

UNIVERSIDADE DE SÃO PAULO
ESCOLA POLITÉCNICA DA UNIVERSIDADE DE SÃO PAULO

BRUNO HENRIQUE PAES

**USO DA SIMULAÇÃO PARA AVALIAR POSIÇÕES DE BASES DE SERVIÇOS
PÚBLICOS**

São Paulo
2025

BRUNO HENRIQUE PAES

**USO DA SIMULAÇÃO PARA AVALIAR POSIÇÕES DE BASES DE SERVIÇOS
PÚBLICOS**

Trabalho de Formatura apresentado à Escola
Politécnica da Universidade de São Paulo para a
obtenção do diploma de Engenheiro de Produção.

Orientador: Daniel de Oliveira Mota

São Paulo
2025

RESUMO

Este estudo teve como objetivo analisar a eficiência operacional e a otimização do sistema de transporte de táxis no Campus da Universidade de São Paulo (USP), por meio de simulação computacional e modelagem de fluxo. A pesquisa se concentrou em compreender de que forma o georreferenciamento e a implementação de lógicas otimizadas de alocação de veículos podem aprimorar o desempenho do sistema, considerando aspectos como distribuição dos táxis, tempo de espera, deslocamento até o usuário e nível geral de serviço. A simulação foi realizada utilizando três cenários principais: o sistema atual (AS-IS), o modelo otimizado (TO-BE) e uma versão ampliada com variáveis adicionais, incluindo aumento da frota disponível e novas configurações operacionais. A metodologia adotada foi organizada em três etapas fundamentais: levantamento conceitual, desenvolvimento do modelo de simulação e análise comparativa do desempenho entre os cenários propostos. Inicialmente, foi conduzido um levantamento bibliográfico estruturado para fundamentar a modelagem computacional e os parâmetros adotados para representar o comportamento da demanda e dos agentes. Em seguida, desenvolveu-se a simulação do sistema AS-IS, tomando como referência a dinâmica real dos fluxos internos do campus. Na sequência, foi elaborada a modelagem TO-BE, incorporando estratégias de otimização e redistribuição espacial das bases, com o objetivo de melhorar o atendimento às solicitações de transporte. A validação empírica utilizou coordenadas reais dos pontos de táxi e das origens das demandas, garantindo maior precisão na representação espacial da operação. O desempenho dos cenários foi avaliado por meio de métricas como nível de serviço, tempo médio de atendimento, distância percorrida e disponibilidade de veículos. Os resultados indicaram que o modelo otimizado (TO-BE) apresentou desempenho superior ao do modelo AS-IS, especialmente no que se refere à redução do tempo de espera e à melhoria da distribuição da frota. As lógicas otimizadas proporcionaram maior equilíbrio entre a oferta de veículos e a demanda simulada, enquanto o georreferenciamento permitiu maior controle sobre as localizações críticas do sistema, ampliando a eficiência operacional. Entretanto, a pesquisa também revelou que, em situações de demanda elevada, o sistema continua a enfrentar limitações relacionadas ao aumento do tempo de resposta e ao maior deslocamento dos veículos, apontando a necessidade de ajustes contínuos. A discussão destacou a relevância da simulação computacional como instrumento de análise e aprimoramento de sistemas urbanos complexos, evidenciando os avanços obtidos a partir da comparação entre os cenários. A implementação futura de veículos autônomos e o uso de inteligência artificial para ajustes dinâmicos foram sugeridos como possíveis evoluções do modelo. Em conclusão, o estudo demonstrou que lógicas otimizadas podem melhorar significativamente a eficiência do transporte em ambientes universitários e urbanos, embora ajustes contínuos sejam necessários para lidar com flutuações de demanda. Pesquisas futuras devem incorporar novas tecnologias, avaliar impactos ambientais e explorar estratégias de sustentabilidade para o sistema analisado.

Palavras-chave: Simulação computacional, Transporte de táxis, Georreferenciamento, Eficiência operacional, Fluxos otimizados, Mobilidade urbana.

ABSTRACT

This study aimed to analyze the operational efficiency and optimization of the taxi transportation system at the University of São Paulo (USP) Campus through computational simulation and flow modeling. The research focused on understanding how georeferencing and the implementation of optimized vehicle allocation logics can enhance system performance, considering aspects such as taxi distribution, waiting time, distance to the user, and overall service level. The simulation was conducted using three main scenarios: the current system (AS-IS), the optimized model (TO-BE), and an expanded version including additional variables, such as an increased fleet and new operational configurations. The methodology was organized into three fundamental stages: conceptual groundwork, development of the simulation model, and comparative performance analysis between the proposed scenarios. Initially, a structured literature survey was conducted to support the computational modeling and the parameters adopted to represent demand behavior and agent interactions. Following this stage, the AS-IS system simulation was developed, using the actual dynamics of internal campus flows as a reference. Subsequently, the TO-BE model was constructed, incorporating optimization strategies and spatial redistribution of taxi bases with the aim of improving service responsiveness. Empirical validation was carried out using real coordinates of taxi stands and demand origin points, ensuring greater spatial accuracy in the representation of system operations. Scenario performance was assessed using metrics such as service level, average response time, distance traveled, and vehicle availability. The results indicated that the optimized model (TO-BE) achieved superior performance compared to the AS-IS model, particularly regarding reductions in waiting time and improvements in fleet distribution. The optimized logics provided a better balance between vehicle supply and simulated demand, while georeferencing enabled greater control over critical system locations, enhancing operational efficiency. However, the study also showed that under high-demand conditions, the system still faces limitations related to increased response time and greater distances traveled by vehicles, indicating the need for continuous adjustments. The discussion emphasized the relevance of computational simulation as a tool for analyzing and improving complex urban systems, highlighting the advancements achieved through the comparison of scenarios. The future implementation of autonomous vehicles and the use of artificial intelligence for dynamic operational adjustments were suggested as potential developments for the model. In conclusion, the study demonstrated that optimized logics can significantly improve transportation efficiency in university and urban environments, although continuous refinements are necessary to address demand fluctuations. Future research should incorporate new technologies, assess environmental impacts, and explore sustainability strategies for the system analyzed.

Keywords: Computational simulation, Taxi transportation, Georeferencing, Operational efficiency, Optimized flows, Urban mobility.

LISTA DE FIGURAS

Figura 1. Fluxograma PRISMA	39
Figura 2. Simulação Modelo Táxi	42
Figura 3. requestPedido.....	43
Figura 4. Diagrama de Estado Táxi	44
Figura 5. Lógica Embarque de Passageiro	45
Figura 6. Lógica Desembarque/Pagamento de Passageiro.....	46
Figura 7. Localização Pontos de Táxi	47
Figura 8. Localização Estação Butantã	48
Figura 9. Request Lifecycle	48
Figura 10. System Prototype Grid.....	49
Figura 11. Táxi aguardando solicitações	50
Figura 12. Surgimento de demanda (estrela = origem, quadrado = destino)	50
Figura 13. Definição da rota pelo táxi mais próximo.....	51
Figura 14. Surgimento de novas demandas e redistribuição de veículos	52
Figura 15. Surgimento de novas demandas e redistribuição de veículos	52
Figura 16. Embarque e deslocamento de passageiros	53
Figura 17. Embarque e deslocamento de passageiros	54
Figura 18. Desembarque e retorno ao ponto de táxi.....	54
Figura 19. Desembarque e retorno ao ponto de táxi.....	55
Figura 20. Finalização do ciclo e disponibilidade de novos atendimentos	56
Figura 21. Finalização do ciclo e disponibilidade de novos atendimentos	56
Figura 22. Nova Lógica de Desembarque de Passageiros.....	57
Figura 23. Simulação Desembarque Estação Butantã.....	58
Figura 24. Simulação Desembarque Estação Butantã.....	59
Figura 25. People Daycycle	59
Figura 26. Sistema de Blocos.....	60

Figura 27. Solicitação de demanda em uma residência.....	61
Figura 28. Fluxo de transporte de passageiros	61
Figura 29. Trânsito de pessoas no sistema	62
Figura 30. Opções pós-expediente do usuário (voltar para casa ou seguir para lazer).....	63
Figura 31. Gráfico do nível de serviço por solicitações por hora (13 veículos).....	78
Figura 32. Gráfico do nível de serviço por solicitações por hora (26 veículos).....	79
Figura 33. Gráfico do nível de serviço por solicitações por hora (39 veículos).....	80
Figura 34. Gráfico do nível de serviço por solicitações por hora (52 veículos).....	81
Figura 35. Gráfico do nível de serviço por solicitações por hora (65 veículos).....	82
Figura 36. Gráfico do tempo médio de corrida por SPH.....	85
Figura 37. Gráfico da distância média até solicitação	86
Figura 38. Gráfico da distância média até pedido para Cenário 3.....	87

LISTA DE TABELAS

Tabela 1.	Cenário 1 - métricas coletadas.....	65
Tabela 2.	Cenário 2 - métricas coletadas.....	66
Tabela 3.	Cenário 3 - métricas coletadas.....	67
Tabela 4.	Métricas agrupadas para 5 solicitações por hora.....	68
Tabela 5.	Métricas agrupadas para 6 solicitações por hora.....	69
Tabela 6.	Métricas agrupadas para 7 solicitações por hora.....	70
Tabela 7.	Métricas agrupadas para 8 solicitações por hora.....	71
Tabela 8.	Métricas agrupadas para 9 solicitações por hora.....	72
Tabela 9.	Métricas agrupadas para 10 solicitações por hora.....	73
Tabela 10.	Nível de serviço para 13 veículos.....	74
Tabela 11.	Nível de serviço para 26 veículos.....	74
Tabela 12.	Nível de serviço para 39 veículos.....	75
Tabela 13.	Nível de serviço para 52 veículos.....	75
Tabela 14.	Nível de serviço para 65 veículos.....	76
Tabela 15.	Distância média até a solicitação para 13 veículos.....	81
Tabela 16.	Distância média até a solicitação para 26 veículos.....	82
Tabela 17.	Distância média até a solicitação para 39 veículos.....	82
Tabela 18.	Distância média até a solicitação para 52 veículos.....	82
Tabela 19.	Distância média até a solicitação para 65 veículos.....	82

SUMÁRIO

1. INTRODUÇÃO.....	10
1.1 Motivação	10
1.2 Contextualização.....	11
1.3 Objetivos	12
1.4 Estrutura do estudo	13
2. REVISÃO DE LITERATURA	16
2.1 Simulação na engenharia de produção e na logística urbana.....	16
2.2 Modelos de localização e alocação de serviços públicos	20
2.3 Aplicação do <i>digital twin</i> em ambientes urbanos	24
2.4 Avaliação de desempenho e eficiência operacional.....	29
2.5 Otimização de fluxos e tomada de decisão baseada em simulação	33
2.6 Procedimentos de busca da literatura.....	38
3. METODOLOGIA.....	41
3.1 Levantamento conceitual e parâmetros.....	41
3.2 Desenvolvimento da simulação computacional.....	41
3.3 Estrutura e Funcionamento do Modelo.....	42
3.4 Ciclo de atendimento e lógica operacional	44
3.5 Georreferenciamento e parâmetros espaciais	46
3.6 Ciclo de vida dos pedidos e representação visual.....	48
3.7 Expansão da simulação: dinâmica de desembarque e fluxo de pessoas	57
3.8 Simulação expandida: estrutura urbana e ciclo de vida do cidadão	59
4. RESULTADOS	64
4.1 Coleta e tratamento dos dados	64
4.2 Comparação intercenários.....	68
4.4 Avaliação do nível de serviço	74
4.5 Avaliação da distância média	82

4.6 Síntese interpretativa e resultados consolidados.....	87
5. DISCUSSÃO	89
5.1 Modelagem AS-IS - Simulação do Sistema Atual de Táxis	89
5.2 Implementação TO-BE - Inclusão de Lógicas Otimizadas e Novos Fluxos	90
5.3 Georreferenciamento e Validação Empírica - Uso de Coordenadas Reais	92
5.4 Comparação e Análise de Desempenho - Avaliação Quantitativa e Qualitativa.....	93
6. CONCLUSÃO.....	96
REFERÊNCIAS BIBLIOGRÁFICAS	98

1. INTRODUÇÃO

1.1 Motivação

A organização e a eficiência dos serviços públicos são temas que vêm adquirindo crescente relevância na Engenharia de Produção, sobretudo diante da necessidade de otimizar o uso dos recursos públicos e atender adequadamente às demandas urbanas. Os serviços públicos, especialmente aqueles ligados à mobilidade e segurança, dependem de um arranjo logístico eficaz que assegure rapidez e qualidade na prestação do atendimento (Daniel *et al.*, 2020). Nesse sentido, a análise da localização de bases operacionais torna-se estratégica para minimizar tempos de resposta e aumentar a cobertura dos serviços, considerando fatores como fluxo de tráfego, demanda espacial e acessibilidade.

A expansão das cidades brasileiras intensificou o desafio de planejar infraestruturas urbanas que equilibrem eficiência operacional e bem-estar social. As universidades, enquanto microcosmos urbanos, enfrentam dilemas semelhantes: a concentração de fluxos e a necessidade de atendimento ágil em áreas de alta densidade tornam essencial o planejamento adequado das bases de serviços públicos internos, como transporte, segurança e manutenção (Almeida *et al.*, 2023). O uso de simulações computacionais oferece uma possibilidade concreta de compreender e testar diferentes configurações de alocação, permitindo reduzir custos e melhorar a eficácia do atendimento.

