF THE 2022 WINTER SIMULATION CONFERENCE. **Anais do** WSC 2022. DOI: 10.1109/WSC57314.2022.10015516.

BUYUKOZKAN, G.; ILICAK O. Smart urban logistics: literature review and future directions. **Socio-economic planning sciences**, v. 81, 2022. DOI: 10.1016/j.seps.2021.101197.

CAF TRANSPORTES. 2026. Catálogo de linhas e horários. Disponível em: https://wa.me/c/553535229491. Acesso em: 10/01/2026.

CAMPOS, A. C. Partição de diagramas de estado. 2021. 89f. Dissertação (Mestrado em Engenharia Eletrotécnica e de Computadores.) – Universidade NOVA de Lisboa, Lisboa, Portugal. Disponível em: https://run.unl.pt/bitstream/10362/148841/1/Campos_2022.pdf. Acessado em: 05/05/25.

CARMEN, F. C. A.; IDALIA, F. M. Simulation models for public transportation: a state-of-art review. **Procedia Computer Science**, n. 217, p. 562-569, 2023. DOI: 10.1016/j.procs.2022.12.252.

CASTILLO, V. E.; BELL, J. E.; MOLLENKOPF, D. A.; STANK, T. P. Hybrid last mile delivery fleets with crowdsourcing: a systems view of managing the cost-service trade-off. **Journal of Business Logistics**, v. 43, n. 1, p. 36-61, 2022a. DOI: 10.1111/jbl.12288.

CASTILLO, V. E.; MOLLENKOPF, D. A.; BELL, J. E.; ESPER, T. L. Designing technology for on-demand delivery: the effect of customer tipping on crowdsourced driver behavior and last mile performance. **Journal of Operational Management**, v. 68, n. 5, p. 424-453, 2022b. DOI: 10.1002/joom.1187.

CASTRELLON, J. P.; SANCHEZ-DIAZ, I.; ROSO, V.; ALTUNTAS-VURAL, C.; ROGERSON, S.; SANTÉN, V.; KALAHASTRHI, L. K. Assessing the eco-efficiency benefits of empty container repositioning strategies via dry ports. **Transportation Research Part D**, v. 120, 2023, 103778. DOI: 10.1016/j.trd.2023.103778.

CATS, O.; WEST, J.; ELIASSON, J. A dynamic stochastic model for evaluating congestion and crowding effects in transit systems. **Transportation Research Part B**, v. 89, p. 43-57, 2016. DOI: 10.1016/j.trb.2016.04.001.

CEDER, A. **Public Transit Planning and Operation**: Theory, Modeling and Practice. Oxford: Elsevier, 2007.

CHADEGANI, A. A.; SALEHI, H.; YUNUS, M. M.; FARHADI, H.; FOOLADI, M.; EBRAHIM, N. A. A comparison between two main academic literature collections: web os science and scopu databases. **Asian Social Science**, v. 9, n. 5, 2013. DOI: 10.48550/arXiv.1305.0377.

CHADI, M. A.; MOUSANNIF, H. Understanding Reinforcement Learning Algorithms: The Progress from Basic Q-Learning to Proximal Policy Optimization. **arXiv** preprint, 2023. DOI: arXiv:2304.00026.

CHALLAPALLI, S. S. A. Optimizing Dallas-Fort Worth bus transportation system using AnyLogic. **Journal of Sensors, IoT & Health Sciences**, v. 2, n. 4, p. 40-55, 2024. DOI: 10.69996/jsihs.2024020.

CHRISNAWATI, Y.; SUSILO, Y. O. Dynamic demand patterns in the profit optimisation of bike-sharing station locations: an agent-based analysis of the greater Vienna region. **Transportation Planning and Technology**, v. 47, n. 6, p. 852-874, 2024. DOI: 10.1080/03081060.2024.2352737.

CHWIF, L.; MEDINA, A. **Modelagem e Simulação de Eventos Discretos**: Teoria e Aplicações. 4. Ed. Elsevier Brasil, 2014.

CIPRIANI, E.; GORI, S.; PETRELLI, M. Transit network design: A procedure and an application to a large urban area. **Transportation Research Part C: Emerging Technologies**, v. 20, n. 1, p. 3-14, 2012. DOI: 10.1016/j.trc.2010.09.003

CISTERNA, C.; BIGI, F.; NAKAO, H.; VITI, F. Assessing the willingness to pay for Mobility-as-A-Service: An Agent-Based approach. **Case Studies on Transport Policy**, v. 17, p. 101221, 2024. DOI: 10.1016/j.cstp.2024.101221.

CNEFE. 2022 (online). Cadastro Nacional de Endereços para Fins Estatísticos. Disponível em: https://www.ibge.gov.br/estatisticas/sociais/populacao/38734-cadastro-nacional-de-enderecos-para-fins-estatisticos.html?=&t=o-que-e . Acesso em: 01/10/2026.

CRAMER, F.; FIKAR, C. Investigating crowd logistics platform operations for local food distribution. **International Journal of Retail & distribution Management**, v. 52, n. 7, 2024. DOI: 10.1108/ijrdm-10-2022-0400.

CUNHA, J.; REIS, V.; TEIXEIRA, P. Development of an agent-based model for railway infrastructure project appraisal. **Transportation**, n. 49, p. 1649-1681, 2022. DOI: 10.1007/s11116-021-10223-2.

CURRENT, J.; DASKIN, M.; SCHILLING, D. **Discrete network location models**. In: Facility Location: Applications and Theory. Springer, p. 81-118, 2002.

DATAVIVA.INFO. 2025 (online). **Perfil geral de Passos/MG**. Disponível em: https://www.dataviva.info/pt/location/4mg070310. Acessado em: 13/07/2025.

DELLING, D.; SANDERS, P.; SCHULTES, D.; WAGNER, D. **Engineering route planning algorithms**. *In*: Algorithmics of Large and Complex Networks. Springer, p. 117-139, 2009.

DIALLO, A. O.; DONIEC, A.; LOZENGUEZ, G.; e MANDIAU, R. Agent-based simulation from anonymized data: an application to Lille metropolis. **Procedia Computer Science**, v. 184, p. 164-171, 2021. DOI: 10.1016/j.procs.2021.03.027.

EPTV 1. Passos perdeu quase 1 mil habitantes na zona rural em 12 anos, apontam dados do Censo divulgados pelo IBGE. 2024. Disponível em: https://g1.globo.com/mg/sul-de-minas/noticia/2024/11/15/passos-perdeu-quase-1-mil-habitantes-na-zona-rural-em-12-anos-apontam-dados-do-censo-divulgados-pelo-ibge.ghtml . Acessado em: 30/05/2026.

ERCAN, R.; ONAT, N. C.; KEYA, N.; TATARI, O.; ELURU, N.; KUCUKVAR, M. Autonomous electric vehicles can reduce carbon emissions and air pollution in cities. **Transportation Research Part D**, v. 112, 2022, 103472. DOI: 10.1016/j.trd.2022.103472.

FARAHANI, R. Z.; FALLAH, S.; RUIZ, R.; HOSSEIN, S.; ASGARI, N. OR models in urban service facility location: A critical review of applications and future developments. **European Journal of Operational Research**, v. 276, n. 1, p. 1-27, 2019. DOI: 10.1016/j.ejor.2018.07.036.

FARHAN, M.; KREJCI, C. C.; CANTOR, D. E. A. Do a non-core worker's procedural justice concerns influence their engagement in helping behavior? A multi-method study. **International Journal of physical distribution & logistics management**, v. 53, n. 9, p. 1015-1042, 2023. DOI: 10.1108/ijpdlm-02-2022-0044.

FARIA, C. H.; PINTO, L. R.; ALMEIDA, J. F. F.; BRETAS, A. M. C. Sustainable and integrated rail operations planning for grains exports. **Journal of Simulation**, p. 1-18, 2024. DOI: 10.1080/17477778.2024.2302616.

FERREIRA JUNIOR, J. S.; LIMA, J. P.; PINHO, A. F. Modelagem e Simulação Axiomática Descritiva Baseada em Agentes da Linha 1 do transporte coletivo por ônibus de Passos/MG *In*: SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL, 56, 2024. **Anais do LVI SBPO 2024**. DOI: 10.59254/sbpo-2024-193853.

FERREIRA JUNIOR, J. S.; LIMA, J. P.; PINHO, A. F. Hybrid Modeling and Simulation for Urban Mobility: A Systematic Review and Future Research Agenda. **IEEE Access**, vol. 14, pp. 80237-80251, 2026. DOI: 10.1109/ACCESS.2026.3694240.

FRANCO, P.; JOHNSTON, R.; McCORMICK, E. Demand responsive transport: Generation of activity patterns from mobile phone network data to support the operation of new mobility services. **Transportation Research Part A: Policy and Practice**, v. 131, p. 244-266, 2020. DOI: 10.1016/j.tra.2019.09.038.

GEURS, K. T.; VAN WEE, B. Accessibility evaluation of land-use and transport strategies: review and research directions. **Journal of Transport Geography**, v. 12, n. 2, p. 127-140, 2004. DOI: 10.1016/j.jtrangeo.2003.10.005.

GRIMM, V. *et al.* A standard protocol for describing individual-based and agent-based model. **Ecological Modelling**, vol. 198, nº 1-2, pp. 115-126, 2006. DOI: 10.1016/j.ecolmodel.2006.04.023.

HAMADNEH, J.; ESZTERGAR-KISS, D. Evaluation of the impacts of autonomous vehicles on the mobility of user groups by using agent-based simulation. **Transport**, v. 37, p. 1-16, 2022. DOI: 10.3846/transport.2022.16322.

HAREL, S. Statecharts: a visual formalism for complex systems. **Science of computer programming**, v. 8, p. 231-274, 1987. DOI: 10.1016/0167-6423(87)90035-9.

HARKS, T.; JÄGER, S.; MARKL, M.; SCHIEWE, P. Computing User Equilibria for Schedule-Based Transit Networks with Hard Vehicle Capacities. **Computer Science and Game Theory**, 2024. DOI: 10.48550/arXiv.2406.17153.

HONG, J.; JUNG, W. S. Application of gravity model on the Korean urban bus network. **Physica A**, v. 462, p. 48-55, 2016. DOI: 10.1016/j.physa.2016.06.055.

HU, H.; LI, J.; WU, S. Simulation evaluation of a current limiting scheme in an urban rail transit network. **Sustainability**, v. 15, 2023, 375. DOI: 10.3390/su15010375.

HUANG, J.; CUI, Y.; ZHANG, L.; TONG, W.; SHI, Y.; LIU, Z. An overview of agent-based models for transport simulation and analysis. **Journal of Advanced Trasnportation**, 2022. DOI: 10.1155/2022/1252534.

HUSSEIN, M.; KARAM, A.; ELTOUKHY, A. E. E.; DARKO, A.; ZAYED, T. Optimized multimodal logistics planning of modular integrated construction using hybrid multi-agent and metamodeling. **Automation in construction,** v. 145, 2023, 104637. DOI: 10.1016/j.autcon.2022.104637.

IBGE CIDADES. 2025 (online). **Panorama de Passos/MG**. Disponível em: https://cidades.ibge.gov.br/brasil/mg/passos/panorama. Acesso em: 13/07/2025.

IBGE Notícias. Indicadores educacionais avançam em 2024, mas atraso escolar aumenta. 2024. Disponível em: https://agenciadenoticias.ibge.gov.br/agencia-noticias/2012-agencia-de-noticias/noticias/43699-indicadores-educacionais-avancam-em-2024-mas-atraso-escolar-aumenta . Acesso em: 28/04/2026.

INGRAM, D. R. The concept of accessibility: a search for an operational form. **Regional Studies**, v. 5, n. 2, p. 101–107, 1971.

JANG, B.; KIM, M.; HARERIMANA, G.; KIM, J. W. Q-Learning Algorithms: A Comprehensive Classification and Applications. **IEEE Access**, v. 7, 2019. DOI: 10.1109/ACCESS.2019.2941229.

JIMENEZ, R. C.; LEE, T.; ROSILLO, N.; CORDOVA, R.; CREE, I. A.; GONZALEZ, A.; RUIZ, B. I. I. Machine learning computational tools to assist the performance of systematic reviews: A mapping review. **BMC Medical Research Methodology,** v. 22, n. 322, 2022. DOI: 10.1186/s12874-022-01805-4.

KABOUDVAND, S.; MONTREUIL, B. Simulation-based assessment of hyperconnected megacity parcel logistics. **Logistics**, v. 66, n. 8, 2024. DOI: 10.3390/logistics8030066.

KADOSH, S. C.; SIMUANY-STERN, Z.; BITAN, Y. Location of emergency treatment sites after earthquake using hybrid simulation. **Preliminary communication**, v. 17, n. 3, p. 391-396, 2023. DOI: 10.31803/tg-20230511184836.

KAELBLING, L. P.; LITTMAN, M. L.; MOORE, A. W. Reinforcement learning: A survey. **Journal of artificial intelligence research**, v. 4, p. 237-285, 1996. DOI: 10.1613/jair.301.

KAGHO, G. O.; HENSLE, D.; BALAC, M.; FREEDMAN, J.; TWUMASI-BOAKYE, R.; BROADDUS, A.; FISHELSON, J.; AXHAUSEN, K. W. Demand responsive transit simulation of Wayne County, Michigan. Transportation Research Board, v. 2675, n. 12, p. 702-716, 2021. DOI: 10.1177/03611981211031221.

KAPATSILA, B.; SANTANA PALACIOS, M.; GRISÉ, E.; EL-GENEIDY, A. Resolving the accessibility dilemma: comparing cumulative and gravity-based measures of accessibility in eight Canadian cities. **Journal of Transport Geography**, v. 107, art. 103530, 2023. DOI: 10.1016/j.jtrangeo.2023.103530.

KASHIYAMA, T.; PANG, Y. B.; SHIBUYA, Y.; YABE, T.; SEKIMOTO, Y. Nationwide synthetic human mobility dataset construction from limited travel surveys and open data. **Computer-aided Civil and Infrastructure Engineering**, v. 21, p. 3337-3352, 2024. DOI: 10.1111/mice.13285.

KHATTAK, A.; HUSSAIN, A. Hybrid DES-PSO framework for the design of comuuters' circulation space at multimodal transport interchange. **Mathematics and Computers in Simulation**, v. 180, p. 205-229, 2021. DOI: 10.1016/j.matcom.2020.08.025.

KLAR, B.; LEE, J.; LONG, J. A.; DIAB, E. The impacts of accessibility measure choice on public transit project evaluation: a comparative study of cumulative, gravity-based, and hybrid approaches. **Journal of Transport Geography**, v. 106, art. 103508, 2023. DOI: 10.1016/j.jtrangeo.2022.103508.

KLASOVITÁ, V.; CORMAN, F. Network design, line planning and timetabling in public transport systems with uncertain parameters: A literature review. **EURO Journal on Transportation and Logistics**, v. 15, p. 100174, 2026. DOI: 10.1016/j.ejtl.2026.100174.

KULKARNI, K.; KUJALA, P.; MUSHARRAF, M. RAINIO, I. Simulation tool for winter navigation decision support in the Baltic Sea. **Applied Sciences**, v. 12, 2022, 7568. DOI: 10.3390/app12157568.

LAW, A. M. Simulation of manufacturing systems. *In*: WINTER SIMULATION CONFERENCE 1988. **Anais do WSC 1988**. DOI: 10.1109/WSC.1998.744898.

LEAL, F.; ALMEIDA, D. A.; MONTEVECHI, J. A. B. Uma Proposta de Técnica de Modelagem Conceitual para a Simulação através de elementos do IDEF. *In*: SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL, 45, João Pessoa, 2008. **Anais do XL SBPO, João Pessoa, SOBRAPO 2008.**

LEOBONS, C. M.; CAMPOS, V. B. G.; BANDEIRA, R. A. M. Assessing urban transportation systems resilience: a proposal of indicadors. **Transportation Research Procedia,** v. 37, p. 322-329, 2019. DOI: 10.1016/j.trpro.2018.12.199.

LESSA; D. A.; LOBO, C.; CARDOSO, L. Accessibility and urban mobility by bus in Belo Horizonte/ Minas Gerais – Brazil. **Journal of Transport Geography**, v. 77, p. 1-10, 2019. DOI: 10.1016/j.jtrangeo.2019.04.004.

LI, R.; XU, B.; LU, W.; CHEN, Z.; ZHANG, S.; XIA, F. The parameter calibration of social force model for pedestrian flow simulation based on YOLOv5. **Sensors**, v. 24, p. 5011, 2024.

LIBERTO, C.; NIGRO, M.; CARRESE, S.; MANNINI, L.; VALENTI, G.; ZARELLI, C. Simulation framework for pedestrian dynamics: Modelling and calibration. **IET Intelligent Transport Systems**, v. 14, n. 9, p. 1048-1057, 2020. DOI: 10.1049/iet-its.2019.0677.

LIU, W.; WANG, F.; ZHANG, C.; WANG, L. A simulation study of urban public transport transfer station based on AnyLogic. **KSII Transactions on internet and information systems**, v. 15, n. 4, 2021. DOI: 10.3837/tiis.2021.04.002.

LU, W.; YI, Z.; GIDOFALVI, G.; SIMONI, M. D.; RUI, Y. RAN, B. Urban network geofencing with dynamic speed limit policy via deep reinforcement learning. **Transportation Research Part A**, v. 183, 2024. DOI: 10.1016/j.tra.2024.104067.

MACAL, C. M. Everything you need to know about agent-based modelling and simulation. **Journal of Simulation**, v. 10, p. 144-156, 2016. DOI: 10.1057/jos.2016.7.

MACAL, C. M.; NORTH, M. J. Agent-based modeling and simulation. *In*: WINTER SIMULATION CONFERENCE, 2009. **Anais do WSC 2009**. DOI: 10.1109/WSC.2009.5429318.

MAGGI, E.; VALLINO, E. Price-based and motivation-based policies for sustainable urban commuting: An agent-based model. **Research in Transportation Business and Management**, v. 39, p. 100588, 2021. DOI: 10.1016/j.rtbm.2020.100588.

MAHMOUDI, R.; SAIDI, S.; EMROUZNEJAD, A. Mathematical programming in public bus transit design and operations: Emerging technologies and sustainability – A review. **Socio-Economic Planning Sciences**, v. 98, 2025. DOI: 10.1016/j.seps.2025.102155.

MAHMOUDI, R.; SAIDI, S.; WIRASINGHE, S. C. A critical review of analytical approaches in public bus transit network design and operations planning with focus on emerging Technologies and sustainability. **Journal of Public Transportation**, v. 26, 2024. DOI: 10.1016/j.jpubtr.2024.100100.

MAN, C. Y.; SHYR, O. F.; HSU, Y. Y.; SHEPHERD, S.; LIN, H. L.; TU, C. H. Tourism, transport, and land use: a dynamic impact assessment for Kaohsiung's Asia New Bay Area. **Journal of Simulation**, v. 14, n. 4, p. 304-315, 2020. DOI: 10.1080/17477778.2020.1806748.

MANDL, C. Evaluation and optimization of urban public transportation networks. **European Journal of Operational Research**, v. 5, n. 6, p. 396–404, 1980. DOI: 10.1016/0377-2217(80)90126-5.

MANLEY, E.; CHENG, T.; PENN, A.; EMMONDS, A. A framework for simulating large-scale complex urban traffic dynamic through hybrid agent-based modelling. **Computers, Environment and urban system**, v. 44, p. 27-36, 2014. DOI: 10.1016/j.compenvurbsys.2013.11.003.

MANSER, P.; BECKER, H.; HORL, S.; AXHAUSEN, K. W. Designing a large-scale public transport network using agent-based microsimulation. **Transportation Research Part A**, v. 137, p. 1-15, 2020. DOI: 10.1016/j.tra.2020.04.011.

MARCONI, M. A.; LAKATOS, E. M. **Metodologia Científica**. 8. ed. São Paulo: Atlas, 2022.

MARTINS, A. L. P. **Integrando o machine learning a um sistema de simulação baseada a agentes**. 2022. 86f. Dissertação (Mestrado em Engenharia de Produção) – Universidade Federal de Itajubá, Itajubá/MG.

MEHDIZADEH, M.; NORDFJAERN, T.; KLOCKNER, C. A. A systematic review of the agent-based modelling/ simulation paradigmin mobility transition. **Technological Forecasting & Social Change**, v. 184, p. 122011, 2022. DOI: 10.1016/j.techfore.2022.122011.

MAHESHWARI, T.; AXHAUSEN, K.W. How will the technological shift in transportation impact cities? A review of quantitative studies on the impacts of new transportation technologies. **Sustainability**, v. 13, n. 6, 2021. DOI: 10.3390/su13063013.

MAZZULLA, G.; PIRRONE, C. G. Accessibility measures: from a literature review to a classification framework. **ISPRS International Journal of Geo-Information**, v. 13, n. 12, art. 450, 2024. DOI: 10.3390/ijgi13120450.

MENDES, J. A.; FERREIRA, M. C. Avaliação de métodos de geocodificação para conversão de agravos localizados em endereços para mapas de pontos em sistema de coordenadas espaciais. *In:* SIMPÓSIO NACIONAL DE GEOGRAFIA DA SAÚDE, Blumenal-SC, 2019. **Anais do SNGS 2019.**

MIEDVIEDIEVA, N.; BAHARII, M. Optimization of the simulation process of product supply from the manufacturer. Science-based Tecnologies, v. 57, n.1, 2023. DOI: 10.18372/2310-5461.57.17449.

MIGUEL, P. A. C. *et al.* **Metodologia de pesquisa em Engenharia de Produção e Gestão de operações**. Rio de Janeiro: Elsevier, 2012.

MITCHELL, T. M. **Machine Learning**. McGraw-Hill, 1997.

MITROFF, I. I.; BETZ, F.; PONDY, L. R.; SAGASTI, F. On managing science in the systems age: two schemas for the study of science as a whole systems phenomenon. **Interfaces**, vol. 4, n. 3, pp. 46-58, 1974.

MOECKEL, R.; KUEHNEL, N.; LLORCA, C.; MORENO, A. T.; RAYAPROLU, H. Agent-based simulation to improve policy sensitivity of trip-based models. **Journal of advanced transportation**, p. 1902162, 2020. DOI: 10.1155/2020/1902162.

MOHRI, M.; ROSTAMIZADEH, A.; TALWALKAR, A. **Foundations of machine learning**. MIT press, 2018.

MONTEVECHI, J. A. B.; LEAL, F.; PINHO, A. F.; COSTA, R. F.; OLIVEIRA, M. L. M.; SILVA, A. L. F. Conceptual modeling in simulation projects by mean adapted IDEF: an application in Brazilian tech company. *In*: WINTER SIMULATION CONFERENCE, 2010. **Anais do WSC 2010**. DOI: 10.1109/WSC.2010.5678908.

MONTGOMERY, D. C.; RUNGER, G. C. **Applied Statistics and Probability for Engineers**, 6 ed. New York: Wiley, p. 832, 2013.