A transformação digital no setor público introduziu uma perspectiva analítica mais orientada a dados, em que ferramentas computacionais e modelos matemáticos passaram a integrar o processo decisório. Conforme observam Francisco e Bonette (2021), a adoção de tecnologias de modelagem e *digital twin* contribui para uma visão integrada da cidade e das suas operações, permitindo a testagem virtual de políticas urbanas antes da execução real. Essa possibilidade de reproduzir digitalmente a dinâmica urbana é especialmente promissora quando aplicada à alocação de bases operacionais, pois permite avaliar alternativas com precisão e em tempo reduzido.

A motivação deste estudo decorre, portanto, da necessidade de repensar a disposição de bases de serviços públicos sob uma ótica sistêmica, em que a simulação e a modelagem digital sejam instrumentos de apoio à tomada de decisão. O aprimoramento dos métodos de localização e a incorporação de ferramentas tecnológicas tornam-se medidas estratégicas para garantir o atendimento eficiente de demandas urbanas complexas (Simette, Rezende e Sequeira, 2025). Assim, o presente trabalho propõe avaliar a aplicação de simulação computacional e *digital twin* no redesenho das bases de táxis de uma universidade com alta densidade de fluxo.

1.2 Contextualização

A logística urbana é um campo em constante transformação, marcado pelo desafio de integrar tecnologias, sustentabilidade e gestão pública eficiente. As administrações municipais e institucionais buscam equilibrar custos operacionais e qualidade no atendimento, o que exige planejamento embasado em dados e evidências (Daniel *et al.*, 2020). A literatura recente destaca que o modelo tradicional de gestão de serviços públicos, baseado apenas na intuição ou em critérios empíricos, tende a gerar alocações ineficazes, redundância de esforços e baixa responsividade. A integração entre engenharia e políticas públicas passa a ser, portanto, indispensável para o desenvolvimento urbano inteligente.

As universidades brasileiras, por seu porte e estrutura, funcionam como cidades em escala reduzida, abrigando fluxos intensos de pessoas, veículos e serviços. Essa complexidade exige o uso de ferramentas que permitam simular diferentes arranjos espaciais para a otimização das operações. Segundo Almeida *et al.* (2023), a inovação pela coprodução de serviços públicos, envolvendo gestores, pesquisadores e usuários, constitui um caminho eficaz para repensar a infraestrutura institucional. Esse modelo de colaboração encontra suporte na teoria da localização, que propõe decisões logísticas baseadas em critérios de acessibilidade, centralidade e demanda.

A relação entre tecnologia e gestão pública tem sido ampliada pela implementação de projetos de governança digital, que integram inteligência artificial, *blockchain* e sistemas de simulação para apoiar decisões estratégicas (Sampaio, 2025). Tais iniciativas buscam tornar os serviços mais responsivos, reduzindo desperdícios e aumentando a transparência. A aplicação do conceito de *digital twin*, ou gêmeo digital, no contexto urbano, representa uma das mais relevantes inovações recentes, pois permite a criação de réplicas digitais de sistemas reais para testar cenários, prever resultados e aprimorar políticas públicas antes de sua execução.

No âmbito da mobilidade urbana e da segurança, a localização estratégica de bases operacionais — como as de táxis, policiamento e manutenção — constitui um fator determinante para a eficiência das respostas (Francisco e Bonette, 2021). No entanto, a realocação dessas bases geralmente é feita de maneira empírica, sem considerar variáveis críticas como tempo de deslocamento, tráfego e densidade de demanda. Essa limitação torna evidente a necessidade de metodologias que incorporem variáveis dinâmicas e técnicas de simulação preditiva, assegurando decisões mais precisas e sustentáveis.

A análise proposta por Simette, Rezende e Sequeira (2025) sobre cidades digitais estratégicas reforça que a eficiência na gestão pública depende da capacidade de integrar

ferramentas de análise espacial e de inteligência de dados. O conceito de cidade digital estratégica se apoia na ideia de que a tomada de decisão deve ser sustentada por sistemas de informação em tempo real, permitindo ajustes imediatos em função das condições observadas. Aplicar essa lógica a uma universidade, que concentra fluxos comparáveis aos de um pequeno centro urbano, justifica o emprego da simulação como instrumento de diagnóstico e planejamento operacional.

Além disso, o uso da simulação computacional permite reduzir custos experimentais e riscos associados à implementação de mudanças estruturais. Conforme argumenta Daniel *et al.* (2020), as administrações públicas frequentemente enfrentam barreiras orçamentárias e burocráticas que limitam a experimentação direta. Modelar digitalmente o sistema e executar simulações representa, nesse contexto, uma alternativa eficiente e segura para testar cenários e propor soluções com base empírica, sem necessidade de interferência imediata na realidade física.

A aplicação de tais modelos na gestão de bases de serviços públicos permite, ainda, alinhar-se aos princípios de sustentabilidade e inovação. A otimização espacial de recursos reduz o consumo energético, diminui deslocamentos desnecessários e melhora a alocação de equipes (Almeida *et al.*, 2023). O uso de simulações urbanas integradas a modelos *digital twin* proporciona uma visão preditiva que favorece tanto a eficiência operacional quanto a tomada de decisões mais embasadas em evidências científicas e sociais.

1.3 Objetivos

O presente estudo tem como objetivo geral analisar o uso da simulação computacional como ferramenta para avaliar e otimizar as posições de bases de serviços públicos em ambientes urbanos, propondo um modelo de localização baseado em *digital twin* aplicado às bases de táxis da Universidade de São Paulo.

De forma mais específica, busca-se:

1. Identificar o problema operacional e logístico relacionado à ineficiência das bases atuais de serviços públicos na universidade, considerando fluxo de demanda e tempo de resposta;
2. Revisar criticamente a literatura sobre métodos de simulação aplicados à Engenharia de Produção e à gestão de operações urbanas;

3. Aplicar o conceito de *digital twin* para representar o ambiente urbano e testar diferentes configurações de localização de bases;
4. Comparar o desempenho do modelo atual (*AS-IS*) com o modelo proposto (*TO-BE*), considerando variáveis de tráfego, distância e tempo médio de atendimento;
5. Avaliar a eficácia do modelo otimizado em termos de eficiência operacional e potencial de replicação em outros contextos de serviços públicos.

Esses objetivos convergem para a construção de um modelo de análise aplicável tanto a universidades quanto a administrações municipais, com foco na melhoria contínua da alocação de recursos e da prestação de serviços à comunidade (Sampaio, 2025).

1.4 Estrutura do estudo

A condução deste trabalho segue uma sequência metodológica alinhada aos princípios da Engenharia de Produção e às exigências analíticas das simulações urbanas. O desenvolvimento da pesquisa ocorre em etapas complementares, estruturadas da seguinte forma: A primeira etapa corresponde à identificação do problema, associado à limitação das bases de serviços públicos em atender de forma eficiente à demanda de uma universidade com alta densidade populacional (Daniel *et al.*, 2020). Essa etapa permite caracterizar o cenário de interesse e reconhecer insuficiências operacionais que justificam a necessidade de reorganização espacial.

A segunda etapa envolve a justificativa da relevância e pertinência do problema, sustentada pela crescente adoção de técnicas de modelagem computacional no planejamento urbano (Almeida *et al.*, 2023). A importância social está relacionada à melhoria da qualidade dos serviços prestados, enquanto a importância tecnológica decorre do emprego de simulações e modelos de *digital twin* para representação dinâmica do ambiente de estudo.

A terceira etapa consiste na organização da literatura especializada, utilizada para fundamentar os conceitos técnicos aplicados nas seções posteriores. Esse levantamento foi estruturado de maneira criteriosa e registrado por meio de um fluxograma PRISMA adaptado, incorporado ao Capítulo 2 como mecanismo de transparência quanto ao processo de seleção das referências que compõem a fundamentação teórica (Francisco e Bonette, 2021). Ressalta-se que tal procedimento não caracteriza uma revisão sistemática, mas sim um método de organização conceitual que apoia a definição dos parâmetros de modelagem.

Na quarta etapa, realiza-se o levantamento de dados empíricos, abrangendo informações sobre fluxo de veículos, tempos médios de atendimento e distribuição espacial das bases existentes. Esses dados constituem os insumos necessários para estruturar as simulações e possibilitam a comparação entre o cenário atual (AS-IS) e os cenários propostos (TO-BE) (Simette, Rezende e Sequeira, 2025).

A quinta etapa refere-se à proposição de alternativas de redistribuição das bases, desenvolvidas a partir dos resultados das simulações. São testados diferentes arranjos espaciais considerando variáveis como densidade de demanda, acessibilidade e condições de tráfego, a fim de identificar configurações compatíveis com o ambiente físico e capazes de elevar o desempenho operacional (Sampaio, 2025).

A sexta etapa compreende a seleção da configuração mais adequada, fundamentada em critérios objetivos, tais como redução de tempos de resposta, otimização de recursos e ampliação da cobertura de atendimento. A decisão é tomada com base na análise comparativa entre os cenários simulados e nas implicações técnicas e administrativas observadas.

A sétima e última etapa envolve a avaliação crítica da solução proposta, integrando análises quantitativas e qualitativas para verificar a consistência dos resultados e o potencial de replicação da metodologia em outros contextos. Essa etapa consolida a aplicabilidade do método HALTER à gestão de serviços públicos e aos estudos da Engenharia de Produção (Almeida *et al.*, 2023).

A organização do trabalho está apresentada a seguir:

- **Capítulo 1 – Introdução:** apresenta a contextualização, motivação, objetivos, método geral e estrutura da pesquisa.
- **Capítulo 2 – Fundamentação teórica:** reúne cinco eixos conceituais essenciais ao estudo e integra a descrição do PRISMA adaptado empregado para organizar a literatura utilizada.
- **Capítulo 3 – Metodologia:** detalha as etapas da pesquisa, procedimentos de coleta de dados, cenários simulados e parâmetros aplicados ao modelo.
- **Capítulo 4 – Resultados e discussão:** apresenta comparações entre o cenário atual e as alternativas propostas, destacando o desempenho operacional obtido.
- **Capítulo 5 – Conclusão:** sintetiza contribuições, limitações e perspectivas de continuidade do estudo.

Essa estrutura assegura coerência, progressão lógica e rastreabilidade das etapas, compatíveis com a natureza aplicada e analítica da abordagem adotada.

2. REVISÃO DE LITERATURA

2.1 Simulação na engenharia de produção e na logística urbana

A simulação computacional tornou-se uma das principais ferramentas da Engenharia de Produção e da logística urbana, especialmente em contextos de tomada de decisão que envolvem múltiplas variáveis interdependentes. Essa técnica consiste em reproduzir digitalmente sistemas reais para compreender seu comportamento sob diferentes condições e intervenções, o que possibilita reduzir custos, otimizar recursos e prever resultados operacionais. Na gestão urbana, a simulação tem sido aplicada para modelar fluxos de transporte, avaliar desempenho de serviços e projetar estruturas logísticas que respondam de forma eficiente à demanda (Baalrsud Hauge e Jeong, 2024).

Historicamente, o uso da simulação na Engenharia de Produção esteve associado ao controle de processos industriais e à otimização de cadeias produtivas. Com o avanço da tecnologia computacional e o aumento da capacidade de processamento de dados, seu campo de aplicação expandiu-se para o planejamento urbano e os sistemas de transporte, permitindo uma abordagem mais sistêmica e realista. Os modelos de simulação são capazes de representar dinâmicas complexas, como o comportamento do tráfego e a distribuição espacial de serviços públicos, viabilizando análises que antes dependiam de longos períodos de observação empírica (Goodwin *et al.*, 2021).

No contexto da logística urbana, a simulação computacional auxilia na gestão de fluxos de materiais e pessoas, oferecendo suporte para decisões estratégicas sobre localização, roteirização e dimensionamento de recursos. Essa técnica permite identificar gargalos, testar alternativas e prever o impacto de mudanças estruturais, promovendo melhorias operacionais contínuas. Conforme salientam Singh *et al.* (2021), o valor dessa abordagem reside na capacidade de reproduzir cenários reais com precisão, reduzindo o risco de falhas e otimizando o tempo de resposta das operações urbanas.

Entre os métodos de simulação mais utilizados estão a simulação de eventos discretos, a simulação baseada em agentes e a simulação híbrida. A primeira foca na análise sequencial de eventos que ocorrem em determinado sistema, enquanto a segunda introduz variáveis comportamentais, modelando agentes que interagem segundo regras definidas. Essa integração torna a simulação uma ferramenta poderosa para o planejamento urbano, especialmente em contextos de alta densidade, como grandes universidades ou centros metropolitanos (Van Heeswijk *et al.*, 2020).

A aplicação de modelos baseados em agentes na logística urbana permite compreender a interação entre diferentes componentes do sistema — veículos, pedestres e infraestrutura — em ambientes dinâmicos e não lineares. Essa abordagem tem se mostrado eficaz para analisar o impacto de políticas de mobilidade, reorganização de tráfego e localização de bases operacionais. Além disso, possibilita avaliar o comportamento dos usuários e dos prestadores de serviço de maneira detalhada, algo essencial para a formulação de estratégias de atendimento mais eficientes (Van Heeswijk *et al.*, 2020).

No âmbito da Engenharia de Produção, a simulação também tem sido empregada como instrumento de apoio à inovação e à reconfiguração de sistemas produtivos. Segundo Goodwin *et al.* (2023), o avanço de técnicas de otimização associadas à simulação, como *Epsilon Optimal Sampling*, contribui para a criação de modelos preditivos mais precisos, capazes de adaptar-se às condições variáveis dos processos industriais e urbanos. Essa integração entre simulação e otimização oferece aos gestores um ambiente virtual de experimentação que reduz custos e amplia o potencial de eficiência.

A utilização da simulação computacional também se destaca por sua aplicabilidade interdisciplinar. Na logística urbana, ela é usada tanto em análises estratégicas quanto operacionais, apoiando desde o planejamento de longo prazo até o gerenciamento diário das operações. A versatilidade da ferramenta permite a criação de modelos adaptáveis, ajustáveis conforme a escala do problema ou a disponibilidade de dados. Em ambientes complexos, como cidades ou universidades, essa flexibilidade é indispensável para lidar com variáveis que mudam em tempo real (Singh *et al.*, 2021).

O uso de simulações em sistemas de transporte urbano tem evoluído de modelos estáticos para representações dinâmicas integradas a dados em tempo real. Esses avanços possibilitam a análise de rotas, tempos de espera, consumo de combustível e emissão de poluentes, promovendo uma visão abrangente da eficiência operacional. A simulação baseada em agentes, por exemplo, permite avaliar o comportamento coletivo em resposta a mudanças de infraestrutura, como a realocação de bases de serviços públicos (Baalrsud Hauge e Jeong, 2024).

A capacidade de integrar a simulação a processos de aprendizado computacional amplia ainda mais seu potencial. Segundo Goodwin *et al.* (2021), a combinação de simulação e aprendizado de máquina cria um ciclo iterativo de aprimoramento, no qual os resultados geram dados que retroalimentam o sistema, ajustando continuamente os parâmetros de análise. Essa característica é particularmente útil na logística urbana, onde as condições mudam rapidamente e as decisões precisam ser adaptadas a partir de novas informações.

A aplicação de simulação na análise de processos de coleta e gestão de resíduos urbanos também tem se consolidado como uma tendência. O estudo conduzido por Morán-Zabala *et al.* (2024) apresenta um modelo de otimização com base em simulação para o controle de qualidade na coleta de resíduos sólidos. O método permite identificar rotas mais eficientes, reduzir custos operacionais e minimizar impactos ambientais, mostrando a capacidade dessa técnica de gerar soluções aplicáveis tanto a serviços públicos quanto a sistemas produtivos.

A Engenharia de Produção, ao incorporar ferramentas de simulação, promove uma transformação significativa na forma de planejar e avaliar processos. Essa integração possibilita uma visão sistêmica dos fluxos produtivos e urbanos, superando a fragmentação tradicional das análises. Conforme Santos *et al.* (2021), a otimização baseada em simulação aplicada a sistemas de produção permite não apenas a melhoria da produtividade, mas também o desenvolvimento de soluções mais sustentáveis, ajustadas às restrições ambientais e econômicas contemporâneas.

A modelagem e simulação contribuem, ainda, para a análise de incertezas em ambientes complexos. Em vez de depender exclusivamente de dados históricos, o pesquisador pode introduzir variações controladas nos parâmetros e observar seus efeitos no desempenho do sistema. Essa abordagem reduz a dependência de experimentação real e amplia o escopo das hipóteses testadas. Souza *et al.* (2020) destacam que a simulação de processos operacionais de minas a céu aberto exemplifica essa capacidade, pois permite antecipar falhas e otimizar a utilização de recursos antes da implementação prática.

O avanço tecnológico tem permitido que as ferramentas de simulação se tornem mais acessíveis e interativas. Modelos que antes exigiam alto custo computacional agora podem ser executados em plataformas abertas e integradas, o que democratiza seu uso em instituições públicas e privadas. Baalrsud Hauge e Jeong (2024) ressaltam que a adoção de softwares de código aberto amplia o acesso à simulação aplicada à logística urbana, fomentando a colaboração entre universidades, empresas e órgãos públicos.

Outro aspecto relevante é o uso da simulação como instrumento de participação social na formulação de políticas públicas. Singh *et al.* (2021) propõem um modelo participativo baseado em simulação, que permite aos diferentes agentes — gestores, cidadãos e especialistas — interagir com os resultados e contribuir para o aperfeiçoamento das decisões. Essa abordagem reforça o caráter democrático e colaborativo das ferramentas tecnológicas, estimulando o engajamento social no processo de planejamento urbano.

No campo da logística urbana, a simulação também tem sido utilizada para aprimorar a eficiência de sistemas de entrega e transporte coletivo. Van Heeswijk *et al.* (2020)

desenvolveram modelos baseados em agentes para avaliar esquemas de transporte de carga e passageiros, identificando oportunidades de melhoria no fluxo de veículos e na redução de tempos ociosos. Tal estudo reforça a importância da modelagem como suporte à modernização das infraestruturas urbanas.

A integração entre simulação e otimização operacional representa um avanço significativo para a Engenharia de Produção. Essa combinação permite identificar as melhores soluções entre um grande conjunto de possibilidades, equilibrando critérios de custo, tempo e qualidade. Conforme Goodwin *et al.* (2023), as técnicas de amostragem otimizadas melhoram a precisão dos resultados e reduzem o tempo de processamento, tornando o método aplicável a contextos reais de grande escala.

A análise de processos urbanos complexos, como a localização de bases operacionais, exige a consideração de múltiplas variáveis que interagem entre si. A simulação computacional, ao reproduzir essas interações, permite testar diferentes cenários e avaliar o impacto de cada decisão. Morán-Zabala *et al.* (2024) demonstram que modelos híbridos, combinando simulação e otimização, podem gerar soluções adaptáveis a variações de demanda, mantendo o equilíbrio entre custo e eficiência.

Na gestão de serviços públicos, a simulação também atua como ferramenta de diagnóstico. Ao identificar gargalos e sobreposições de recursos, ela orienta a redistribuição de equipes e equipamentos de forma mais racional. Essa capacidade de antecipar falhas e propor soluções fundamentadas em dados tem fortalecido a adoção de modelos computacionais no setor público (Santos *et al.*, 2021).

Além de sua relevância operacional, a simulação contribui para o aprimoramento metodológico da pesquisa aplicada em Engenharia de Produção. Ela possibilita validar teorias, testar hipóteses e avaliar impactos de inovações sem necessidade de experimentos reais, o que acelera o ciclo de desenvolvimento de soluções tecnológicas (Souza *et al.*, 2020). Essa característica reforça o papel da simulação como elo entre o conhecimento teórico e a prática profissional.

A simulação computacional, ao ser empregada em sistemas urbanos, exige a integração de dados espaciais, temporais e comportamentais. Essa característica faz dela uma ferramenta essencial para a gestão inteligente de cidades, promovendo análises preditivas que auxiliam na alocação de recursos e na organização de fluxos logísticos. A utilização de plataformas interoperáveis e o avanço dos sistemas de *digital twin* consolidam a transição para uma abordagem de planejamento urbano orientada por evidências (Baalrsud Hauge e Jeong, 2024).

Observa-se que o avanço contínuo da simulação na Engenharia de Produção e na logística urbana tem impulsionado uma nova forma de gestão baseada em dados e experimentação virtual. Os estudos recentes destacam que a integração entre diferentes metodologias de modelagem, como eventos discretos e agentes autônomos, amplia a precisão e a aplicabilidade das análises. Essa tendência reflete a consolidação da simulação como elemento central para o desenvolvimento sustentável e tecnológico das operações urbanas (Goodwin *et al.*, 2023).

2.2 Modelos de localização e alocação de serviços públicos

Os modelos de localização e alocação de serviços públicos representam um campo essencial de estudo dentro da Engenharia de Produção e da logística urbana, pois tratam de definir o posicionamento ideal de infraestruturas e recursos de modo a maximizar a eficiência e minimizar custos. Esses modelos têm origem na teoria da localização industrial e evoluíram para abranger problemas de natureza social, ambiental e administrativa, permitindo a alocação estratégica de bases operacionais, centros de serviço e instalações públicas. A aplicação desses métodos auxilia gestores na tomada de decisão sobre onde posicionar unidades de atendimento, considerando acessibilidade, demanda e restrições orçamentárias (Rabe *et al.*, 2020).

A formulação matemática dos modelos de localização busca encontrar o ponto ótimo que minimize a distância média entre os usuários e os serviços oferecidos. Esse princípio, denominado minimização do custo de deslocamento, é amplamente utilizado na definição de locais para hospitais, escolas, delegacias e bases operacionais. A abordagem tradicional envolve o uso de funções objetivo lineares e não lineares, sujeitas a restrições geográficas e de capacidade, cuja solução pode ser alcançada por métodos exatos ou heurísticos. Esses modelos tornaram-se instrumentos indispensáveis para planejar infraestruturas urbanas mais eficientes e sustentáveis (Deineko *et al.*, 2025).

A evolução das técnicas de modelagem trouxe consigo novas possibilidades, com destaque para as heurísticas e metaheurísticas, que oferecem soluções aproximadas em tempo computacional reduzido. Métodos como algoritmos genéticos, *simulated annealing* e busca tabu têm sido amplamente aplicados para resolver problemas complexos de localização e alocação, especialmente em sistemas de grande escala. Essas técnicas são particularmente úteis quando o espaço de soluções é extenso e as variáveis envolvidas apresentam comportamentos não lineares, permitindo análises mais realistas em comparação aos métodos puramente analíticos (Camargo, 2022).

Além da eficiência computacional, a aplicabilidade dos modelos de localização depende da qualidade dos dados e das variáveis incluídas. Entre os parâmetros comumente considerados estão densidade populacional, tempo de resposta, fluxo de tráfego e distância média de atendimento. A combinação desses elementos permite projetar redes de serviços públicos que sejam economicamente viáveis e socialmente justas. A incorporação de dados georreferenciados e de sistemas de informação geográfica (SIG) tem aprimorado significativamente a precisão das análises e a visualização dos resultados (Rabe *et al.*, 2020).

Na logística urbana, os modelos de localização e alocação desempenham papel estratégico na distribuição de serviços e produtos. A definição de pontos de coleta, centros de distribuição e bases de operação é fundamental para reduzir tempos de deslocamento e custos de transporte. Esses modelos são aplicados não apenas em contextos industriais, mas também em políticas públicas, como o posicionamento de bases policiais e unidades de emergência. Em tais casos, a eficiência logística está diretamente associada à capacidade de resposta às demandas da população, exigindo abordagens que conciliem eficiência operacional e equidade social (Lima, Nepomuceno e Turet, 2025).

Os modelos de localização também podem ser classificados conforme sua estrutura matemática e o tipo de decisão envolvida. Entre os principais estão o *p-median problem*, que busca minimizar as distâncias médias de atendimento; o *set covering problem*, que visa garantir cobertura total do território; e o *maximal covering location problem*, cujo objetivo é maximizar o número de usuários atendidos dentro de um raio predefinido. Esses modelos têm sido amplamente empregados em estudos urbanos e logísticos, fornecendo resultados consistentes que orientam políticas públicas e investimentos em infraestrutura (Deineko *et al.*, 2025).

Um aspecto central na formulação desses modelos é a definição das restrições que limitam o número de instalações e os recursos disponíveis. O balanceamento entre custo de instalação e eficiência do atendimento constitui o principal desafio para gestores públicos. Nesse sentido, abordagens baseadas em programação linear inteira mista e em métodos heurísticos híbridos têm demonstrado elevada eficiência na solução de problemas complexos. Esses métodos permitem equilibrar precisão e tempo de execução, tornando-se ferramentas viáveis para a análise operacional de sistemas urbanos (Camargo, 2022).

A abordagem de otimização multiobjetivo vem ganhando destaque por permitir a consideração simultânea de múltiplos critérios de decisão, como custo, tempo, equidade e sustentabilidade. Essa perspectiva é essencial para a formulação de políticas públicas mais abrangentes, que considerem não apenas a eficiência técnica, mas também os impactos sociais e ambientais das decisões locacionais. A aplicação de algoritmos de Pareto e técnicas de

fronteira eficiente contribui para identificar soluções que atendam simultaneamente a diferentes metas de desempenho (El Yaagoubi *et al.*, 2023).

A integração entre modelos matemáticos e simulação computacional fortalece as análises locais ao permitir a validação dos resultados sob condições dinâmicas. Em vez de limitar-se a soluções estáticas, os modelos híbridos incorporam variações temporais e comportamentais, refletindo a natureza mutável dos sistemas urbanos. Essa combinação torna possível testar diferentes cenários de tráfego, crescimento populacional e demanda de serviços, ampliando a aplicabilidade dos resultados à realidade das cidades contemporâneas (Rabe *et al.*, 2020).