MURAVEV, D.; HU, H.; RAKHMANGULOV, A.; MISHKUROV, P. Multi-agent optimization of the intermodal terminal main parameters by using AnyLogic simulation platform: Case study on the Ningbo-Zhoushan Port. **International Journal of Information Management**, v. 57, 2021, 102133. DOI: 10.1016/j.ijinfomgt.2020.102133.

MUSTAFEE, N.; HARPER, N.; FAKHIMI, M. From conceptualization of hybrid modelling & simulation to empirical studies in hybrid modelling. *In*: WINTER SIMULATION CONFERENCE, 2022. **Anais do WSC 2022**. DOI: 10.1109/WSC57314.2022.10015400.

NGUYEN, K.; SCHUMANN, R. A socio-psychological modal choice approach to modelling mobility and energy demand for electric vehicles, **Energy Informatics**, v. 3, n. 20, 2020. DOI: 10.1186/s42162-020-00123-7.

OH, S.; SESHADRI, R.; AZEVEDO, C. L.; KUMAR, W.; BASAK, K.; BEM-AKIVA, M. Assessing the impacts of automated mobility-on-demand through agent-based simulation: A study of Singapore. **Transportation Research Part A**, v. 138, p. 367-388, 2020. DOI: 10.1016/j.tra.2020.06.004.

OLIVEIRA, R. P.; PEREIRA, L. G.; PINHO, A. F.; LIMA, R. S. Análise e previsão do comportamento de usuários-alvo através da simulação baseada em agentes em um marketplace logístico. *In*: SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL, 54, Juiz de Fora, 2022. **Anais do LIV SBPO 2022**.

OMAR, M. I.; OGUT, K. S. Evaluating the accessibility of collective fixed-route paratransit service in developing cities: A case study of Djibouti. **Transportation Research Interdisciplinary Perspectives**, v. 28, 2024. DOI: 10.1016/j.trip.2024.101270.

ONGGO, F. S.; FORAMITTI, J. Agent-based and Simulation for business and management: a review and tutorial. *In:* WINTER SIMULATION CONFERENCE 2021**. Anais do WSC 2021.** DOI: 10.1109/WSC52266.2021.9715352.

OO, R. M.; LUPIN, S.; KHAING, M. T.; THU, A. Using hybrid modeling for estimation of the efficiency of service systems. *In*: PROCEEDINGS OF THE 2021 IEEE CONFERENCE OF RUSSIAN YOUNG RESEARCHS IN ELECTRICAL AND ELECTRONIC ENGINEERING. **Anais do IEEE ElConRus 2021**. DOI: 10.1109/ElConRus51938.2021.9396596.

PALANCA, J.; TERRASA, A.; RODRIGUEZ, S.; CARRASCOSA, C.; JULIAN, V. An agent-based simulation framework for the study of urban delivery. **Neurocomputing**, n. 423, p. 679-688, 2021. DOI: 10.1016/j.neucom.2020.03.117.

PASSOS1. 2025 (online). **Cartilha do transporte Coletivo**. Disponível em: https://www.passos.mg.gov.br/portal/noticias/0/3/2470/cartilha-de-transporte-coletivo/ . Acessado em 13/07/2025.

PASSOS2. 2025 (online). Dados gerais do município. Disponível em: https://www.passos.mg.gov.br/dados-gerais-do-municipio. Acessado em: 13/07/2025.

PENG, W.; TENG, J.; WANG, H. Understanding heterogeneous passenger route choice in municipal rail transit with express and local trains: an empirical study in Shangai**. Urban Rail Transit**, v. 10, p. 122-143, 2024. DOI: 10.1007/s40864-024-00214-8.

PEREIRA, R. H. M.; HERSZEHHUT, D. **Introduction to Urban Accessibility**: a practical guide with R, Rio de Janeiro: IPEA, 2023, pp. 152.

PESSOA, D. O.; FERREIRA JUNIOR, J. S.; PINHO, A. F.; LIMA, R. S. Developing routes using hybrid simulations: public transport vs. Bike sharing. **International journal of simulation modelling**, v. 24, n. 1, 2025. DOI: 10.2507/IJSIMM24-1-718.

PRAJAPATI, S. P.; BHAUMIK, R.; KUMAR, R. An intelligent ABM-based framework for developing pandemic-resilient urban spaces in Post-COVID Smart cities. **Procedia Computer Science**, n. 218, p. 2299-2308, 2023. DOI: 10.1016/j.procs.2023.01.205.

PRÉDHUMEAU, M.; MANLEY, E. A synthetic population for agent-based modelling in Canada. **Scientific Data**, v. 148, n. 10, 2023. DOI: 10.1038/s41597-023-02030-4.

PSYLLIDIS, A.; GAO, S.; HU, Y.; KIM, E. K.; McKENZIE, G.; PUVERS, R.; YUAN, M.; ANDRIS, C. Points of Interest (POI): a commentary on the state of the art, challenges, and prospects for the futere. **Computational Urban Science**, v. 2, n. 20, 2022. DOI: 10.1007/s43762-022-00047-w.

RASCA, S.; HU. B., BIESINGER, B.; PRANDTSTETTER, M. Agent-based decision-support model for bus route redesign in networks of small cities and towns: case study of Agder, Norway. **Public Transport**, v. 16, p. 583-618, 2024. DOI: 10.1007/s12469-024-00358-7.

REGGELIN, T.; LANG, S.; SCHAUF, C. Mesoscopic discrete-rate-based simulation models for production and logistics planning. **Journal of simulation**, v. 16, n. 5, p. 448-457, 2022. DOI:10.1080/17477778.2020.1841575

ROBINSON, S. Conceptual modeling for simulation. *In*: WINTER SIMULATION CONFERENCE 2013. **Anais do WSC 2013**. DOI: 10.1109/WSC.2013.6721435.

ROBINSON, S. **Simulation**: The Practice of Model Development and Use. Chichester, UK: Wiley, 2004.

RODRIGUES, J. C.; MACHADO, M. L. G.; SOLEDADE, M. S.; LEFUNDES, M. Prevalência de idosos restritos em uma comunidade de salvador, Bahia. *In*: SEPA - SEMINÁRIO ESTUDANTIL DE PRODUÇÃO ACADÊMICA, UNIFACS, 18, 2019. **Anais do XVIII SEPA 2019.** Disponível em: http://www.revistas.unifacs.br/index.php/sepa . Acessado em: 28/04/2026.

ROTH, S.; WERMER-COLAN, A. Machine Learning Methods for Systematic Reviews: A Rapid Scoping Review. **Dela Journal Public Health,** v. 9, n. 4, p. 40-47, 2023. DOI: 10.32481/djph.2023.11.008

RUNBAUGH, J.; JACOBSON, I.; BOOCH, G. The Unifid Modeling Language Reference Manual. Addison-Wesley Longman: Massachusetts, USA, 1999. Disponível em: https://idsi.md/files/file/referinte_utile_studenti/The%20Unified%20Modeling%20Language%20Reference%20Manual.pdf. Acesso em: 05/05/2025.

SAHU, S. K.; MOKHADE, A.; BOKDE, N. D. An Overview of Machine Learning, Deep Learning, and Reinforcement Learning-Based Techniques in Quantitative Finance: Recent Progress and Challenges. **Applied Sciences,** v. 13, n. 3, 2023. DOI: 10.3390/app13031956.

SAMNAMI, S. S.; VASKA, M.; AHMED, S.; TURIN, R. C. Review typology: the basic types of reviews for synthesiging evidence for the purpose of knowledge translation. **Journal of the college of physicious and surgeons Pakistan**, vol. 27, nº 10, pp. 635-641, 2017.

SAMPIERI, R. H.; COLLADO, C. F.; LUCIO, M. P. B. Metodologia de Pesquisa. 5. Ed. São Paulo: McGraw Hall, 2013.

SANTANA, E. F. Z.; COVAS, G.; DUARTE, F.; SANTI, P.; RATTI, C.; KON, F. Transitioning to a driverless city: Evaluating a hybrid system for autonomous and non-autonomous vehicles. **Simulation Modelling Practice and Theory,** v. 107, 2021, 102210. DOI: 10.1016/j.simpat.2020.102210.

SANTOS, J. B.; LIMA, J. P. Quality of public transportation based on the multi-criteria approach and from the perspective of user's satisfaction level: a case study in a Brazilian city. **Case studies on transport policy**, v. 9, p. 1233-1244, 2021. DOI: 10.1016/j.cstp.2021.05.015.

SANTOS, J. B.; LIMA, J. P. Health determinants, applications, and methods: A systematic literature review on the relationships between the urban transport of people and health. **Transportation Research Record**, p. 1-27, 2023. DOI: 10.1177/03611981231170625.

SANTOS, R. L.; OLIVEIRA, H. C.; SIMÕES, D. P. Application of Spatial Data and Analysis for Bus Transportation Optimization and Planning: A State-of-the-Art Review. **IEEE Access**, v. 14, 2026. DOI: 10.1109/ACCESS.2026.3660571.

SARGENT, R. G. Verification and validation of simulation models. **Journal of Simulation**, n. 7, p. 12-24, 2013. DOI: 10.1057/jos.2012.20.

SARGENT, R. G. Verification and Validation of simulation models: an advanced tutorial. *In*: PROCEEDINGS OF THE 2020 EM WINTER SIMULATION CONFERENCE. **Anais do WSC 2020.** DOI: 10.1109/WSC48552.2020.9384052.

SCHELTES, A.; CORREIA, G. H. A. Explaning the use of automated vehicles as last mile connection of train trips through an agent-based simulation model: An application to Delft, Netherlands. **International Journal of Transportation Science na Technology**, v. 6, p. 28-41, 2017. DOI: 10.1016/j.ijtst.2017.05.004.

SCHILLING, D.; JAYARAMAN, V.; BARKHI, R. A review of covering problems in facility location. **Location Science**, v. 1, n. 1, p. 25-55, 1993.

SCHRIBER, T. J.; BRUNNER, D. T.; SMITH, J. S. Inside Discrete-Event Simulation Software: How it Works and Why it Matters. *In:* WINTER SIMULATION CONFERENCE, 2013, P. 424,438. **Anais do WSC 2013.**

SCHUHMANN, F.; NGUYEN, N. A.; SCHWEIZER, J.; HUANG, W. C.; LIENKAMP, M. Creating and validating hybrid large-scale, multi-modal traffic simulations for efficient transport planning. **Smart cities**, v. 8, n. 1, 2025. DOI: 10.3390/smartcities8010002.

SCIMAGO INSTITUTIONS RANKINGS. Prevalência da assistência domiciliar prestada à população idosa brasileira e fatores associados. **Cadernos de saúde pública**, v. 32, n. 3, 2016. DOI: 10.1590/0102-311X00048515.

SCORRANO, M.; DANIELIS, R. Simulation electric vehicle uptake in Italy in the small-to-medium car segment: A system dynamics/agent-based model parametrized with discrete choice data. **Research in Transportation Business & Management**, n. 43, 2022, 100736. DOI: 10.1016/j.rtbm.2021.100736.

SENNE, C. M.; LIMA, J. P.; FAVARETTO, F. A index for the sustainability of integrated urban transport and logistics: the case study of São Paulo. **Sustainability**, v. 13., 2021. DOI: 10.3390/su132112116.

SERENA, L.; MARZOLLA, M.; D'ANGELO, G.; FERRETI, S. Multilevel modeling as a methodology for the simulation of human mobility. *In*: PROCEEDINGS OF THE 2022 INTERNATIONAL SYMPOSIUM ON DISTRIBUTED SIMULATION AND REAL TIME APPLICATION. **Anais do ISDSRTA 2022**. DOI: 10.1109/DS-RT55542.2022.9932080.