Os modelos de alocação são complementares aos de localização, pois tratam da distribuição ótima dos recursos disponíveis entre as unidades instaladas. Essa etapa é crucial para garantir que as instalações previamente posicionadas operem de forma eficiente e equilibrada. A alocação envolve decisões sobre quantidade de pessoal, veículos, equipamentos e materiais, de modo a evitar sobrecargas e subutilizações. Assim, a análise conjunta de localização e alocação cria uma estrutura integrada de planejamento e gestão operacional (Liu, Li e Wang, 2025).

Na prática, a implementação de modelos de localização e alocação de serviços públicos requer dados atualizados e ferramentas analíticas adequadas. O uso de sistemas de apoio à decisão, integrados a bancos de dados espaciais, possibilita a automação de cálculos e a visualização interativa dos resultados. Essa evolução tecnológica tem reduzido barreiras de aplicação e ampliado o alcance dos modelos a gestores municipais e instituições acadêmicas, consolidando sua importância no planejamento urbano (Lima, Nepomuceno e Turet, 2025).

As aplicações contemporâneas desses modelos abrangem desde o planejamento de infraestruturas viárias até a gestão de emergências. Em operações de segurança pública, por exemplo, o posicionamento de bases operacionais pode ser otimizado para reduzir o tempo de resposta em áreas críticas. No setor da saúde, modelos semelhantes são usados para definir locais de ambulâncias e unidades de pronto atendimento, maximizando a cobertura e a eficiência dos serviços (Deineko *et al.*, 2025).

O avanço recente na utilização de heurísticas reforça a flexibilidade dos modelos de localização. Métodos como busca por colônia de formigas, *particle swarm optimization* e algoritmos de aprendizado profundo estão sendo aplicados para resolver problemas de localização complexos, com grandes volumes de dados e múltiplos objetivos. Essas técnicas oferecem soluções aproximadas de alta qualidade e podem ser adaptadas a diferentes contextos

urbanos e produtivos, demonstrando a versatilidade da Engenharia de Produção na abordagem de problemas reais (El Yaagoubi *et al.*, 2023).

A análise de localização também pode incorporar aspectos de sustentabilidade e justiça espacial. Modelos de equidade visam assegurar que a distribuição de serviços públicos ocorra de forma proporcional à demanda, evitando a concentração em áreas privilegiadas. Esse tipo de abordagem é particularmente importante em cidades com desigualdades socioespaciais marcantes, nas quais a distância física pode representar uma barreira de acesso. Assim, a modelagem locacional torna-se instrumento de planejamento inclusivo, promovendo maior equilíbrio territorial (Van Vliet *et al.*, 2025).

No campo acadêmico, estudos recentes têm explorado a combinação entre heurísticas e aprendizado de máquina para aperfeiçoar modelos de localização. Essa integração permite identificar padrões de demanda e ajustar parâmetros de decisão em tempo real. Conforme observado por Liu, Li e Wang (2025), a utilização de redes neurais e técnicas de análise preditiva potencializa a capacidade dos modelos de antecipar variações na procura e propor redistribuições de recursos mais precisas.

As aplicações de modelos locais em universidades e instituições de grande porte têm se expandido como resposta à necessidade de gestão eficiente de espaços e serviços. Em contextos de alta densidade, como campi universitários, o posicionamento adequado de bases de transporte, manutenção e segurança é fundamental para reduzir deslocamentos e otimizar o uso de recursos. A modelagem locacional permite projetar layouts mais eficientes e sustentáveis, integrando aspectos operacionais e ambientais (Lima, Nepomuceno e Turet, 2025).

A análise espacial dos modelos de localização também oferece suporte à elaboração de políticas públicas voltadas ao transporte coletivo e à logística de última milha. Estudos recentes demonstram que a combinação entre dados de mobilidade e algoritmos de otimização contribui para o desenvolvimento de sistemas de transporte mais eficientes e acessíveis. Essa integração tecnológica permite a formulação de políticas orientadas por evidências, aumentando a precisão das intervenções urbanas (Van Vliet *et al.*, 2025).

Em contextos urbanos dinâmicos, a natureza estocástica das variáveis de tráfego e demanda requer o uso de modelos probabilísticos. Essa abordagem permite lidar com a incerteza inerente ao comportamento humano e às variações temporais. Modelos probabilísticos incorporam distribuições de probabilidade nos parâmetros de entrada, proporcionando maior realismo às simulações e decisões locais. Essa característica é essencial para sistemas de

transporte e serviços de emergência, nos quais a imprevisibilidade é constante (Deineko *et al.*, 2025).

A aplicabilidade dos modelos de localização e alocação também está relacionada à capacidade de integração com outras ferramentas analíticas, como a simulação e o *digital twin*. A combinação dessas metodologias gera ambientes virtuais que permitem testar políticas de realocação e verificar seus efeitos antes da implementação prática. Essa integração reforça a perspectiva sistêmica da Engenharia de Produção, aproximando o planejamento estratégico da execução operacional (Camargo, 2022).

A abordagem multicritério é outro avanço relevante, pois permite que diferentes dimensões da decisão — econômicas, sociais e ambientais — sejam ponderadas de forma equilibrada. Técnicas como o *Analytic Hierarchy Process* (AHP) e o *Technique for Order Preference by Similarity to Ideal Solution* (TOPSIS) têm sido incorporadas aos modelos de localização para apoiar decisões complexas e transparentes. Esses métodos favorecem a participação de diferentes agentes no processo decisório, fortalecendo a governança das políticas públicas (El Yaagoubi *et al.*, 2023).

O futuro dos modelos de localização e alocação de serviços públicos tende a ser marcado pela integração de dados em tempo real e pelo uso de sistemas inteligentes de apoio à decisão. A coleta contínua de informações por meio de sensores e plataformas digitais permitirá atualizações instantâneas dos modelos, ajustando-os conforme as variações de demanda e condições operacionais. Essa evolução aponta para um planejamento urbano mais dinâmico, adaptativo e sustentado por evidências (Liu, Li e Wang, 2025).

A adoção crescente dessas ferramentas no setor público reflete uma mudança cultural na gestão das cidades. O planejamento baseado em modelos matemáticos e heurísticos substitui práticas intuitivas e fragmentadas, fortalecendo a racionalidade técnica das decisões administrativas. Essa transformação, ancorada na Engenharia de Produção, contribui para a criação de cidades mais organizadas, equitativas e sustentáveis (Lima, Nepomuceno e Turet, 2025).

2.3 Aplicação do *digital twin* em ambientes urbanos

O conceito de *digital twin* (gêmeo digital) representa uma das inovações mais significativas na transformação das cidades em ecossistemas inteligentes. Trata-se de uma réplica virtual de um sistema físico, construída com base em dados reais, capaz de simular o comportamento, prever falhas e otimizar o desempenho de infraestruturas urbanas. Essa

tecnologia permite criar modelos digitais dinâmicos que interagem continuamente com o ambiente real, processando informações em tempo real por meio de sensores e plataformas conectadas, o que possibilita um gerenciamento mais eficiente dos serviços públicos e da infraestrutura urbana (Ferré-Bigorra, Casals e Gangolells, 2022).

A aplicação do *digital twin* em cidades inteligentes decorre da evolução da Internet das Coisas (IoT) e da integração entre sistemas cibernéticos e físicos. Essa convergência tecnológica cria uma representação digital fiel do ambiente urbano, facilitando o monitoramento, o planejamento e a execução de políticas públicas. A principal vantagem do uso dessa abordagem é a capacidade de antecipar problemas antes que eles ocorram, permitindo ações preventivas em áreas como mobilidade, energia e saneamento. A modelagem baseada em gêmeos digitais transforma dados dispersos em informações estratégicas que auxiliam a tomada de decisão (Huang, Zhang e Zeng, 2022).

O conceito de *digital twin* foi inicialmente aplicado na indústria manufatureira, com o propósito de otimizar a produção e o ciclo de vida dos produtos. Nos últimos anos, essa tecnologia passou a ser utilizada na gestão de cidades, possibilitando a criação de plataformas digitais que representam sistemas urbanos complexos. Por meio dessas plataformas, gestores podem visualizar o comportamento de redes de transporte, fluxos de energia e padrões de ocupação territorial em tempo real. Essa perspectiva amplia a capacidade analítica das administrações públicas e promove maior eficiência na utilização de recursos (Bariah, Sari e Debbah, 2022).

Um dos diferenciais do gêmeo digital é a integração entre dados geoespaciais, sensores de campo e algoritmos preditivos. Essa combinação cria um sistema autônomo de aprendizado contínuo, capaz de identificar padrões e ajustar-se a mudanças no ambiente. No contexto da mobilidade urbana, por exemplo, o *digital twin* pode simular diferentes fluxos de tráfego, avaliando o impacto de obras, acidentes ou políticas de restrição veicular antes de sua implementação. Essa abordagem reduz custos, evita interrupções desnecessárias e otimiza o desempenho operacional (Shirowzhan, Tan e Sepasgozar, 2020).

A utilização de gêmeos digitais em sistemas de transporte urbano contribui para a criação de cidades mais seguras e eficientes. A simulação em tempo real permite monitorar o trânsito, prever congestionamentos e redirecionar fluxos de forma automática, considerando fatores como demanda, velocidade média e capacidade viária. O cruzamento de dados históricos com informações captadas por sensores e câmeras facilita o planejamento de rotas alternativas e a priorização de transportes coletivos e de emergência (Ford e Wolf, 2020).

Além da mobilidade, o *digital twin* tem sido amplamente utilizado na gestão de energia urbana. Os modelos digitais permitem simular o consumo energético de bairros inteiros, identificar pontos de desperdício e testar cenários de eficiência baseados em fontes renováveis. Essa integração entre dados energéticos e ambientais fortalece a transição para cidades mais sustentáveis. Sistemas que utilizam inteligência artificial para otimizar o uso de energia elétrica em tempo real, com base em dados do gêmeo digital, demonstram redução significativa nos custos operacionais e nas emissões de carbono (Huang, Zhang e Zeng, 2022).

A aplicação do gêmeo digital também se estende à infraestrutura subterrânea, tradicionalmente difícil de monitorar e gerenciar. Modelos tridimensionais de túneis, redes hidráulicas e sistemas elétricos, quando associados ao *digital twin*, permitem prever falhas e planejar manutenções com precisão. Essa capacidade de antecipação é essencial para reduzir interrupções e custos relacionados à infraestrutura urbana, especialmente em áreas de alta densidade populacional (Babanagar *et al.*, 2025).

Nos últimos anos, observa-se uma tendência crescente de adoção de *digital twins* integrados a sistemas de comunicação sem fio e redes 5G. Essa combinação viabiliza a transmissão contínua de dados em alta velocidade, aumentando a capacidade de resposta dos sistemas urbanos inteligentes. As cidades que adotam essa abordagem criam um ecossistema digital interconectado, em que o ambiente físico e o virtual operam de forma sinérgica, permitindo o gerenciamento em tempo real de serviços essenciais como iluminação, tráfego e saneamento (Bariah, Sari e Debbah, 2022).

O *digital twin* também é aplicado na modelagem de edificações inteligentes e sistemas de monitoramento ambiental. Essa tecnologia possibilita avaliar o desempenho estrutural de edifícios, prever desgaste de materiais e otimizar o uso de recursos hídricos e energéticos. Em ambientes urbanos, os modelos digitais de edificações integram-se ao contexto da cidade inteligente, oferecendo informações essenciais para o planejamento urbano sustentável e a redução de impactos ambientais (Ferré-Bigorra, Casals e Gangolells, 2022).

A consolidação dos gêmeos digitais em contextos urbanos demanda uma arquitetura tecnológica baseada na interoperabilidade entre sistemas. Para que o modelo digital funcione de forma eficaz, é necessário que diferentes plataformas possam trocar dados em tempo real, sem perdas de informação. Essa interconexão depende da padronização de protocolos e da integração de bases de dados públicas e privadas, o que exige planejamento institucional e políticas de governança digital bem estruturadas (Petrova-Antonova e Ilieva, 2020).

A incorporação de *digital twins* na administração pública representa uma oportunidade para a modernização da gestão urbana. Esses sistemas permitem visualizar o impacto das

decisões antes de sua implementação, facilitando a avaliação de políticas e investimentos. Em setores como habitação, saneamento e segurança pública, o gêmeo digital atua como um laboratório virtual que reduz riscos e otimiza o uso dos recursos públicos. Essa aplicação reforça a importância de políticas integradas de inovação e tecnologia no contexto municipal (Mulpuru, Bhattacharya e Barat, 2025).

Os gêmeos digitais também desempenham papel relevante na mitigação de desastres naturais e no gerenciamento de crises. Por meio da simulação em tempo real, é possível prever o comportamento de eventos como inundações, incêndios e falhas elétricas, permitindo respostas mais rápidas e coordenadas. A integração entre sensores, sistemas de previsão climática e plataformas digitais fortalece a resiliência das cidades, tornando-as mais preparadas para lidar com emergências (Ford e Wolf, 2020).

Outra aplicação relevante é o uso do *digital twin* na criação de ambientes urbanos voltados à inclusão e ao bem-estar. Modelos digitais de bairros e espaços públicos têm sido utilizados para planejar infraestruturas acessíveis e adaptadas às necessidades de populações vulneráveis, como idosos e pessoas com deficiência. Essas aplicações demonstram o potencial da tecnologia para promover a equidade urbana e melhorar a qualidade de vida da população (Villanueva-Merino *et al.*, 2024).

A integração entre *digital twin* e inteligência artificial amplia a capacidade de análise e previsão dos sistemas urbanos. Algoritmos de aprendizado de máquina processam grandes volumes de dados provenientes de sensores e dispositivos conectados, identificando padrões que indicam falhas, gargalos ou oportunidades de melhoria. Essa combinação cria um ciclo de aprendizado contínuo, em que o gêmeo digital se torna cada vez mais preciso e adaptável às condições do ambiente (Wang *et al.*, 2024).

A interoperabilidade entre diferentes camadas do *digital twin* é um desafio recorrente nas aplicações urbanas. A necessidade de unificar dados de transporte, energia, meio ambiente e infraestrutura demanda soluções de arquitetura digital flexíveis. Iniciativas que adotam modelos abertos de dados e padronização de interfaces vêm obtendo avanços significativos na criação de plataformas integradas, promovendo maior colaboração entre os setores público e privado (Jeddoúb *et al.*, 2023).

Além de promover eficiência, os gêmeos digitais contribuem para a transparência e a governança participativa. A disponibilização de modelos urbanos digitais acessíveis ao público permite que cidadãos e pesquisadores visualizem dados em tempo real, participando de decisões sobre planejamento e gestão. Essa abertura estimula a corresponsabilidade e fortalece o

engajamento social na construção de cidades mais inteligentes e sustentáveis (Peldon *et al.*, 2024).

Os gêmeos digitais também encontram aplicações relevantes em sistemas de saúde pública urbana. Modelos digitais de hospitais e redes de atendimento permitem simular fluxos de pacientes, otimizar o uso de leitos e prever demandas em situações de emergência. Essa capacidade de antecipação é crucial para garantir o funcionamento eficiente dos serviços de saúde e reduzir o tempo de resposta em casos críticos (Laamarti *et al.*, 2020).

O *digital twin* é igualmente promissor para o setor agrícola urbano e periurbano, especialmente no contexto das cidades que buscam segurança alimentar. Modelos digitais de cultivo monitoram variáveis como temperatura, umidade e nutrientes do solo, ajustando automaticamente as condições para maximizar a produtividade. Essa integração entre natureza e tecnologia reforça o conceito de cidades inteligentes resilientes e sustentáveis (Mohapatra *et al.*, 2025).

A implementação do *digital twin* exige uma infraestrutura de dados robusta e políticas de segurança cibernética adequadas. O armazenamento e a manipulação de grandes volumes de informações sensíveis tornam a proteção dos sistemas um fator determinante para seu sucesso. Estratégias de criptografia, autenticação e controle de acesso são essenciais para evitar vulnerabilidades e garantir a integridade dos dados. Essa preocupação cresce à medida que os gêmeos digitais se tornam parte essencial da infraestrutura urbana (Shafik, 2025).

O potencial do gêmeo digital para transformar a forma como as cidades são planejadas e administradas está diretamente relacionado à sua capacidade de aprendizado contínuo. A cada ciclo de coleta e análise de dados, o modelo se torna mais preciso, refletindo com fidelidade o comportamento real da cidade. Essa característica torna possível testar políticas públicas, prever impactos ambientais e aprimorar processos de governança, promovendo uma gestão urbana baseada em evidências (Ferré-Bigorra, Casals e Gangolells, 2022).

Os gêmeos digitais aplicados à gestão de recursos naturais e infraestrutura hídrica possibilitam monitoramento detalhado e previsão de falhas. Ao modelar sistemas de distribuição de água e saneamento, as administrações conseguem identificar vazamentos, ajustar pressões e otimizar o consumo. Essa abordagem contribui para a conservação dos recursos e a redução de custos, alinhando-se aos objetivos de desenvolvimento sustentável propostos para as cidades inteligentes (Huang, Zhang e Zeng, 2022).

A utilização de *digital twins* em projetos urbanos também promove a integração entre planejamento e execução de obras. Modelos digitais de infraestrutura permitem simular todo o ciclo de vida de um projeto, desde o planejamento até a manutenção, garantindo maior controle

sobre prazos e orçamentos. Essa metodologia, conhecida como *Building Information Modeling* (BIM), quando associada ao *digital twin*, amplia o nível de detalhamento e a precisão das análises, proporcionando uma visão holística do ambiente urbano (Petrova-Antonova e Ilieva, 2020).

O *digital twin* redefine a forma como as cidades são compreendidas e geridas. Sua capacidade de integrar, simular e prever torna essa tecnologia um elemento-chave para o desenvolvimento de cidades inteligentes, resilientes e sustentáveis. As aplicações vão desde a gestão do tráfego e energia até o planejamento social e ambiental, transformando dados em conhecimento estratégico. À medida que os sistemas digitais se tornam mais interconectados e inteligentes, o gêmeo digital consolida-se como uma das ferramentas mais promissoras para o futuro da gestão urbana (Villanueva-Merino *et al.*, 2024).

2.4 Avaliação de desempenho e eficiência operacional

A avaliação de desempenho e eficiência operacional constitui um dos pilares da Engenharia de Produção e da gestão urbana moderna, uma vez que fornece as bases quantitativas e qualitativas para a tomada de decisão e o aprimoramento contínuo de processos. A mensuração de desempenho envolve a definição de métricas e indicadores que refletem o grau de atingimento dos objetivos organizacionais e operacionais. No contexto urbano, essa análise é indispensável para o gerenciamento de serviços públicos, transporte, energia e logística, enquanto, no ambiente produtivo, orienta o uso racional de recursos e a melhoria da qualidade e produtividade (Santos *et al.*, 2020).

A eficiência operacional pode ser compreendida como a relação entre os resultados obtidos e os recursos empregados para alcançá-los. Trata-se de um conceito que ultrapassa a simples produtividade, abrangendo a capacidade de realizar atividades de forma sustentável e integrada. Em sistemas urbanos e produtivos, essa eficiência está diretamente associada à redução de desperdícios, à otimização do tempo de resposta e ao aumento da confiabilidade das operações. O desafio consiste em construir modelos de avaliação que sejam capazes de capturar a complexidade e a variabilidade das atividades envolvidas (Vieira e Santos, 2025).

A utilização de métricas e indicadores de desempenho é essencial para traduzir os resultados operacionais em informações gerenciais. Esses indicadores podem ser classificados em categorias como eficiência técnica, eficácia, qualidade, flexibilidade e sustentabilidade. No ambiente urbano, incluem variáveis como tempo médio de atendimento, taxa de cobertura de serviços, nível de satisfação do usuário e custo operacional. Já na Engenharia de Produção,

envolvem indicadores de rendimento, disponibilidade de máquinas, produtividade de mão de obra e perdas energéticas (Hijry, 2024).

Entre as metodologias mais empregadas na mensuração de desempenho destaca-se a *Data Envelopment Analysis* (DEA), uma técnica que permite avaliar a eficiência relativa de unidades produtivas ou de serviço com base em múltiplas entradas e saídas. Essa abordagem possibilita comparar o desempenho entre diferentes organizações ou departamentos, identificando quais operam na fronteira de eficiência e quais necessitam de ajustes. A DEA tem sido amplamente utilizada em estudos de logística, saúde, educação e transporte, consolidando-se como ferramenta de gestão pública e empresarial (Vieira e Santos, 2025).

A integração de modelos de simulação e indicadores de desempenho potencializa a capacidade analítica das organizações. A simulação fornece dados dinâmicos sobre o comportamento dos sistemas, enquanto os indicadores traduzem esses dados em métricas objetivas de eficiência. Essa combinação permite prever resultados, testar alternativas e quantificar os impactos de decisões estratégicas antes de sua implementação. A aplicação conjunta dessas ferramentas promove uma cultura de decisão orientada por evidências e baseada em dados empíricos (Santos *et al.*, 2020).

Em ambientes urbanos inteligentes, a avaliação de desempenho se apoia cada vez mais em dados coletados por sensores, sistemas de Internet das Coisas (IoT) e plataformas digitais. Esses dispositivos permitem monitorar em tempo real o funcionamento de infraestruturas como redes de transporte, iluminação pública e abastecimento de água. O uso de algoritmos analíticos sobre esses dados viabiliza a construção de indicadores automáticos que apontam falhas, gargalos e oportunidades de melhoria, fortalecendo a gestão baseada em evidências (Hijry, 2024).

A transformação digital trouxe consigo novos paradigmas para a avaliação de desempenho, impulsionando o surgimento de métricas preditivas e adaptativas. Diferentemente das métricas tradicionais, que refletem o passado, as métricas inteligentes baseiam-se em aprendizado de máquina e modelagem preditiva para antecipar variações no desempenho. Essa abordagem tem sido utilizada para ajustar automaticamente processos produtivos, otimizar rotas logísticas e redistribuir recursos urbanos conforme padrões de demanda emergentes (Lan *et al.*, 2025).

A aplicação da inteligência artificial (IA) e do *machine learning* nos processos de avaliação operacional possibilita uma análise mais precisa e dinâmica dos sistemas. Por meio da coleta e tratamento contínuo de dados, essas tecnologias conseguem identificar correlações complexas entre variáveis e gerar indicadores mais sensíveis às mudanças do ambiente. Essa

capacidade analítica aprimorada é especialmente útil em contextos urbanos, onde as condições de tráfego, clima e comportamento populacional sofrem variações constantes (Xu *et al.*, 2025).

A análise de eficiência em sistemas urbanos requer uma visão integrada dos fatores que influenciam o desempenho operacional. Elementos como infraestrutura, tecnologia, gestão e comportamento dos usuários devem ser avaliados em conjunto para evitar conclusões parciais. Modelos híbridos de análise — que combinam dados históricos, simulações e previsões — vêm se consolidando como instrumentos mais eficazes para mensurar e aprimorar a eficiência dos serviços públicos e das operações logísticas (Santos *et al.*, 2020).

Em ambientes produtivos, a eficiência é frequentemente avaliada por meio do indicador OEE (*Overall Equipment Effectiveness*), que mede a eficácia global dos equipamentos. Esse índice considera três dimensões principais: disponibilidade, desempenho e qualidade. A aplicação do OEE permite identificar perdas ocultas e medir a utilização real dos ativos, orientando ações corretivas e preventivas. Essa métrica, amplamente difundida na manufatura, tem sido adaptada também para operações urbanas, como sistemas de transporte e infraestrutura energética (Lan *et al.*, 2025).

A eficiência operacional não se limita ao desempenho técnico das operações, mas inclui também aspectos relacionados à governança e à gestão de recursos humanos. A motivação das equipes, a clareza dos processos e a coordenação entre setores são variáveis determinantes para o alcance de bons resultados. A literatura recente enfatiza a importância de indicadores qualitativos, como clima organizacional e engajamento, que complementam as métricas quantitativas tradicionais, oferecendo uma visão mais completa da performance institucional (Vieira e Santos, 2025).

A aplicação de sistemas de avaliação contínua tem permitido que as organizações públicas e privadas adotem ciclos de melhoria baseados em feedback. Esse processo, conhecido como *continuous performance monitoring*, utiliza dados em tempo real para identificar desvios e implementar ajustes imediatos. Em cidades inteligentes, essa metodologia é essencial para garantir que serviços como transporte, saneamento e segurança funcionem de forma estável e previsível. A capacidade de resposta rápida aumenta a resiliência das operações e reduz os impactos de falhas (Hijry, 2024).

A análise comparativa de desempenho, ou *benchmarking*, é uma prática consolidada que busca identificar as melhores práticas entre diferentes unidades operacionais. Essa técnica consiste em comparar indicadores de desempenho e identificar fatores de sucesso que possam ser replicados. Em sistemas urbanos, o *benchmarking* auxilia na definição de metas realistas e

na priorização de investimentos, enquanto em ambientes produtivos promove a padronização de processos e o compartilhamento de inovações (Santos *et al.*, 2020).

Modelos baseados em *digital twin* também têm sido utilizados para medir o desempenho operacional em ambientes urbanos. Esses modelos criam réplicas digitais de sistemas reais e permitem testar o impacto de alterações estruturais antes de sua execução prática. No contexto de transporte, energia e saneamento, os gêmeos digitais possibilitam a identificação de gargalos operacionais e a avaliação de indicadores de desempenho sob diferentes condições, aumentando a precisão das decisões de planejamento (Hijry, 2024).

A integração de indicadores de sustentabilidade à avaliação de desempenho é uma tendência que reflete a crescente preocupação com os impactos ambientais e sociais das operações. Indicadores de emissões de carbono, eficiência energética e uso racional de recursos naturais têm sido incorporados aos sistemas de mensuração, proporcionando uma visão mais abrangente da eficiência. Essa abordagem é fundamental para alinhar as estratégias operacionais aos objetivos globais de desenvolvimento sustentável (Lan *et al.*, 2025).

A avaliação de desempenho também envolve desafios relacionados à coleta e confiabilidade dos dados. Em sistemas complexos, a heterogeneidade das fontes e a variabilidade dos registros podem comprometer a consistência das análises. Para superar essas limitações, recomenda-se a adoção de protocolos padronizados de medição e o uso de tecnologias de armazenamento distribuído, como *blockchain*, que garantem a integridade e a rastreabilidade das informações utilizadas nas avaliações (Xu *et al.*, 2025).