SILVA, K. O. A. N.; LIMA, R. S.; ALVES, R. The impacts of the pandemic on urban freight deliveries: a case study in a Brazilian carrier. **International Journal of Simulation Modelling**, v. 23, n. 1, p. 65-76, 2024. DOI: 10.2507/IJSIMM23-1-672.

SILVEIRA, I. H.; OLIVEIRA, B. F. A.; JUNGER, W. L. Utilização do google maps para o georreferenciamento de dados do sistema de informações sobre mortalidade no município do Rio de Janeiro, 2010-2012. **Epidemiologia e Serviços de Saúde**, n. 26, v. 4, p. 881-886, 2017. DOI: 10.5123/S1679-49742017000400018.

SIMONI, M. D.; KOCKELMAN, R. M.; GURUMURTHY, K. M.; BISCHOFF, J. Congestion pricing in a world of self-driving vehicles: an analysis of different strategies in alternative future scenarios. **Transportation Research Part C**, v. 98, p. 167-185, 2019. DOI: 10.1016/j.trc.2018.11.002.

SINGH, A. A simulation-based participatory modelling framework for stakeholder involvement in urban logistics. *In*: WINTER SIMULATION CONFERENCE, 2021, IEEE. **Anais do WSC 2021.** DOI: 10.1109/WSC52266.2021.9715462.

SCHMITT, A.; CALDEIRA, V. M.; CAVALLAZI, J. E.; VALENTE, A. M. Localização De Pontos De Parada No Sistema De Transporte Coletivo Por Ônibus–O Caso De Chapecó/Sc. *In*: CONGRESSO LATINOAMERICANO DE TRANSPORTE PÚBLICO Y URBANO, 20, 2018, Medellín, Colômbia. **Anais do XX ALATPU 2018 Medellín, Colômbia.**

SUTTON, R. S.; BARTO, A. G. **Reinforcement Learning**: An Introduction. 2. ed. Cambridge: MIT Press, 2018.

STEVENS, M.; CORREIA, G. H. D. A.; SCHELTES, A.; van AREM, B. An agent-based model for assessing the financial viability of autonomous mobility on-demand systems used as first and last-mile of public transport trips: A case-study in Rotterdam, the Netherlands. **Research in Transportation Business and Management**, v. 45, 2022, 100875. DOI: 10.1016/j.rtbm.2022.100875.

STOCKKAMP, C.; SCHAFER, J.; MILLEMANN, J. A.; HEIDENREICH, S. Identifying factors associated with consumers' adoption of e-mobility - a systematic literature review. **Sustainability**, v. 13, 2021, 10975. DOI: 10.3390/su131910975.

STURROCK, D. T. Tutorial: Tips for Successful Practice of Simulation. *In*: WINTER SIMULATION CONFERENCE. **Anais do WSC 2014**. DOI: 10.1109/WSC.2015.7408293.

SUNGKONO, K. R.; SARNO, R.; ONGGO, B. S.; SEPTIVANTO, A. F. Optimising waste management collaboration processes using hybrid modelling**. International Journal of Simulation Modelling**, v. 23, n. 1, 2024. DOI: 10.2507/IJSIMM23-1-671.

TOLK, A.; HARPER, A.; MUSTAFEE, N. Hybrid models as transdiciplinay research enablers. **European Journal of Operational Research**, v. 291, p. 1075-1090, 2021. DOI: 10.1016/j.ejor.2020.10.010.

TORBALI, B.; ALPAN, G. A. A multi-agent-based real-time truck scheduling model for cross-docking with single inbound and outbound doors. **Supply Chain Analytics**, v. 3, 2023, 100028. DOI: 10.1016/j.sca.2023.100028.

TORRES, T. R.; OTTONI, A. L. C.; OLIVEIRA, M. S.; NEPOMUCENO, L. G. Aplicação de aprendizado por reforço na ordenação de arestas do problema do carteiro chinês. *In*: SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL, 52, Juiz de Fora, 2020. **Anais do LII SBPO 2020**.

TRUDEN, C.; RUTHMAIR, M.; KOLLINGBAUM, M. J. Analysis of Schedules for Rural First and Last Mile Microtransit Services. *In:* INTERNATIONAL CONFERENCE ON COMPUTATIONAL LOGISTICS 2021. **Anais do ICCL 2021.** DOI: 10.1007/978-3-030-87672-2_22.

VERMEULEN, A. F. **Industrial machine learning**: using artificial intelligence as a transformational disruptor. Apress, 2019.

VIDOVIC, K.; SOSTARIC, M.; BUDIMIR, D. An overview of indicators and indices used for urban mobility assessment. **PROMET-Traffic & Transportation**, v. 31, n. 6, p. 703-714, 2019. DOI: 10.7307/ptt.v31i6.3281.

TORO-GONZALEZ, D.; CANTILLO, V.; CANTILLO-GARCIA, V. Factor influencing demand for public transport in Colombia. **Research in Transportation Business & Management**, v. 36, 2020. DOI: 10.1016/j.rtbm.2020.100514.

WATKINS, C. J. C. H.; DAYAN, P. Q-Learning. **Machine learning**, v. 8, n. 3, p. 279-292, 1992.

XANTHOPOULOS, A.; KOSTAVELIS, I. Novel simulation optimization approach for supply chain coordination and management. **Procedia Computer Science**, v. 232, p. 1646-1653, 2024. DOI: 10.1016/j.procs.2024.01.162.

YANG, S.; LIU, J.; JIANG, B.; WANG, Z. AnyLogic-based simulation study on terminal passenger departing business process. *In*: INTERNATIONAL CONFERENCE ON TRAFFIC ENGINEERING AND TRANSPORTATION SYSTEM, 5, 2021. **Anais do V ICTETS 2021**. DOI: 10.1117/12.2619704.

YAO, Z.; SCHMOCKER, J. Access distance to free-floating services considering uncertain availability and smartphone activeness. **Transportmetrica B: Transport Dynamics**, v. 11, n. 1, p. 783-800, 2023. DOI: 10.1080/21680566.2022.2129857.

YAO, F.; ZHU, J.; YU, J.; CHEN, C.; CHEN, X. Hybrid operations of human driving vehicles and automated vehicles with data-drive agent-based simulation. T**ransportation Research Part D**, v. 86, p. 102469, 2020. DOI: 10.1016/j.trd.2020.102469.

ZACHOS, I.; DAMOULAS, R.; GIROLAMI, M. Table inference for combinatorial origin-destination choices in agent-based population synthesis. **Wiley**, n. 13, 2024. DOI: 10.1002/sta4.656.

ZANNAT, K. E.; ADNAN, M. S. G.; DEWAN, A. A GIS-based approach to evaluating environmental influences on active and public transport accessibility of university students, **Journal of Urban Management**, v. 9, n. 3, p. 331-346, 2020. DOI: 10.1016/j.jum.2020.06.001.

ZHANG, H.; SHEPPARD, C. J. R.; LIPMAN, R. E.; ZENG, T.; MOURA, S. J. Charging infrastructure demands of share-use autonomous electric vehicles in urban áreas. **Transportation Research Part D**, v. 78, 2020. DOI: 10.1016/j.trd.2019.102210.

ZHANG, B.; WANG, L.; LI, L.; LEI, X.; JU, Y. Vehicle assignment considering battery endurance for electric vehicle carsharing systems. **Journal of advanced transportation**, 2021, 8863985. DOI: 10.1155/2021/8863985.

ZHANG, Z.; XIAO, U.; JIANG, L.; YANG, D.; WANG, P. Spatial-temporal interplay in human mobility: a hierarchical reinforcement learning approach with hypergraph representation. *In:* CONFERENCE ON ARTIFICIAL INTELLIGENCE, 38, 2024. **Anais do XXXVIII AAAI-24**. DOI: 10.1609/aaai.v38i8.28793.

ZENG, Y.; LI, W.; LI, C. A dynamic simulation framework based on hybrid modeling paradigm for parallel scheduling systems in warehouses. **Simulation Modelling Practice and Theory**, v. 133, 2024, 102921. DOI: 10.1016/j.simpat.2024.102921.

ZHUKOV, A. I.; MOROZ, D. F. Simulation modeling of a bus route. *In*: INTELLIGENT TECHNOLOGIES AND ELECTRONIC DEVICES IN VEHICLE AND ROAD TRANSPORT COMPLEX, 2021. **Anais do TIRVED 2021**. DOI: 10.1109/TIRVED53476.2021.9639219.

APÊNDICE A – ACESSIBILIDADE DOS PONTOS DE ÔNIBUS

A Tabela 14 apresenta o valor da acessibilidade normalizada para todos os pontos de ônibus do objeto de estudo. No valor normalizado em escala [0, 1], quanto mais próximo de 0, melhor a acessibilidade.

Tabela 14 - Acessibilidade dos pontos de ônibus

N. Ponto	Latitude	Longitude	Acessibilidade Normalizada
1	-20,7552	-46,6007	0,8423
2	-20,7534	-46,6007	0,7957
3	-20,7533	-46,5988	0,7420
4	-20,7513	-46,5984	0,7002
5	-20,7494	-46,5988	0,7590
6	-20,7457	-46,6001	0,5804
7	-20,7423	-46,6009	0,4502
8	-20,7438	-46,5993	0,5302
9	-20,7459	-46,5969	0,6464
10	-20,7442	-46,5970	0,6097
11	-20,7438	-46,5986	0,5585
12	-20,7424	-46,5992	0,5046
13	-20,7421	-46,5958	0,5625
14	-20,7397	-46,5953	0,5620
15	-20,7394	-46,5984	0,6117
16	-20,7387	-46,6024	0,4629
17	-20,7356	-46,6034	0,3950
18	-20,7335	-46,6041	0,2939
19	-20,7307	-46,6051	0,2740
20	-20,7274	-46,6062	0,1848
21	-20,7248	-46,6070	0,1430
22	-20,7219	-46,6100	0,1670
23	-20,7171	-46,6099	0,1656
24	-20,7153	-46,6111	0,2157
25	-20,7147	-46,6122	0,2242
26	-20,7133	-46,6115	0,1690
27	-20,7101	-46,6131	0,1924
28	-20,7084	-46,6134	0,2252
29	-20,7069	-46,6137	0,2558
30	-20,7052	-46,6141	0,2645
31	-20,7005	-46,6161	0,3656
32	-20,6998	-46,6138	0,4071
33	-20,6993	-46,6110	0,4621
34	-20,6975	-46,6110	0,4833
35	-20,6978	-46,6131	0,5022
36	-20,6967	-46,6140	0,4900
37	-20,6965	-46,6165	0,4764
38	-20,6934	-46,6144	0,6470
39	-20,6920	-46,6163	0,7134
40	-20,6983	-46,6164	0,4209
41	-20,6964	-46,6156	0,4815
42	-20,6969	-46,6141	0,4855
43	-20,6978	-46,6132	0,5024
44	-20,6989	-46,6107	0,4412
45	-20,6997	-46,6140	0,4262
46	-20,7006	-46,6161	0,3660
47	-20,7039	-46,6147	0,2923
48	-20,7068	-46,6138	0,2589
49	-20,7080	-46,6135	0,2359
50	-20,7100	-46,6131	0,1930
51	-20,7124	-46,6121	0,1587
52	-20,7120	-46,6094	0,2206
53	-20,7171	-46,6093	0,1628
54	-20,7181	-46,6108	0,1618
56	-20,7245	-46,6082	0,1487
57	-20,7290	-46,6058	0,2056
58	-20,7332	-46,6044	0,2797
59	-20,7346	-46,6040	0,2793
60	-20,7392	-46,6024	0,3774
61	-20,7398	-46,5983	0,5065
62	-20,7394	-46,5954	0,5524
63	-20,7421	-46,5949	0,6212
64	-20,7422	-46,5994	0,4987
65	-20,7438	-46,5974	0,5942
66	-20,7458	-46,5968	0,6509
67	-20,7439	-46,5991	0,5360
68	-20,7421	-46,6004	0,4659
69	-20,7455	-46,6004	0,5217
70	-20,7503	-46,5988	0,6596
71	-20,7519	-46,5986	0,7021
72	-20,7551	-46,5987	0,7896
73	-20,7067	-46,6346	0,6474
74	-20,7054	-46,6367	0,6949
75	-20,7060	-46,6326	0,6119
76	-20,7092	-46,6306	0,4680
77	-20,7110	-46,6284	0,3908
78	-20,7129	-46,6291	0,3965
79	-20,7149	-46,6274	0,3226
80	-20,7162	-46,6234	0,2309
81	-20,7173	-46,6207	0,2000
82	-20,7171	-46,6189	0,2115
83	-20,7157	-46,6163	0,1640
86	-20,7139	-46,6096	0,2196
87	-20,7172	-46,6132	0,1618
88	-20,7217	-46,6134	0,1281
90	-20,7269	-46,6116	0,1683
91	-20,7292	-46,6104	0,1786
92	-20,7333	-46,6075	0,2669
93	-20,7347	-46,6091	0,2959
94	-20,7361	-46,6084	0,3185
95	-20,7388	-46,6068	0,3677
96	-20,7383	-46,6079	0,3690
97	-20,7395	-46,6092	0,4283
98	-20,7437	-46,6072	0,5615
99	-20,7463	-46,6061	0,5797
100	-20,7503	-46,6071	0,6923
101	-20,7531	-46,6123	0,9334
102	-20,7533	-46,6092	0,8230
103	-20,7547	-46,6075	0,8956
104	-20,7565	-46,6053	1,0000
105	-20,7555	-46,6031	0,9242
111	-20,7536	-46,6006	0,8033
112	-20,7562	-46,6056	0,9647
113	-20,7547	-46,6073	0,8985
114	-20,7532	-46,6092	0,8231
115	-20,7532	-46,6123	0,9338
116	-20,7504	-46,6071	0,6935