No setor público, a mensuração da eficiência deve considerar não apenas o custo-benefício, mas também o impacto social das políticas implementadas. Indicadores como acessibilidade, equidade e satisfação do cidadão complementam os índices de desempenho técnico e financeiro. Essa perspectiva reforça o princípio de que eficiência não se resume à redução de custos, mas envolve também a entrega de valor público de maneira transparente e sustentável (Vieira e Santos, 2025).

A análise de desempenho em redes logísticas urbanas é particularmente desafiadora devido à multiplicidade de atores e às variáveis externas que afetam o sistema. Modelos baseados em inteligência artificial e *big data* têm sido utilizados para captar essas complexas inter-relações, permitindo o cálculo de métricas de desempenho mais precisas. Esses modelos auxiliam na identificação de pontos de congestão, falhas de sincronização e oportunidades de otimização de rotas e recursos (Xu *et al.*, 2025).

Em contextos industriais e urbanos, a integração entre indicadores operacionais e estratégicos constitui um diferencial competitivo. A utilização de *dashboards* interativos e

sistemas de visualização de dados facilita o acompanhamento do desempenho em múltiplos níveis hierárquicos. Essas plataformas permitem que gestores visualizem, em tempo real, o desempenho global e o desempenho de subsistemas, favorecendo uma gestão mais ágil e orientada a resultados (Lan *et al.*, 2025).

A introdução de modelos de aprendizado profundo nas análises de eficiência operacional representa um avanço significativo. Esses algoritmos conseguem identificar padrões ocultos nos dados e prever falhas antes que elas ocorram, aumentando a confiabilidade dos sistemas. A aplicação dessas técnicas em operações urbanas e industriais tem resultado em reduções expressivas de custos e aumento da disponibilidade de equipamentos e serviços (Xu *et al.*, 2025).

A avaliação de desempenho e eficiência operacional é um processo dinâmico que deve evoluir continuamente para acompanhar as transformações tecnológicas e organizacionais. A integração entre inteligência artificial, simulação, *digital twins* e indicadores de sustentabilidade redefine os parâmetros de mensuração e controle. A eficiência passa a ser compreendida não apenas como produtividade, mas como capacidade adaptativa, inovação e geração de valor público e social. Essa perspectiva consolida a avaliação de desempenho como instrumento essencial para o desenvolvimento urbano e produtivo (Santos *et al.*, 2020).

2.5 Otimização de fluxos e tomada de decisão baseada em simulação

A otimização de fluxos e a tomada de decisão baseada em simulação constituem abordagens fundamentais na Engenharia de Produção e na logística urbana contemporânea. Essas técnicas permitem modelar sistemas complexos, testar estratégias alternativas e identificar soluções que maximizem a eficiência operacional e o uso racional de recursos. A combinação entre simulação e métodos de otimização tem transformado a forma como gestores e planejadores compreendem e intervêm em sistemas produtivos e urbanos, integrando tecnologia, análise de dados e inteligência artificial para fundamentar decisões precisas e sustentáveis (Camargo, 2022).

A otimização de fluxos refere-se ao processo de identificar a melhor configuração possível para o movimento de materiais, informações ou pessoas dentro de um sistema. Em ambientes urbanos e produtivos, isso envolve o planejamento de rotas, o balanceamento de carga e a minimização de custos de transporte e tempo de operação. Quando associada à simulação, essa técnica ganha uma dimensão dinâmica, permitindo que os modelos considerem

variáveis reais, como congestionamentos, falhas e flutuações de demanda. Essa integração amplia a capacidade preditiva e estratégica das decisões (Moreno *et al.*, 2025).

Os modelos de simulação atuam como laboratórios virtuais que reproduzem o comportamento de sistemas reais sob diferentes condições operacionais. Essa característica torna possível avaliar o impacto de decisões antes de sua implementação prática, reduzindo riscos e custos. Na tomada de decisão, a simulação auxilia na escolha de alternativas que atendam a múltiplos objetivos, como eficiência econômica, sustentabilidade e qualidade de serviço. Dessa forma, os tomadores de decisão dispõem de um instrumento que combina experimentação virtual com análise quantitativa de resultados (Santos *et al.*, 2021).

A otimização multiobjetivo tem assumido papel central no planejamento de operações complexas, pois permite equilibrar metas potencialmente conflitantes. Diferentemente da otimização tradicional, que busca uma única solução ótima, a abordagem multiobjetivo procura identificar um conjunto de soluções de Pareto — aquelas que não podem ser melhoradas em um critério sem piorar outro. Essa técnica é particularmente útil em contextos urbanos, onde eficiência, custo e impacto ambiental precisam ser conciliados em decisões de infraestrutura e mobilidade (Camargo, 2022).

Os métodos heurísticos e metaheurísticos, como algoritmos genéticos, enxame de partículas e busca tabu, têm se mostrado eficazes para resolver problemas de otimização de fluxos com múltiplos objetivos. Esses algoritmos inspiram-se em processos naturais e sociais para explorar vastos espaços de solução, encontrando alternativas próximas ao ótimo global. Quando combinados com a simulação, permitem testar milhares de cenários em tempo reduzido, o que potencializa a capacidade de adaptação dos modelos a ambientes urbanos dinâmicos e incertos (Goodwin *et al.*, 2023).

A tomada de decisão baseada em simulação depende fortemente da qualidade dos dados e da representação realista do sistema. Modelos bem calibrados utilizam dados históricos e em tempo real para ajustar parâmetros e validar resultados. A integração entre plataformas de simulação e sistemas de informação, como *Enterprise Resource Planning* (ERP) e *Geographic Information Systems* (GIS), viabiliza uma análise abrangente que combina aspectos operacionais, espaciais e estratégicos. Essa sinergia permite uma visão sistêmica do fluxo de operações e apoia decisões com base em evidências (Moreno *et al.*, 2025).

O avanço da inteligência artificial (IA) trouxe novas possibilidades para a otimização de fluxos e a tomada de decisão em ambientes simulados. A IA é capaz de aprender padrões complexos a partir de grandes volumes de dados, ajustar parâmetros automaticamente e propor soluções adaptativas. Essa característica é essencial em sistemas urbanos, onde a variabilidade

é alta e as condições mudam em tempo real. Técnicas como *deep learning* e *reinforcement learning* são amplamente aplicadas para prever demandas, ajustar fluxos e otimizar o uso de recursos (Lan *et al.*, 2025).

O uso de *reinforcement learning* (aprendizado por reforço) tem se destacado por permitir que os sistemas de simulação aprendam com a experiência, sem depender de modelos analíticos pré-definidos. O algoritmo interage com o ambiente virtual, testando diferentes ações e aprendendo quais geram melhores resultados de desempenho. Essa abordagem é especialmente útil para o controle de tráfego, o gerenciamento de estoques e o roteamento de veículos, pois possibilita o aperfeiçoamento contínuo das decisões a partir do feedback dos próprios sistemas (Goodwin *et al.*, 2023).

A otimização de fluxos em contextos urbanos requer a consideração simultânea de múltiplas dimensões — espacial, temporal e operacional. A combinação entre simulação e IA permite capturar a interação entre essas dimensões, viabilizando decisões mais eficientes e flexíveis. Por exemplo, em redes de transporte público, os modelos podem analisar o efeito de novas linhas, intervalos de operação e variações de demanda, ajustando o planejamento de acordo com a realidade observada. Essa abordagem orientada a dados reforça a racionalidade técnica e a sustentabilidade das políticas públicas (Almeida *et al.*, 2023).

As técnicas de apoio à decisão baseadas em simulação e otimização multiobjetivo também têm sido aplicadas em processos industriais. Em sistemas produtivos, a simulação permite identificar gargalos, balancear linhas de produção e testar configurações alternativas sem interromper as operações. A aplicação de métodos de otimização possibilita alcançar maior rendimento e redução de custos, ajustando a alocação de recursos conforme as restrições de capacidade e demanda. Essa integração melhora o planejamento operacional e reduz desperdícios (Santos *et al.*, 2021).

A utilização de ferramentas de simulação combinadas a algoritmos de otimização contribui para o desenvolvimento de modelos preditivos robustos. Esses modelos permitem prever o comportamento de sistemas complexos sob diferentes condições e identificar tendências futuras. Quando aliados à IA, tornam-se capazes de ajustar-se automaticamente às mudanças nas variáveis externas, criando sistemas autônomos de controle e decisão. Essa abordagem é essencial em contextos como transporte urbano, energia e logística de suprimentos (Lan *et al.*, 2025).

A aplicação de técnicas de otimização em fluxos urbanos e produtivos também está associada ao conceito de resiliência operacional. Modelos baseados em simulação permitem identificar vulnerabilidades e testar respostas a eventos disruptivos, como falhas em

equipamentos ou interrupções na cadeia de suprimentos. A otimização, por sua vez, propõe soluções alternativas que restabelecem o equilíbrio do sistema com o mínimo impacto possível. Essa capacidade de adaptação é um diferencial para a gestão moderna de operações (Camargo, 2022).

A integração da simulação com modelos de otimização é frequentemente operacionalizada por meio de abordagens híbridas, nas quais a simulação fornece dados para alimentar o processo de otimização, e os resultados da otimização retroalimentam a simulação. Esse ciclo iterativo permite refinar continuamente as soluções até alcançar níveis desejáveis de desempenho. O uso de plataformas híbridas tem se expandido em áreas como planejamento urbano, manufatura avançada e gestão de energia (Goodwin *et al.*, 2023).

A tomada de decisão baseada em simulação também se beneficia de métodos multicritério, como o *Analytic Hierarchy Process* (AHP) e o *Technique for Order Preference by Similarity to Ideal Solution* (TOPSIS). Esses métodos auxiliam na ponderação de diferentes objetivos, permitindo avaliar alternativas sob diversos critérios de desempenho. Quando combinados com simulação, oferecem uma estrutura sistemática para priorizar ações e selecionar políticas operacionais mais adequadas, reduzindo a subjetividade nas decisões (Almeida *et al.*, 2023).

Em ambientes urbanos complexos, a otimização de fluxos depende da capacidade de integrar informações provenientes de diferentes fontes. A interoperabilidade entre sistemas de transporte, energia e comunicação é essencial para coordenar decisões de forma eficiente. A utilização de gêmeos digitais (*digital twins*) e plataformas de simulação integradas permite analisar interdependências entre setores e prever os impactos cruzados das intervenções. Essa abordagem aumenta a precisão das decisões e promove um planejamento mais sustentável (Moreno *et al.*, 2025).

No âmbito industrial, as técnicas de otimização baseadas em simulação têm sido empregadas para planejar operações personalizadas e adaptativas. Modelos de manufatura inteligente utilizam simulação para projetar a configuração ideal de linhas de produção, levando em conta restrições de recursos e variabilidade de demanda. Com o apoio da IA, esses modelos tornam-se capazes de reconfigurar automaticamente o fluxo produtivo em tempo real, assegurando maior produtividade e flexibilidade (Lan *et al.*, 2025).

A integração entre IA e simulação cria um ambiente de apoio à decisão que aprende com os resultados e aprimora continuamente as estratégias de otimização. A combinação entre dados históricos, simulação em tempo real e algoritmos de aprendizado supervisionado permite prever a eficácia de diferentes políticas operacionais e ajustar parâmetros automaticamente.

Essa convergência entre automação e análise inteligente impulsiona a transformação digital da gestão de operações (Goodwin *et al.*, 2023).

Os modelos de simulação e otimização também têm contribuído para a redução do impacto ambiental das operações urbanas e industriais. Ao analisar cenários alternativos de transporte, produção e distribuição, é possível identificar soluções que minimizam o consumo de energia e as emissões de poluentes sem comprometer o desempenho. A otimização multiobjetivo fornece suporte à implementação de estratégias sustentáveis que equilibram eficiência e responsabilidade ambiental (Camargo, 2022).

No campo das políticas públicas, a utilização de modelos baseados em simulação e otimização tem favorecido a formulação de estratégias mais eficazes e transparentes. Esses modelos possibilitam avaliar previamente o impacto de investimentos e mudanças estruturais, fornecendo informações objetivas para a priorização de projetos. A integração com dados em tempo real fortalece a governança baseada em evidências e amplia a eficiência na gestão urbana (Almeida *et al.*, 2023).

Em termos conceituais, a tomada de decisão baseada em simulação reflete a transição de uma abordagem reativa para uma abordagem preditiva e proativa. Em vez de responder a eventos após sua ocorrência, gestores passam a antecipar resultados e a escolher estratégias com base em projeções fundamentadas. Essa mudança de paradigma reforça a importância da modelagem computacional e da inteligência artificial como pilares da administração moderna de sistemas complexos (Lan *et al.*, 2025).

Os métodos de otimização baseados em aprendizado de máquina estão transformando a forma como se interpretam os dados gerados pela simulação. Algoritmos de redes neurais e de regressão profunda permitem identificar relações não lineares entre variáveis e prever respostas do sistema a novos estímulos. Essa capacidade de generalização amplia o potencial das simulações e torna os processos decisórios mais confiáveis e adaptáveis às condições reais (Goodwin *et al.*, 2023).

A consolidação da tomada de decisão baseada em simulação depende de um ambiente de dados integrados e de um ciclo contínuo de aprendizado organizacional. Isso requer investimentos em infraestrutura tecnológica, capacitação e governança da informação. À medida que a integração entre simulação, IA e otimização avança, as organizações tornam-se mais aptas a operar de maneira autônoma, previsível e eficiente. Essa evolução redefine o conceito de desempenho, aproximando a engenharia da análise estratégica (Moreno *et al.*, 2025).

A otimização de fluxos e a tomada de decisão baseada em simulação representam um avanço metodológico que alia eficiência, inovação e sustentabilidade. Ao combinar modelagem matemática, inteligência artificial e experimentação virtual, essas técnicas possibilitam compreender e gerir sistemas complexos de forma integrada. A aplicação desses princípios em ambientes urbanos e produtivos impulsiona a modernização da gestão e estabelece um novo paradigma de racionalidade técnica e estratégica na Engenharia de Produção (Lan *et al.*, 2025).

2.6 Procedimentos de busca da literatura

A construção da fundamentação teórica apresentada neste capítulo exigiu a seleção estruturada de referências capazes de sustentar os conceitos discutidos ao longo das seções anteriores. Embora o presente estudo não configure uma revisão sistemática, adotou-se o uso de um fluxograma PRISMA em versão adaptada com a finalidade de documentar, de forma transparente e organizada, o percurso de identificação e seleção da literatura pertinente.

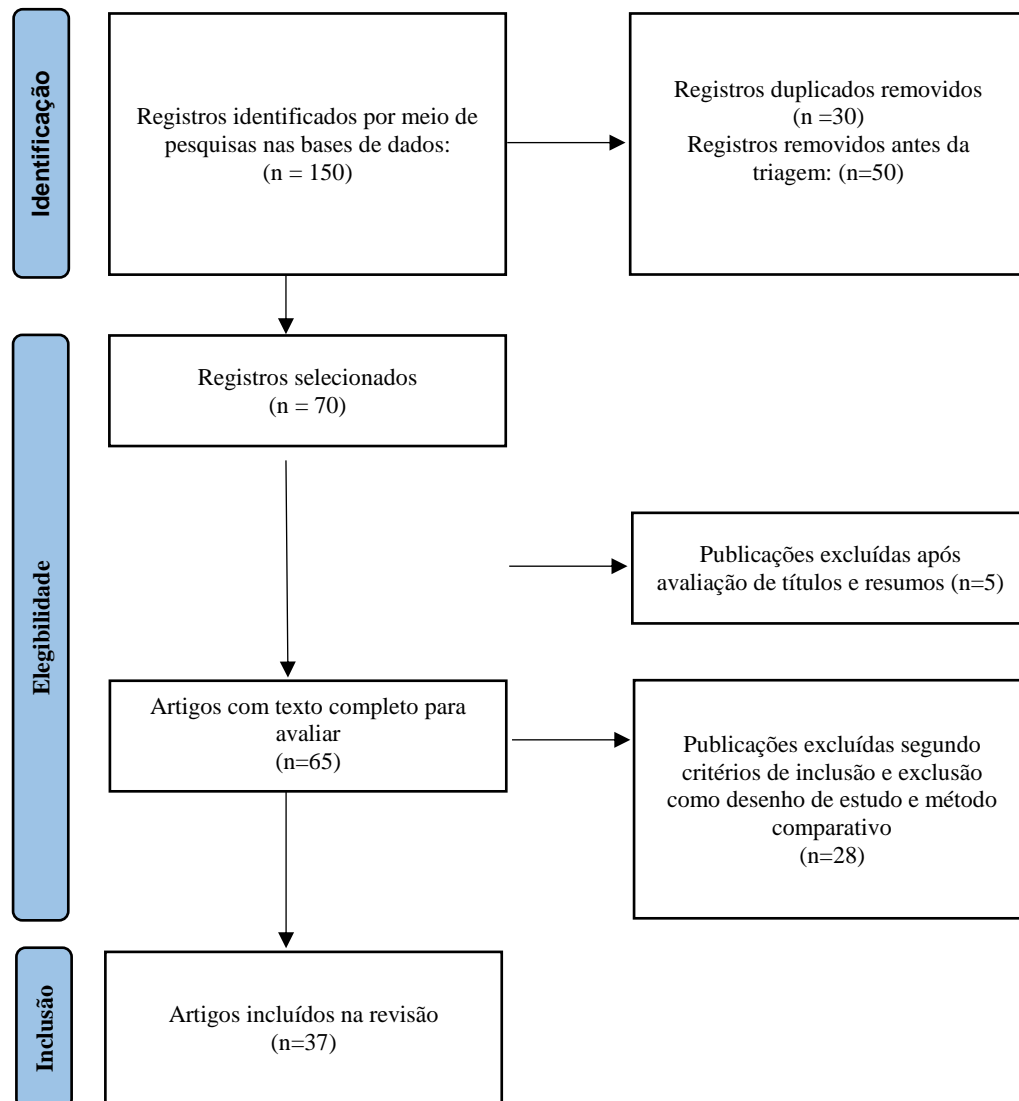
O emprego do PRISMA (Figura 1) neste contexto possui caráter exclusivamente descritivo, atuando como um recurso metodológico complementar para registrar o fluxo geral de busca, triagem e inclusão dos estudos consultados. Não foram aplicados os procedimentos formais e rigorosos característicos de revisões sistemáticas, preservando-se o foco deste capítulo como parte de uma fundamentação teórica orientada à análise e contextualização dos temas essenciais às simulações urbanas que compõem as etapas posteriores da pesquisa.

O processo de organização da literatura foi estruturado em etapas sequenciais, conforme descrito a seguir:

1. Identificação: realização de busca inicial nas bases Google Scholar, Scopus, Web of Science e ScienceDirect, contemplando publicações alinhadas aos temas centrais deste capítulo, tais como simulação urbana, modelos locacionais, digital twins, avaliação operacional e otimização de fluxos.
2. Triagem preliminar: leitura de títulos e resumos para verificar aderência conceitual aos eixos temáticos da fundamentação, descartando materiais redundantes ou claramente distantes do escopo teórico pretendido.
3. Seleção: análise seletiva dos textos remanescentes, avaliando sua relevância, aplicabilidade conceitual e contribuição para o delineamento dos fundamentos utilizados no estudo.

4. Inclusão: consolidação final de 37 estudos que subsidiaram a formulação dos tópicos apresentados nas seções 2.1 a 2.5, compondo o conjunto de referências essenciais à contextualização teórica da pesquisa.

Figura 1. Fluxograma PRISMA



Fonte: PRISMA (2020)

A inclusão de um PRISMA adaptado no Capítulo 2 tem por objetivo:

- evidenciar o percurso sistematizado adotado para estruturar o corpo teórico do estudo;
- reforçar a transparência acadêmica no levantamento da literatura;

- demonstrar que a fundamentação foi construída com base em critérios claros de pertinência temática;
- assegurar rastreabilidade e organização das bases conceituais que orientam a etapa de modelagem e simulação.

Ressalta-se que o uso do fluxograma não implica a realização de uma revisão sistemática, mas sim o registro formal do processo de levantamento que sustenta os conteúdos teóricos integrados ao desenvolvimento metodológico apresentado nos capítulos seguintes.

3. METODOLOGIA

A metodologia deste estudo foi estruturada para integrar modelagem orientada a agentes, análise operacional e avaliação de cenários, em conformidade com os princípios da Engenharia de Produção. O processo foi dividido em etapas encadeadas que permitem representar, simular e comparar diferentes configurações espaciais de bases de táxi dentro da Cidade Universitária da Universidade de São Paulo (USP), considerando os fluxos de deslocamento em direção à Estação Butantã.

3.1 Levantamento conceitual e parâmetros

A fundamentação teórica necessária para o desenvolvimento do modelo foi construída a partir de um levantamento organizado da literatura especializada em simulação urbana, otimização espacial, localização de serviços públicos e avaliação de desempenho. Esse levantamento serviu para estruturar os conceitos utilizados no modelo, orientar a definição dos parâmetros operacionais e embasar a lógica dos agentes empregados na simulação.

Foram priorizados estudos com aplicação prática em logística urbana, transporte, digital twins e técnicas de modelagem computacional, publicados entre 2020 e 2025.

3.2 Desenvolvimento da simulação computacional

A simulação foi projetada com base na metodologia HALTER, adaptada às etapas de modelagem computacional. O sistema principal corresponde à Cidade Universitária da USP, adotada como ambiente de teste (template). Dentro deste sistema, foram definidos subsistemas operacionais, representados pelas células de operação correspondentes aos departamentos universitários, pontos de táxi e a Estação Butantã, que atua como ponto fixo de destino.

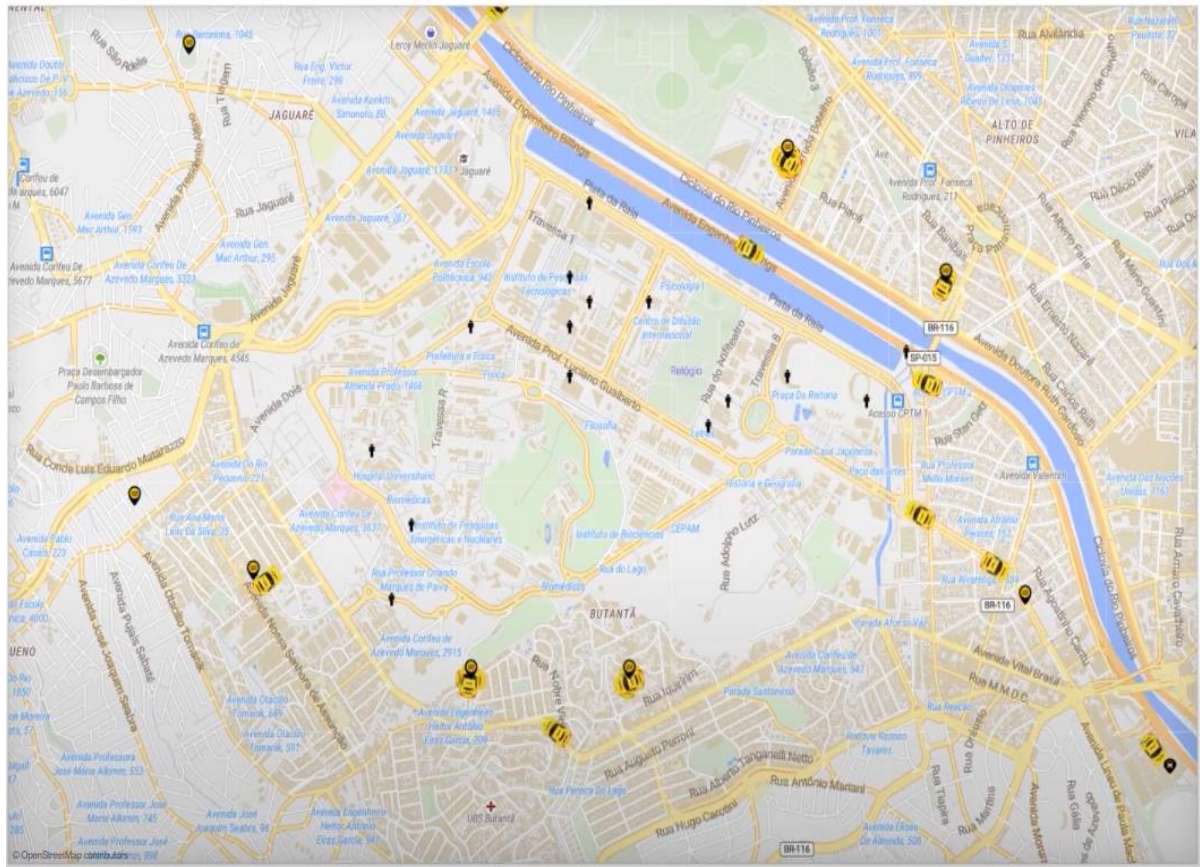
O desenvolvimento foi dividido em duas fases:

1. Modelagem do sistema AS-IS, correspondente à configuração atual das operações de transporte;
2. Proposição do modelo TO-BE, com inclusão de fluxos otimizados e lógica de interação dinâmica entre agentes.

3.3 Estrutura e Funcionamento do Modelo

Na primeira etapa, simulou-se o sistema AS-IS, conforme ilustrado na Figura 2, onde o campus da USP foi representado por uma rede de agentes (departamentos, pontos de táxi e destino fixo). As solicitações de viagem foram geradas aleatoriamente em diferentes institutos (como o Instituto de Física, a Escola Politécnica e a Faculdade de Filosofia, Letras e Ciências Humanas), de modo a reproduzir o comportamento estocástico da demanda por transporte interno.

Figura 2. Simulação Modelo Táxis



Fonte: Elaborado pelo autor (2025)

A Figura 2 mostra a configuração do modelo AS-IS no ambiente simulado, evidenciando a distribuição espacial dos agentes e a estrutura operacional atual. Observa-se a localização dos pontos de táxi ao longo do campus e a disposição das unidades acadêmicas, o que permite visualizar as distâncias médias que os veículos precisam percorrer ao atender uma solicitação. O mapa reforça a natureza descentralizada do sistema real, revelando a potencial existência de zonas de maior demanda e áreas mais afastadas dos pontos de origem dos táxis.