117	-20,7496	-46,6045	0,6607
118	-20,7452	-46,6040	0,5590
119	-20,7454	-46,6074	0,5858
120	-20,7454	-46,6090	0,7191
121	-20,7436	-46,6095	0,6780
122	-20,7438	-46,6074	0,5510
123	-20,7396	-46,6083	0,4345
124	-20,7385	-46,6098	0,3944
125	-20,7383	-46,6080	0,3678
126	-20,7388	-46,6069	0,3683
127	-20,7361	-46,6083	0,3194
128	-20,7328	-46,6069	0,2534
129	-20,7300	-46,6095	0,2143
130	-20,7265	-46,6114	0,1786
131	-20,7223	-46,6131	0,1452
134	-20,7146	-46,6107	0,2184
136	-20,7155	-46,6159	0,1601
137	-20,7167	-46,6199	0,2023
138	-20,7161	-46,6234	0,2309
139	-20,7151	-46,6272	0,3135
140	-20,7125	-46,6261	0,3390
141	-20,7111	-46,6283	0,3884
142	-20,7095	-46,6294	0,4368
143	-20,7078	-46,6289	0,4503
144	-20,7043	-46,6273	0,4713
145	-20,7025	-46,6263	0,4855
146	-20,6988	-46,6309	0,6424
147	-20,7008	-46,6323	0,6951
148	-20,7028	-46,6340	0,6894
149	-20,7019	-46,6354	0,7364
150	-20,7020	-46,6358	0,7463
151	-20,7043	-46,6371	0,7223
153	-20,7328	-46,6294	0,5368
154	-20,7327	-46,6269	0,5041
155	-20,7302	-46,6239	0,4282
156	-20,7280	-46,6201	0,3341
157	-20,7264	-46,6184	0,2304
158	-20,7250	-46,6172	0,1849
159	-20,7248	-46,6162	0,1712
160	-20,7269	-46,6123	0,1747
161	-20,7267	-46,6114	0,1717
165	-20,7292	-46,6043	0,2235
166	-20,7257	-46,6009	0,1844
167	-20,7227	-46,5980	0,2006
168	-20,7242	-46,5968	0,2478
169	-20,7249	-46,5957	0,2612
170	-20,7285	-46,5966	0,2771
171	-20,7293	-46,5935	0,3475
172	-20,7271	-46,5895	0,4254
173	-20,7262	-46,5876	0,4398
174	-20,7266	-46,5856	0,5010
175	-20,7257	-46,5792	0,7013
176	-20,7209	-46,5768	0,8555
177	-20,7254	-46,5792	0,7743
178	-20,7265	-46,5856	0,5546
179	-20,7260	-46,5879	0,4816
180	-20,7281	-46,5905	0,4254
181	-20,7293	-46,5932	0,3730
182	-20,7283	-46,5965	0,2726
183	-20,7248	-46,5956	0,2535
184	-20,7241	-46,5968	0,2369
185	-20,7225	-46,5978	0,1915
186	-20,7252	-46,6007	0,1736
187	-20,7275	-46,6023	0,1752
188	-20,7261	-46,6064	0,1420
191	-20,7204	-46,6116	0,1335
194	-20,7274	-46,6128	0,1513
195	-20,7274	-46,6158	0,1513
196	-20,7258	-46,6162	0,1287
197	-20,7264	-46,6184	0,1685
198	-20,7279	-46,6202	0,2525
199	-20,7292	-46,6230	0,2927
200	-20,7340	-46,6250	0,4099
202	-20,7165	-46,6348	0,4275
203	-20,7186	-46,6360	0,4569
204	-20,7200	-46,6351	0,4355
205	-20,7220	-46,6347	0,4292
206	-20,7197	-46,6332	0,3594
207	-20,7200	-46,6313	0,3003
208	-20,7198	-46,6293	0,2491
209	-20,7178	-46,6272	0,2043
210	-20,7171	-46,6253	0,1783
211	-20,7183	-46,6240	0,1443
212	-20,7199	-46,6235	0,1332
213	-20,7211	-46,6214	0,1017
214	-20,7255	-46,6206	0,1080
215	-20,7244	-46,6194	0,1144
216	-20,7234	-46,6181	0,0524
223	-20,7112	-46,6092	0,0391
224	-20,7104	-46,6076	0,0586
225	-20,7116	-46,6049	0,0549
226	-20,7123	-46,6035	0,0479
227	-20,7115	-46,6000	0,0799
228	-20,7100	-46,6007	0,0924
229	-20,7086	-46,5997	0,1250
230	-20,7057	-46,5979	0,1972
231	-20,7053	-46,6002	0,1758
232	-20,7052	-46,6037	0,1334
233	-20,7028	-46,6056	0,1742
234	-20,7047	-46,6020	0,1549
235	-20,7057	-46,6005	0,1524
236	-20,7058	-46,5979	0,1758
237	-20,7083	-46,5994	0,1110
238	-20,7119	-46,5996	0,0534
239	-20,7116	-46,6012	0,0397
240	-20,7089	-46,6042	0,0540
241	-20,7078	-46,6058	0,0555
242	-20,7111	-46,6091	0,0000
251	-20,7231	-46,6182	0,1826
252	-20,7245	-46,6198	0,2442
254	-20,7252	-46,6216	0,2944
255	-20,7210	-46,6215	0,2564
256	-20,7198	-46,6235	0,2780
257	-20,7183	-46,6240	0,2712
258	-20,7169	-46,6254	0,2795
259	-20,7178	-46,6273	0,3315
260	-20,7198	-46,6293	0,3752
261	-20,7199	-46,6313	0,4269
262	-20,7196	-46,6332	0,4902
263	-20,7220	-46,6347	0,5656
264	-20,7188	-46,6373	0,6216
265	-20,7197	-46,6377	0,6575
266	-20,7203	-46,6386	0,6708
267	-20,7200	-46,6356	0,5785
268	-20,7183	-46,6359	0,5683
272	-20,7236	-46,5897	0,4697
273	-20,7218	-46,5892	0,4875
274	-20,7201	-46,5911	0,4841
275	-20,7200	-46,5922	0,3674
276	-20,7178	-46,5945	0,3125
277	-20,7144	-46,5983	0,3024
278	-20,7121	-46,5961	0,3701
279	-20,7104	-46,5980	0,3256
281	-20,7156	-46,5995	0,2706

282	-20,7181	-46,6019	0,1576
283	-20,7200	-46,6024	0,1396
284	-20,7219	-46,6023	0,1929
285	-20,7226	-46,6036	0,1593
286	-20,7220	-46,6064	0,1619
292	-20,7071	-46,6105	0,2463
293	-20,7047	-46,6098	0,3321
294	-20,7053	-46,6126	0,2666
296	-20,7045	-46,6164	0,2920
297	-20,7052	-46,6182	0,3116
298	-20,7037	-46,6194	0,3815
299	-20,7011	-46,6201	0,4477
300	-20,7006	-46,6213	0,4729
301	-20,7053	-46,6205	0,3388
302	-20,7063	-46,6215	0,3287
303	-20,7062	-46,6236	0,3646
304	-20,7049	-46,6253	0,4102
305	-20,7069	-46,6268	0,4171
306	-20,7085	-46,6238	0,3405
307	-20,7073	-46,6220	0,3272
308	-20,7053	-46,6205	0,3399
309	-20,7006	-46,6212	0,4728
310	-20,7010	-46,6203	0,4530
311	-20,7036	-46,6196	0,3762
312	-20,7052	-46,6185	0,3140
313	-20,7045	-46,6165	0,2931
314	-20,7056	-46,6139	0,2541
315	-20,7047	-46,6099	0,3319
316	-20,7070	-46,6105	0,2472
324	-20,7230	-46,6059	0,1348
325	-20,7208	-46,6037	0,1181
326	-20,7181	-46,6032	0,1334
327	-20,7167	-46,6039	0,1905
328	-20,7144	-46,6022	0,2309
329	-20,7128	-46,6005	0,2690
330	-20,7105	-46,5980	0,3257
332	-20,7178	-46,5947	0,3123
333	-20,7201	-46,5922	0,3678
334	-20,7202	-46,5911	0,4183
335	-20,7218	-46,5894	0,4710
336	-20,7235	-46,5897	0,4694
337	-20,7228	-46,5962	0,2304

Fonte: Elaborado pelo autor (2026).

APÊNDICE B – VIABILIDADE DE ALTERAÇÃO DO PONTO DE ÔNIBUS PARA O RACIONALIZADO

A Tabela 15 apresenta, para cada alteração proposta após a racionalização via Q-Learning, a viabilidade qualitativa dos pontos de ônibus por completo, perante análise discutida na Seção 5.3.5.

Tabela 15 - Análise qualitativa da viabilidade de alteração de localização dos pontos de ônibus após racionalização

Linha	NPonto	Latitude Original	Longitude Original	Melhor Latitude	Melhor Longitude	Deslocamento	Viabilidade Prática	Observação
1	1	-20,7552	-46,6007	-20,7492	-46,6027	696,46	Alta	Implantação viável
1	2	-20,7534	-46,6007	-20,7534	-46,6027	208,37	Alta	Implantação viável
1	3	-20,7533	-46,5988	-20,7533	-46,6008	208,37	Alta	Implantação viável
1	4	-20,7513	-46,5984	-20,7473	-46,5984	443,04	Alta	Implantação viável
1	5	-20,7494	-46,5988	-20,7454	-46,5988	443,04	Alta	Implantação viável
1	6	-20,7457	-46,6001	-20,7397	-46,6021	696,46	Alta	Implantação viável
1	7	-20,7423	-46,6009	-20,7363	-46,6009	664,56	Baixa	Posição sem vias
1	8	-20,7438	-46,5993	-20,7358	-46,6013	910,25	Baixa	Posição sem vias
1	9	-20,7459	-46,5969	-20,7439	-46,5969	221,52	Alta	Implantação viável
1	10	-20,7442	-46,5970	-20,7402	-46,5970	443,04	Alta	Implantação viável
1	11	-20,7438	-46,5986	-20,7318	-46,5966	1.345,35	Alta	Implantação viável
1	12	-20,7424	-46,5992	-20,7384	-46,5992	443,04	Alta	Implantação viável
1	13	-20,7421	-46,5958	-20,7401	-46,5938	304,13	Alta	Implantação viável
1	14	-20,7397	-46,5953	-20,7337	-46,5953	664,56	Alta	Implantação viável
1	15	-20,7394	-46,5984	-20,7334	-46,5984	664,56	Alta	Implantação viável
1	16	-20,7387	-46,6024	-20,7307	-46,6024	886,08	Alta	Implantação viável
1	18	-20,7335	-46,6041	-20,7295	-46,6041	443,04	Alta	Implantação viável
1	19	-20,7307	-46,6051	-20,7267	-46,6071	489,61	Alta	Implantação viável
1	20	-20,7274	-46,6062	-20,7234	-46,6062	443,04	Alta	Implantação viável
1	22	-20,7219	-46,6100	-20,7179	-46,6100	443,04	Alta	Implantação viável
1	23	-20,7171	-46,6099	-20,7111	-46,6099	664,56	Alta	Implantação viável
1	24	-20,7153	-46,6111	-20,7173	-46,6111	221,52	Alta	Implantação viável
1	25	-20,7147	-46,6122	-20,7127	-46,6122	221,52	Alta	Implantação viável
1	26	-20,7133	-46,6115	-20,7053	-46,6115	886,07	Alta	Implantação viável
1	27	-20,7101	-46,6131	-20,7121	-46,6131	221,52	Alta	Implantação viável
1	29	-20,7069	-46,6137	-20,7089	-46,6137	221,52	Alta	Implantação viável
1	30	-20,7052	-46,6141	-20,7032	-46,6141	221,52	Alta	Implantação viável
1	31	-20,7005	-46,6161	-20,7105	-46,6141	1.127,03	Alta	Implantação viável
1	32	-20,6998	-46,6138	-20,7078	-46,6138	886,07	Média	Rua estreita
1	34	-20,6975	-46,6110	-20,6935	-46,6110	443,04	Alta	Implantação viável
1	35	-20,6978	-46,6131	-20,7098	-46,6151	1.345,35	Alta	Implantação viável
1	36	-20,6967	-46,6140	-20,7027	-46,6140	664,55	Alta	Implantação viável
1	37	-20,6965	-46,6165	-20,6965	-46,6185	208,44	Alta	Implantação viável
1	39	-20,6920	-46,6163	-20,6900	-46,6163	221,52	Alta	Implantação viável
1	40	-20,6983	-46,6164	-20,6963	-46,6164	221,52	Alta	Implantação viável
1	42	-20,6969	-46,6141	-20,7009	-46,6141	443,04	Alta	Implantação viável
1	43	-20,6978	-46,6132	-20,6918	-46,6132	664,55	Alta	Implantação viável
1	45	-20,6997	-46,6140	-20,6997	-46,6180	416,88	Alta	Implantação viável
1	47	-20,7039	-46,6147	-20,7079	-46,6147	443,04	Alta	Implantação viável
1	48	-20,7068	-46,6138	-20,7068	-46,6118	208,43	Alta	Implantação viável
1	49	-20,7080	-46,6135	-20,7100	-46,6135	221,52	Alta	Implantação viável
1	52	-20,7120	-46,6094	-20,7100	-46,6094	221,52	Alta	Implantação viável
1	53	-20,7171	-46,6093	-20,7151	-46,6153	663,34	Alta	Implantação viável
1	54	-20,7181	-46,6108	-20,7161	-46,6108	221,52	Alta	Implantação viável

1	55	-20,7219	-46,6100	-20,7239	-46,6100	221,52	Alta	Implantação viável
1	56	-20,7245	-46,6082	-20,7225	-46,6082	221,52	Alta	Implantação viável
1	57	-20,7290	-46,6058	-20,7230	-46,6058	664,56	Alta	Implantação viável
1	59	-20,7346	-46,6040	-20,7266	-46,6060	910,25	Alta	Implantação viável
1	60	-20,7392	-46,6024	-20,7312	-46,6024	886,08	Alta	Implantação viável
1	61	-20,7398	-46,5983	-20,7358	-46,5983	443,04	Média	Rua sem asfaltamento
1	62	-20,7394	-46,5954	-20,7374	-46,5954	221,52	Alta	Implantação viável
1	63	-20,7421	-46,5949	-20,7401	-46,5989	471,98	Alta	Implantação viável
1	64	-20,7422	-46,5994	-20,7362	-46,5994	664,56	Média	Rua sem asfaltamento
1	65	-20,7438	-46,5974	-20,7378	-46,5974	664,56	Alta	Implantação viável
1	67	-20,7439	-46,5991	-20,7439	-46,6011	208,38	Alta	Implantação viável
1	68	-20,7421	-46,6004	-20,7361	-46,6004	664,56	Baixa	Posição sem vias
1	69	-20,7455	-46,6004	-20,7415	-46,6004	443,04	Alta	Implantação viável
1	70	-20,7503	-46,5988	-20,7483	-46,6008	304,12	Baixa	Posição sem vias
1	71	-20,7519	-46,5986	-20,7479	-46,5986	443,04	Média	Interior de espaço público ou privado
1	72	-20,7551	-46,5987	-20,7531	-46,5987	221,52	Alta	Implantação viável
2	1	-20,7067	-46,6346	-20,7067	-46,6266	833,72	Alta	Implantação viável
2	2	-20,7054	-46,6367	-20,7074	-46,6347	304,16	Alta	Implantação viável
2	3	-20,7060	-46,6326	-20,7080	-46,6326	221,52	Alta	Implantação viável
2	4	-20,7092	-46,6306	-20,7072	-46,6306	221,52	Alta	Implantação viável
2	5	-20,7110	-46,6284	-20,7110	-46,6264	208,43	Alta	Implantação viável
2	6	-20,7129	-46,6291	-20,7069	-46,6251	784,47	Alta	Implantação viável
2	8	-20,7162	-46,6234	-20,7142	-46,6234	221,52	Alta	Implantação viável
2	9	-20,7173	-46,6207	-20,7173	-46,6187	208,42	Alta	Implantação viável
2	10	-20,7171	-46,6189	-20,7131	-46,6189	443,04	Alta	Implantação viável
2	11	-20,7157	-46,6163	-20,7137	-46,6163	221,52	Alta	Implantação viável
2	12	-20,7124	-46,6121	-20,7124	-46,6141	208,42	Baixa	Posição sem vias
2	13	-20,7120	-46,6094	-20,7160	-46,6094	443,04	Alta	Implantação viável
2	14	-20,7139	-46,6096	-20,7159	-46,6096	221,52	Alta	Implantação viável
2	15	-20,7172	-46,6132	-20,7232	-46,6052	1.066,12	Alta	Implantação viável
2	16	-20,7217	-46,6134	-20,7197	-46,6054	862,58	Alta	Implantação viável
2	18	-20,7269	-46,6116	-20,7229	-46,6096	489,61	Alta	Implantação viável
2	19	-20,7292	-46,6104	-20,7212	-46,6104	886,07	Alta	Implantação viável
2	20	-20,7333	-46,6075	-20,7253	-46,6055	910,25	Alta	Implantação viável
2	21	-20,7347	-46,6091	-20,7247	-46,6091	1.107,59	Alta	Implantação viável
2	22	-20,7361	-46,6084	-20,7241	-46,6084	1.329,11	Alta	Implantação viável
2	23	-20,7388	-46,6068	-20,7328	-46,6088	696,46	Alta	Implantação viável
2	24	-20,7383	-46,6079	-20,7363	-46,6079	221,52	Alta	Implantação viável
2	26	-20,7437	-46,6072	-20,7377	-46,6072	664,56	Alta	Implantação viável
2	27	-20,7463	-46,6061	-20,7343	-46,6061	1.329,12	Alta	Implantação viável
2	28	-20,7503	-46,6071	-20,7443	-46,6071	664,56	Alta	Implantação viável
2	29	-20,7531	-46,6123	-20,7471	-46,6123	664,56	Alta	Implantação viável
2	30	-20,7533	-46,6092	-20,7513	-46,6092	221,52	Alta	Implantação viável
2	31	-20,7547	-46,6075	-20,7467	-46,6075	886,08	Alta	Implantação viável
2	32	-20,7565	-46,6053	-20,7485	-46,6033	910,25	Alta	Implantação viável
2	33	-20,7555	-46,6031	-20,7515	-46,6011	489,59	Alta	Implantação viável
2	34	-20,7552	-46,6007	-20,7392	-46,6007	1.772,16	Alta	Implantação viável
2	35	-20,7534	-46,6007	-20,7494	-46,6007	443,04	Baixa	Posição sem vias
2	36	-20,7533	-46,5988	-20,7513	-46,5988	221,52	Alta	Implantação viável
2	37	-20,7513	-46,5984	-20,7373	-46,5984	1.550,64	Alta	Implantação viável
2	38	-20,7534	-46,6007	-20,7474	-46,6007	664,56	Alta	Implantação viável
2	39	-20,7536	-46,6006	-20,7476	-46,6006	664,56	Alta	Implantação viável
2	40	-20,7562	-46,6056	-20,7462	-46,6056	1.107,60	Alta	Implantação viável
2	42	-20,7532	-46,6092	-20,7492	-46,6092	443,04	Alta	Implantação viável
2	43	-20,7532	-46,6123	-20,7492	-46,6103	489,59	Alta	Implantação viável
2	44	-20,7504	-46,6071	-20,7384	-46,6071	1.329,12	Alta	Implantação viável
2	45	-20,7496	-46,6045	-20,7416	-46,6045	886,08	Alta	Implantação viável
2	46	-20,7452	-46,6040	-20,7432	-46,6020	304,13	Alta	Implantação viável
2	47	-20,7454	-46,6074	-20,7414	-46,6074	443,04	Alta	Implantação viável
2	48	-20,7454	-46,6090	-20,7334	-46,6090	1.329,12	Alta	Implantação viável

2	49	-20,7436	-46,6095	-20,7416	-46,6095	221,52	Alta	Implantação viável
2	50	-20,7438	-46,6074	-20,7378	-46,6074	664,56	Alta	Implantação viável
2	51	-20,7396	-46,6083	-20,7336	-46,6103	696,46	Alta	Implantação viável
2	52	-20,7385	-46,6098	-20,7345	-46,6078	489,60	Média	Interior de espaço público ou privado
2	53	-20,7383	-46,6080	-20,7283	-46,6080	1.107,60	Alta	Implantação viável
2	54	-20,7388	-46,6069	-20,7328	-46,6069	664,56	Alta	Implantação viável
2	55	-20,7361	-46,6083	-20,7201	-46,6083	1.772,15	Alta	Implantação viável
2	56	-20,7328	-46,6069	-20,7308	-46,6109	472,00	Alta	Implantação viável
2	57	-20,7300	-46,6095	-20,7260	-46,6095	443,04	Alta	Implantação viável
2	58	-20,7265	-46,6114	-20,7245	-46,6134	304,14	Alta	Implantação viável
2	59	-20,7223	-46,6131	-20,7183	-46,6131	443,04	Alta	Implantação viável
2	60	-20,7219	-46,6100	-20,7219	-46,6080	208,41	Alta	Implantação viável
2	61	-20,7171	-46,6099	-20,7131	-46,6099	443,04	Alta	Implantação viável
2	62	-20,7146	-46,6107	-20,7226	-46,6107	886,07	Alta	Implantação viável
2	63	-20,7133	-46,6115	-20,7153	-46,6115	221,52	Alta	Implantação viável
2	64	-20,7155	-46,6159	-20,7175	-46,6159	221,52	Alta	Implantação viável
2	65	-20,7167	-46,6199	-20,7167	-46,6179	208,42	Alta	Implantação viável
2	66	-20,7161	-46,6234	-20,7201	-46,6174	766,30	Alta	Implantação viável
2	67	-20,7151	-46,6272	-20,7091	-46,6232	784,47	Alta	Implantação viável
2	68	-20,7125	-46,6261	-20,7125	-46,6301	416,85	Alta	Implantação viável
2	69	-20,7111	-46,6283	-20,7131	-46,6323	472,05	Alta	Implantação viável
2	70	-20,7095	-46,6294	-20,7095	-46,6274	208,43	Alta	Implantação viável
2	71	-20,7078	-46,6289	-20,7158	-46,6289	886,07	Alta	Implantação viável
2	73	-20,7025	-46,6263	-20,7005	-46,6263	221,52	Alta	Implantação viável
2	74	-20,6988	-46,6309	-20,7008	-46,6309	221,52	Alta	Implantação viável
2	75	-20,7008	-46,6323	-20,6988	-46,6323	221,52	Alta	Implantação viável
2	76	-20,7028	-46,6340	-20,7008	-46,6320	304,17	Alta	Implantação viável
2	77	-20,7019	-46,6354	-20,6979	-46,6334	489,62	Alta	Implantação viável
3	1	-20,7328	-46,6294	-20,7328	-46,6254	416,79	Alta	Implantação viável
3	2	-20,7327	-46,6269	-20,7287	-46,6229	608,28	Alta	Implantação viável
3	3	-20,7302	-46,6239	-20,7302	-46,6139	1.042,00	Alta	Implantação viável
3	4	-20,7280	-46,6201	-20,726	-46,6241	472,02	Alta	Implantação viável
3	5	-20,7264	-46,6184	-20,7204	-46,6144	784,46	Alta	Implantação viável
3	6	-20,7250	-46,6172	-20,7270	-46,6192	304,14	Alta	Implantação viável
3	7	-20,7248	-46,6162	-20,7248	-46,6122	416,81	Alta	Implantação viável
3	8	-20,7269	-46,6123	-20,7169	-46,6103	1.127,03	Alta	Implantação viável
3	9	-20,7267	-46,6114	-20,7207	-46,6114	664,56	Alta	Implantação viável
3	10	-20,7223	-46,6131	-20,7203	-46,6131	221,52	Alta	Implantação viável
3	11	-20,7219	-46,6100	-20,7179	-46,6080	489,61	Alta	Implantação viável
3	12	-20,7245	-46,6082	-20,7205	-46,6082	443,04	Alta	Implantação viável
3	13	-20,7292	-46,6043	-20,7212	-46,6043	886,07	Alta	Implantação viável
3	14	-20,7257	-46,6009	-20,7197	-46,6029	696,47	Alta	Implantação viável
3	15	-20,7227	-46,598	-20,7187	-46,5960	489,61	Alta	Implantação viável
3	16	-20,7242	-46,5968	-20,7242	-46,5988	208,41	Alta	Implantação viável
3	17	-20,7249	-46,5957	-20,7209	-46,5957	443,04	Alta	Implantação viável
3	18	-20,7285	-46,5966	-20,7285	-46,5986	208,40	Alta	Implantação viável
3	19	-20,7293	-46,5935	-20,7253	-46,5935	443,04	Alta	Implantação viável
3	21	-20,7262	-46,5876	-20,7242	-46,5876	221,52	Alta	Implantação viável
3	22	-20,7266	-46,5856	-20,7186	-46,5916	1.084,45	Alta	Implantação viável
3	23	-20,7257	-46,5792	-20,7237	-46,5792	221,52	Alta	Implantação viável
3	25	-20,7254	-46,5792	-20,7194	-46,5792	664,56	Alta	Implantação viável
3	26	-20,7265	-46,5856	-20,7225	-46,5836	489,61	Alta	Implantação viável
3	27	-20,7260	-46,5879	-20,7280	-46,5859	304,14	Média	Interior de espaço público ou privado
3	28	-20,7281	-46,5905	-20,7261	-46,5905	221,52	Alta	Implantação viável
3	29	-20,7293	-46,5932	-20,7293	-46,5952	208,40	Alta	Implantação viável
3	30	-20,7283	-46,5965	-20,7243	-46,5965	443,04	Alta	Implantação viável
3	31	-20,7248	-46,5956	-20,7208	-46,5956	443,04	Alta	Implantação viável
3	32	-20,7241	-46,5968	-20,7201	-46,5968	443,04	Alta	Implantação viável
3	33	-20,7225	-46,5978	-20,7225	-46,5938	416,82	Alta	Implantação viável

3	34	-20,7252	-46,6007	-20,7172	-46,6007	886,07	Alta	Implantação viável
3	35	-20,7275	-46,6023	-20,7235	-46,6023	443,04	Alta	Implantação viável
3	36	-20,7261	-46,6064	-20,7201	-46,6084	696,47	Alta	Implantação viável
3	37	-20,7248	-46,6070	-20,7148	-46,6070	1.107,59	Alta	Implantação viável
3	39	-20,7204	-46,6116	-20,7164	-46,6116	443,04	Alta	Implantação viável
3	40	-20,7217	-46,6134	-20,7177	-46,6134	443,04	Alta	Implantação viável
3	41	-20,7269	-46,6116	-20,7229	-46,6096	489,61	Alta	Implantação viável
3	42	-20,7274	-46,6128	-20,7194	-46,6108	910,25	Alta	Implantação viável
3	43	-20,7274	-46,6158	-20,7254	-46,6158	221,52	Alta	Implantação viável
3	44	-20,7258	-46,6162	-20,7198	-46,6162	664,56	Alta	Implantação viável
3	45	-20,7264	-46,6184	-20,7244	-46,6184	221,52	Alta	Implantação viável
3	46	-20,7279	-46,6202	-20,7199	-46,6202	886,07	Alta	Implantação viável
3	47	-20,7292	-46,6230	-20,7292	-46,6170	625,20	Alta	Implantação viável
3	48	-20,7340	-46,6250	-20,7320	-46,6290	472,00	Alta	Implantação viável
4	2	-20,7186	-46,636	-20,7166	-46,634	304,15	Alta	Implantação viável
4	3	-20,7200	-46,6351	-20,7160	-46,6351	443,04	Alta	Implantação viável
4	4	-20,7220	-46,6347	-20,7180	-46,6347	443,04	Alta	Implantação viável
4	5	-20,7197	-46,6332	-20,7177	-46,6332	221,52	Alta	Implantação viável
4	6	-20,7200	-46,6313	-20,7140	-46,6313	664,56	Alta	Implantação viável
4	7	-20,7198	-46,6293	-20,7198	-46,6273	208,41	Alta	Implantação viável
4	8	-20,7178	-46,6272	-20,7198	-46,6272	221,52	Alta	Implantação viável
4	9	-20,7171	-46,6253	-20,7171	-46,6233	208,42	Alta	Implantação viável
4	10	-20,7183	-46,624	-20,7143	-46,6220	489,61	Alta	Implantação viável
4	11	-20,7199	-46,6235	-20,7219	-46,6235	221,52	Alta	Implantação viável
4	13	-20,7255	-46,6206	-20,7235	-46,6166	472,02	Alta	Implantação viável
4	14	-20,7244	-46,6194	-20,7164	-46,6174	910,25	Alta	Implantação viável
4	15	-20,7234	-46,6181	-20,7254	-46,6181	221,52	Alta	Implantação viável
4	16	-20,7223	-46,6131	-20,7203	-46,6131	221,52	Alta	Implantação viável
4	17	-20,7219	-46,6100	-20,7119	-46,6100	1.107,59	Alta	Implantação viável
4	18	-20,7171	-46,6099	-20,7111	-46,6099	664,56	Alta	Implantação viável
4	19	-20,7146	-46,6107	-20,7186	-46,6127	489,61	Alta	Implantação viável
4	20	-20,7133	-46,6115	-20,7113	-46,6115	221,52	Alta	Implantação viável
4	21	-20,7124	-46,6121	-20,7144	-46,6101	304,15	Alta	Implantação viável
4	22	-20,7112	-46,6092	-20,7132	-46,6092	221,52	Alta	Implantação viável
4	23	-20,7104	-46,6076	-20,7084	-46,6076	221,52	Alta	Implantação viável
4	24	-20,7116	-46,6049	-20,7196	-46,6049	886,07	Alta	Implantação viável
4	26	-20,7115	-46,6000	-20,7115	-46,5980	208,42	Alta	Implantação viável
4	27	-20,7100	-46,6007	-20,7180	-46,6007	886,07	Alta	Implantação viável
4	28	-20,7086	-46,5997	-20,7106	-46,6057	663,36	Alta	Implantação viável
4	29	-20,7057	-46,5979	-20,7017	-46,5979	443,04	Alta	Implantação viável
4	30	-20,7053	-46,6002	-20,7133	-46,6002	886,07	Alta	Implantação viável
4	31	-20,7052	-46,6037	-20,7012	-46,6037	443,04	Alta	Implantação viável
4	32	-20,7028	-46,6056	-20,7048	-46,6056	221,52	Alta	Implantação viável
4	34	-20,7057	-46,6005	-20,7017	-46,5985	489,62	Alta	Implantação viável
4	35	-20,7058	-46,5979	-20,7058	-46,5959	208,43	Alta	Implantação viável
4	36	-20,7083	-46,5994	-20,7103	-46,5974	304,16	Alta	Implantação viável
4	37	-20,7119	-46,5996	-20,7099	-46,6016	304,16	Alta	Implantação viável
4	38	-20,7116	-46,6012	-20,7136	-46,6012	221,52	Alta	Implantação viável
4	39	-20,7089	-46,6042	-20,7109	-46,6022	304,16	Alta	Implantação viável
4	40	-20,7078	-46,6058	-20,7058	-46,6078	304,16	Alta	Implantação viável
4	41	-20,7111	-46,6091	-20,7091	-46,6071	304,16	Alta	Implantação viável
4	42	-20,7133	-46,6115	-20,7153	-46,6115	221,52	Alta	Implantação viável
4	43	-20,7124	-46,6121	-20,7164	-46,6121	443,04	Alta	Implantação viável
4	44	-20,7120	-46,6094	-20,7180	-46,6094	664,56	Alta	Implantação viável
4	45	-20,7139	-46,6096	-20,7159	-46,6136	472,04	Alta	Implantação viável
4	46	-20,7181	-46,6108	-20,7181	-46,6128	208,42	Alta	Implantação viável
4	47	-20,7219	-46,6100	-20,7199	-46,614	472,03	Alta	Implantação viável
4	48	-20,7204	-46,6116	-20,7204	-46,6076	416,82	Alta	Implantação viável
4	49	-20,7217	-46,6134	-20,7197	-46,6134	221,52	Alta	Implantação viável
4	50	-20,7231	-46,6182	-20,7191	-46,6182	443,04	Alta	Implantação viável
4	51	-20,7245	-46,6198	-20,7205	-46,6178	489,61	Alta	Implantação viável

4	52	-20,7255	-46,6206	-20,7215	-46,6166	608,29	Alta	Implantação viável
4	53	-20,7252	-46,6216	-20,7152	-46,6216	1.107,59	Alta	Implantação viável
4	54	-20,7210	-46,6215	-20,7170	-46,6195	489,61	Alta	Implantação viável
4	55	-20,7198	-46,6235	-20,7178	-46,6195	472,03	Alta	Implantação viável
4	56	-20,7183	-46,6240	-20,7223	-46,6180	766,29	Alta	Implantação viável
4	57	-20,7169	-46,6254	-20,7209	-46,6254	443,04	Alta	Implantação viável
4	58	-20,7178	-46,6273	-20,7218	-46,6213	766,29	Alta	Implantação viável
4	59	-20,7198	-46,6293	-20,7138	-46,6293	664,56	Alta	Implantação viável
4	60	-20,7199	-46,6313	-20,7179	-46,6313	221,52	Alta	Implantação viável
4	61	-20,7196	-46,6332	-20,7176	-46,6312	304,15	Alta	Implantação viável
4	64	-20,7197	-46,6377	-20,7177	-46,6377	221,52	Alta	Implantação viável
4	65	-20,7203	-46,6386	-20,7223	-46,6386	221,52	Alta	Implantação viável
4	66	-20,7200	-46,6356	-20,7160	-46,6376	489,61	Alta	Implantação viável
5	1	-20,7293	-46,5935	-20,7253	-46,5935	443,04	Alta	Implantação viável
5	2	-20,7271	-46,5895	-20,7211	-46,5875	696,47	Alta	Implantação viável
5	3	-20,7236	-46,5897	-20,7196	-46,5957	766,29	Alta	Implantação viável
5	4	-20,7218	-46,5892	-20,7198	-46,5892	221,52	Alta	Implantação viável
5	5	-20,7201	-46,5911	-20,7201	-46,5871	416,83	Alta	Implantação viável
5	6	-20,7200	-46,5922	-20,7180	-46,5922	221,52	Alta	Implantação viável
5	8	-20,7144	-46,5983	-20,7164	-46,5983	221,52	Alta	Implantação viável
5	10	-20,7104	-46,5980	-20,7084	-46,5980	221,52	Alta	Implantação viável
5	11	-20,7119	-46,5996	-20,7059	-46,5996	664,55	Alta	Implantação viável
5	12	-20,7156	-46,5995	-20,7236	-46,5995	886,07	Alta	Implantação viável
5	14	-20,7200	-46,6024	-20,7180	-46,6064	472,03	Alta	Implantação viável
5	15	-20,7219	-46,6023	-20,7239	-46,6023	221,52	Alta	Implantação viável
5	16	-20,7226	-46,6036	-20,7186	-46,6036	443,04	Alta	Implantação viável
5	17	-20,7220	-46,6064	-20,7180	-46,6104	608,30	Alta	Implantação viável
5	18	-20,7219	-46,6100	-20,7159	-46,6100	664,56	Alta	Implantação viável
5	19	-20,7171	-46,6099	-20,7171	-46,6119	208,42	Alta	Implantação viável
5	20	-20,7146	-46,6107	-20,7166	-46,6107	221,52	Alta	Implantação viável
5	22	-20,7100	-46,6131	-20,7140	-46,6151	489,61	Alta	Implantação viável
5	24	-20,7047	-46,6098	-20,7007	-46,6078	489,62	Baixa	Posição sem vias
5	26	-20,7052	-46,6141	-20,7032	-46,6101	472,07	Média	Interior de espaço público ou privado
5	27	-20,7045	-46,6164	-20,7065	-46,6144	304,16	Alta	Implantação viável
5	28	-20,7052	-46,6182	-20,7072	-46,6182	221,52	Alta	Implantação viável
5	29	-20,7037	-46,6194	-20,7037	-46,6174	208,44	Alta	Implantação viável
5	30	-20,7011	-46,6201	-20,6991	-46,6181	304,17	Alta	Implantação viável
5	31	-20,7006	-46,6213	-20,7006	-46,6193	208,44	Alta	Implantação viável
5	32	-20,7053	-46,6205	-20,7073	-46,6205	221,52	Alta	Implantação viável
5	34	-20,7062	-46,6236	-20,7062	-46,6216	208,43	Alta	Implantação viável
5	36	-20,7069	-46,6268	-20,7089	-46,6268	221,52	Alta	Implantação viável
5	37	-20,7085	-46,6238	-20,7145	-46,6198	784,47	Alta	Implantação viável
5	38	-20,7073	-46,622	-20,7053	-46,622	221,52	Alta	Implantação viável
5	39	-20,7053	-46,6205	-20,7133	-46,6185	910,26	Alta	Implantação viável
5	40	-20,7006	-46,6212	-20,7066	-46,6212	664,55	Alta	Implantação viável
5	41	-20,7010	-46,6203	-20,6990	-46,6183	304,17	Alta	Implantação viável
5	42	-20,7036	-46,6196	-20,7096	-46,6156	784,48	Média	Interior de espaço público ou privado
5	43	-20,7052	-46,6185	-20,7032	-46,6185	221,52	Alta	Implantação viável
5	44	-20,7045	-46,6165	-20,7045	-46,6145	208,43	Alta	Implantação viável
5	45	-20,7056	-46,6139	-20,7116	-46,6159	696,47	Alta	Implantação viável
5	46	-20,7047	-46,6099	-20,7047	-46,6139	416,87	Alta	Implantação viável
5	47	-20,7070	-46,6105	-20,7130	-46,6085	696,47	Alta	Implantação viável
5	48	-20,7100	-46,6131	-20,7100	-46,6111	208,43	Baixa	Posição sem vias
5	49	-20,7124	-46,6121	-20,7084	-46,6141	489,61	Alta	Implantação viável
5	52	-20,7171	-46,6093	-20,7171	-46,6073	208,42	Alta	Implantação viável
5	53	-20,7181	-46,6108	-20,7161	-46,6108	221,52	Alta	Implantação viável
5	54	-20,7219	-46,61	-20,7179	-46,6100	443,04	Alta	Implantação viável
5	55	-20,7230	-46,6059	-20,7210	-46,6059	221,52	Alta	Implantação viável
5	56	-20,7208	-46,6037	-20,7248	-46,6017	489,61	Alta	Implantação viável

5	59	-20,7144	-46,6022	-20,7204	-46,6022	664,56	Alta	Implantação viável
5	60	-20,7128	-46,6005	-20,7168	-46,6005	443,04	Alta	Implantação viável
5	61	-20,7105	-46,5980	-20,7125	-46,5940	472,05	Alta	Implantação viável
5	62	-20,7144	-46,5983	-20,7144	-46,5963	208,42	Alta	Implantação viável
5	63	-20,7178	-46,5947	-20,7198	-46,5947	221,52	Alta	Implantação viável
5	64	-20,7201	-46,5922	-20,7181	-46,5902	304,15	Alta	Implantação viável
5	65	-20,7202	-46,5911	-20,7202	-46,5931	208,41	Alta	Implantação viável
5	66	-20,7218	-46,5894	-20,7178	-46,5914	489,61	Alta	Implantação viável
5	67	-20,7235	-46,5897	-20,7195	-46,5897	443,04	Alta	Implantação viável
5	68	-20,7228	-46,5962	-20,7228	-46,5942	208,41	Alta	Implantação viável
5	69	-20,7293	-46,5932	-20,7233	-46,5912	696,47	Média	Rua sem asfaltamento

Fonte: Elaborado pelo autor (2026).

APÊNDICE C – REPOSITÓRIO DA PESQUISA

O modelo computacional, dividido em etapas para melhor apresentação, encontra-se disponibilizado na plataforma AnyLogic Cloud®, permitindo sua execução, inspeção e replicação por outros pesquisadores. Adicionalmente, foram disponibilizados vídeos explicativos contendo o processo de construção e execução do modelo, permitindo maior transparência metodológica e facilitando a replicação por pesquisadores interessados, via plataforma YouTube. Abaixo os links para acesso aos sítios virtuais:

- Parte 1 – Geração da matriz OD
  - AnyLogic Cloud®: https://cloud.anylogic.com/model/1e73dd14-3e1f-43f7-9b8b-8b711fcef4bf?mode=SETTINGS&tab=GENERAL
  - YouTube: https://youtu.be/4pX1BBvCmr4

- Parte 2 – Mobilidade por transporte público com ônibus
  - AnyLogic Cloud®: https://cloud.anylogic.com/model/d26cf77a-eae6-4424-af69-6c2cecd7ba3f?mode=SETTINGS&tab=GENERAL
  - YouTube: https://youtu.be/hyfJGoLPYy4

- Parte 3 – Calibração de usuários aptos para transporte público
  - AnyLogic Cloud®: https://cloud.anylogic.com/model/58210136-02b9-4533-9650-11cb87bf17ab?mode=SETTINGS&tab=GENERAL
  - YouTube: https://youtu.be/5HSDoMNO6sk

- Parte 4 – Racionalização por *machine learning*
  - AnyLogic Cloud®: https://cloud.anylogic.com/model/a8b649e5-2997-4534-8bf7-d4eed44357ba?mode=SETTINGS&tab=GENERAL
  - YouTube: https://youtu.be/aixWLQKzFV8

Como evolução e divulgação científica, alguns trabalhos foram publicados da referida tese. Abaixo a lista dos mesmos:

FERREIRA JUNIOR, J. S.; LIMA, J. P.; PINHO, A. F. Hybrid Modeling and Simulation for Urban Mobility: A Systematic Review and Future Research Agenda. **IEEE Access**, vol. 14, pp. 80237-80251, 2026. DOI: 10.1109/ACCESS.2026.3694240.

FERREIRA JUNIOR, J. S.; PALMA LIMA, JOSIANE; PINHO, A. F. Aplicação do indicador de acessibilidade em pontos de ônibus por simulação híbrida. *In*: IEPG SUMMIT: Planejamento o futuro com inteligência artificial e consciência social, 2025, Itajubá. **Anais do IEPG Summit 2025**.

FERREIRA JUNIOR, J. S.; LIMA, J. P.; PINHO, A. F. Simulação híbrida para múltiplas linhas de transporte coletivo por ônibus de Passos/MG: modelo axiomático descritivo. *In*: SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL, 57, 2025. **Anais do LVII SBPO 2025.** DOI: 10.59254/sbpo-2025-212615.

FERREIRA JUNIOR, J. S.; LIMA, J. P.; PINHO, A. F. Modelagem e Simulação Axiomática Descritiva Baseada em Agentes da Linha 1 do transporte coletivo por ônibus de Passos/MG *In*: SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL, 56, 2024. **Anais do LVI SBPO 2024.** DOI: 10.59254/sbpo-2024-193853.

FERREIRA JUNIOR, J. S.; PINHO, A. F.; LIMA, J. P. Simulação baseada em agentes - análise teórica dos artigos publicados entre 2014 e 2023 nos anais do ENEGEP e SBPO. *In*: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 2024, Porto Alegre/RS - Brasil. **Anais do ENEGEP 2024.** DOI: 10.14488/enegep2024_tn_st_413_2028_47571.

FERREIRA JUNIOR, J. S.; PINHO, A. F.; LIMA, J. P. Desenvolvimento de modelo de simulação baseada em agentes para racionalização do roteiro de transporte por ônibus por meio da teoria dos grafos e do machine learning. *In*: IEPG SUMMIT: construindo o futuro com inovação e sustentabilidade, 2023, Itajubá/MG. **Anais do IEPG Summit 2023**.

FERREIRA JUNIOR, J. S.; PINHO, A. F.; LIMA, J. P. Mapa científico por análise bibliométrica da sinergia entre simulação baseada em agentes e logística urbana utilizando bibliometrix. *In*: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 2022, Foz do Iguaçu/PR - BRASIL. **Anais do ENEGEP 2022.** DOI: 10.14488/enegep2022_tn_st_383_1896_43937.