Essa representação é fundamental para entender como a dispersão espacial interfere no tempo de resposta e no nível de serviço do sistema atual.

Ao surgir uma solicitação, o sistema identifica o ponto de táxi mais próximo e verifica a disponibilidade de veículos. Caso haja táxi livre, ele é direcionado para o local da solicitação, mudando seu estado para “ocupado”. Se não houver disponibilidade, o sistema busca o próximo ponto disponível até localizar um veículo. Quando nenhum táxi estiver livre, o pedido permanece em estado de espera, até que um táxi seja liberado.

A lógica de requisição é representada pela Figura 3, onde o algoritmo é responsável por localizar o ponto mais próximo, definir o tempo de embarque e direcionar o pedido ao táxi livre por meio da função *send(pedido,taxi)*. Os principais parâmetros de entrada são:

- tempo_embarque_pagamento
- local_do_pedido
- ponto_de_táxi
- destino (Butantã)

Figura 3. requestPedido

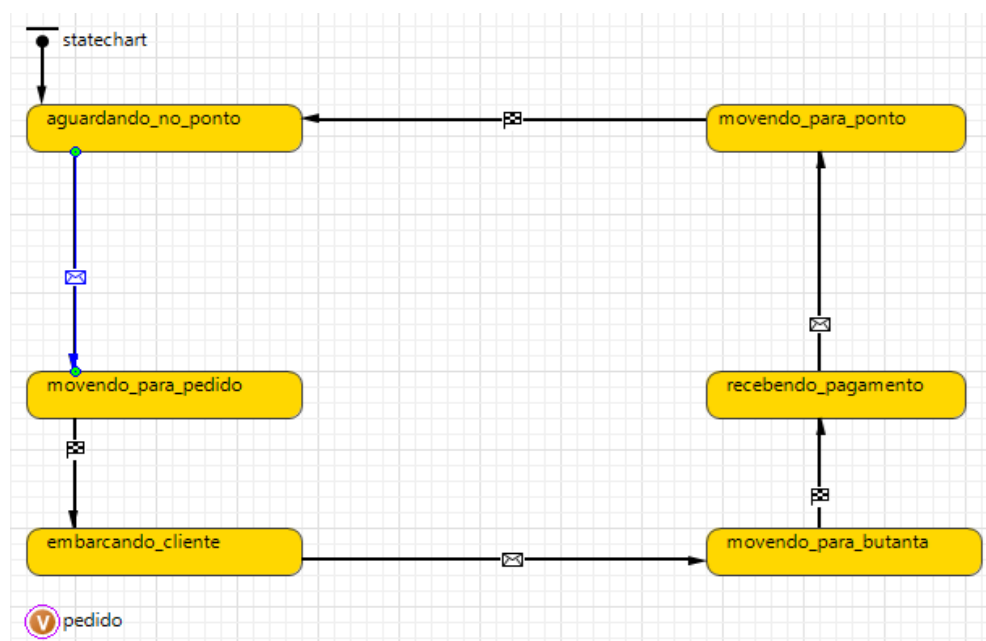
Fonte: Elaborado pelo autor (2025)

A Figura 3 detalha a lógica computacional que estrutura o fluxo de requisição de um táxi. Ela evidencia o processo de tomada de decisão do modelo, mostrando a ordem em que o algoritmo identifica o ponto mais próximo, verifica disponibilidade e aloca o veículo adequado. Esse diagrama destaca a dependência espacial entre o local da solicitação e a posição dos táxis, além de ilustrar a sequência de estados que compõem o atendimento. Também fica claro como o sistema trata situações de indisponibilidade temporária: o pedido entra em espera até que um veículo retorne ao estado “livre”. Assim, a figura reforça o caráter estocástico e dinâmico da operação, explicando visualmente a base lógica empregada para a simulação dos cenários AS-IS e TO-BE.

3.4 Ciclo de atendimento e lógica operacional

Após o recebimento da solicitação, o táxi transita entre os estados definidos no (Figura 4), iniciando em “aguardando_no_ponto”. Ao ser acionado, o veículo passa ao estado “movendo_para_pedido” até chegar ao local de embarque, conforme o processo descrito na Figura 5. Após embarcar o passageiro, o veículo muda para “movendo_para_butantã”. No destino, executa o desembarque e o pagamento, conforme ilustrado na Figura 6. Por fim, o táxi retorna à sua base de origem no estado “movendo_para_ponto”, finalizando o ciclo ao retornar a “aguardando_no_ponto”.

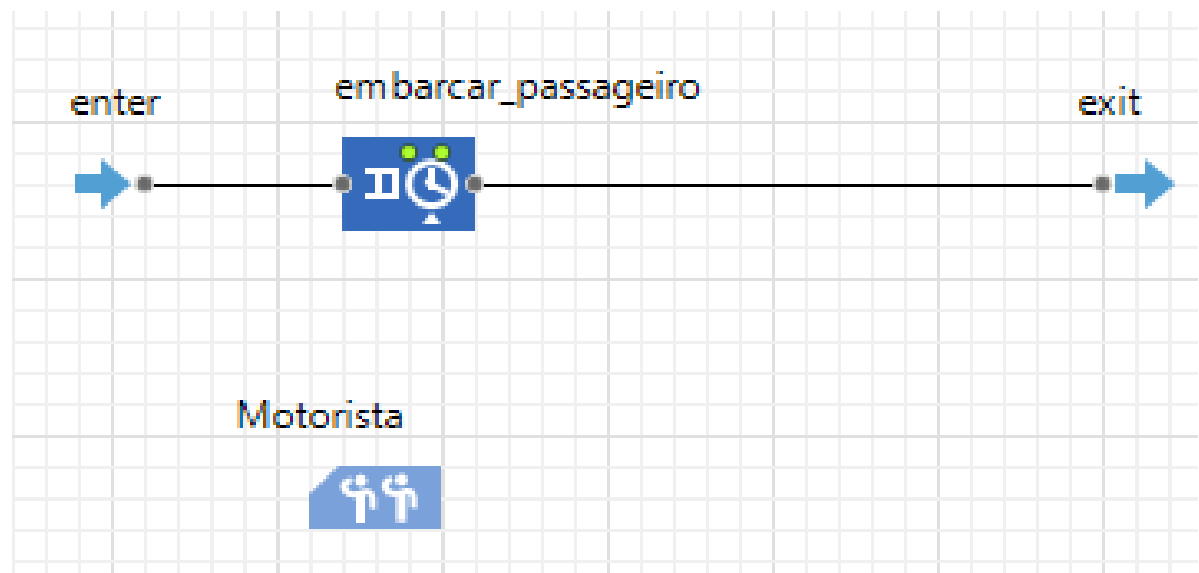
Figura 4. Diagrama de Estado Táxis



Fonte: Elaborado pelo autor (2025)

O diagrama apresenta a sequência de estados do táxi ao longo de todo o ciclo de atendimento. Ele demonstra como o veículo alterna entre momentos de espera, deslocamento e prestação direta do serviço. O estado inicial “aguardando_no_ponto” evidencia o comportamento ocioso, típico do modelo AS-IS. A transição para “movendo_para_pedido” indica o início da operação, guiado pela localização do cliente. A figura destaca ainda que, após completar a viagem, o táxi sempre retorna ao ponto de origem, reforçando a influência da geografia do campus na eficiência operacional. Assim, o diagrama permite visualizar de forma clara a lógica comportamental que sustenta a modelagem e explica como os tempos médios de deslocamento e atendimento são formados durante a simulação.

Figura 5. Lógica Embarque de Passageiro

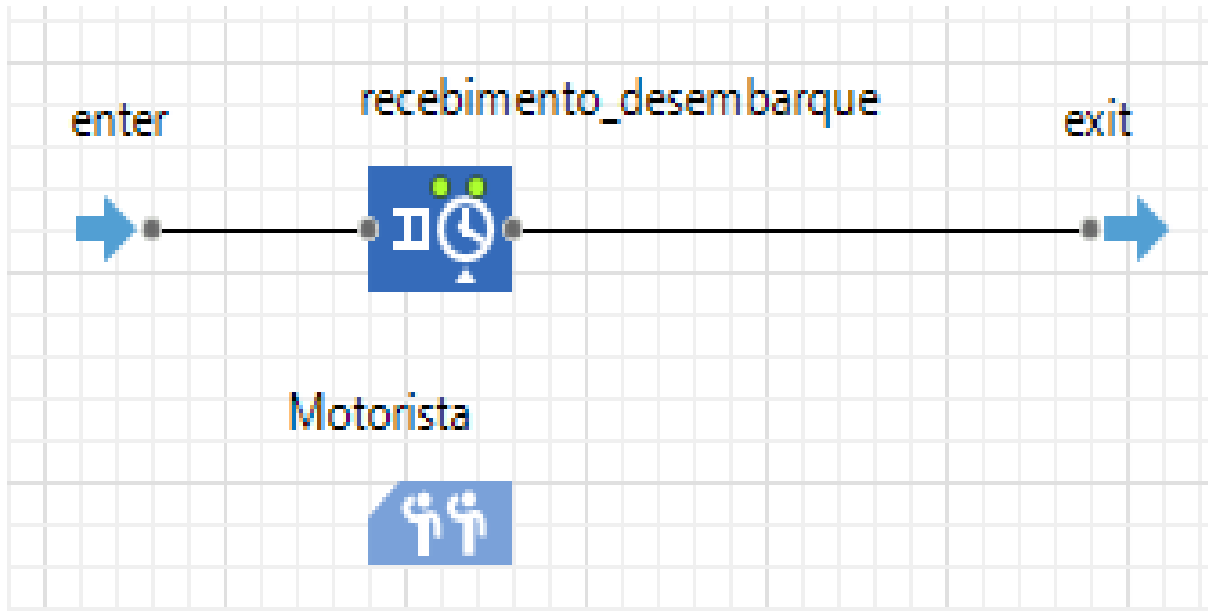


Fonte: Elaborado pelo autor (2025)

A Figura 5 descreve a lógica específica do processo de embarque. É possível observar a sequência de verificações realizadas pelo sistema, desde a chegada do táxi ao local da solicitação até o início efetivo do deslocamento ao destino. A representação evidencia o momento em que o passageiro é atendido e como o tempo de embarque — variável importante na modelagem — é incorporado ao fluxo operacional. Ao tornar explícita essa etapa, a figura demonstra onde ocorrem possíveis atrasos e como fatores comportamentais (ex.: tempo de espera do usuário, tempo de acomodação) influenciam o desempenho global. Essa visualização reforça o caráter detalhado da simulação e sua aderência ao comportamento real do sistema de transporte.

A Figura 6 detalha o processo final do ciclo de atendimento, composto pelo desembarque e pelo pagamento.

Figura 6. Lógica Desembarque/Pagamento de Passageiro



Fonte: Elaborado pelo autor (2025)

A imagem evidencia que o sistema só considera a corrida concluída após o processamento completo dessa etapa, influenciando diretamente o tempo total da operação, destacando a importância dessa transição para a liberação do táxi para novas solicitações, já que o veículo só retorna ao estado “movendo_para_ponto” após finalizar toda a interação com o passageiro. Esse detalhamento permite compreender como pequenas variáveis, como o tempo de pagamento, podem impactar o fluxo geral e aumentar ou reduzir a capacidade do sistema em atender novas demandas.

3.5 Georreferenciamento e parâmetros espaciais

Os pontos de táxi e a Estação Butantã foram inseridos no sistema com base em coordenadas reais de latitude e longitude, representadas na Figura 7 e na Figura 8. Esse georreferenciamento garante maior realismo ao modelo e permite a integração futura com sistemas de navegação baseados em dados GIS (*Geographic Information System*).

A Figura 7 apresenta a distribuição geográfica dos pontos de táxi utilizados na simulação, posicionados exatamente conforme suas coordenadas reais no campus. A

visualização evidencia a dispersão espacial das bases e permite identificar áreas com maior ou menor cobertura potencial.

Figura 7. Localização Pontos de Táxi

	latitude	longitude	n_taxis
	▼	▼	▼
1	-23.547	-46.749	2
2	-23.565	-46.752	2
3	-23.568	-46.746	2
4	-23.572	-46.735	2
5	-23.582	-46.738	2
6	-23.572	-46.727	2
7	-23.584	-46.724	2
8	-23.584	-46.721	2
9	-23.583	-46.717	2
10	-23.569	-46.707	2
11	-23.556	-46.711	2
12	-23.551	-46.719	2
13	-23.557	-46.695	2

Fonte: Elaborado pelo autor (2025)

A relação entre esses pontos e a malha urbana modelada ajuda a compreender por que determinadas solicitações exigem percursos mais longos no cenário AS-IS. Além disso, a representação reforça a importância do georreferenciamento para reproduzir fielmente os padrões operacionais e para sustentar as análises comparativas entre os cenários posteriormente simulados. Já a Figura 8 destaca a posição da Estação Butantã, tratada como destino fixo para todas as simulações.

Figura 8. Localização Estação Butantã

	longitude	latitude	tipo
1	-46.708	-23.571	BUTANTÃ

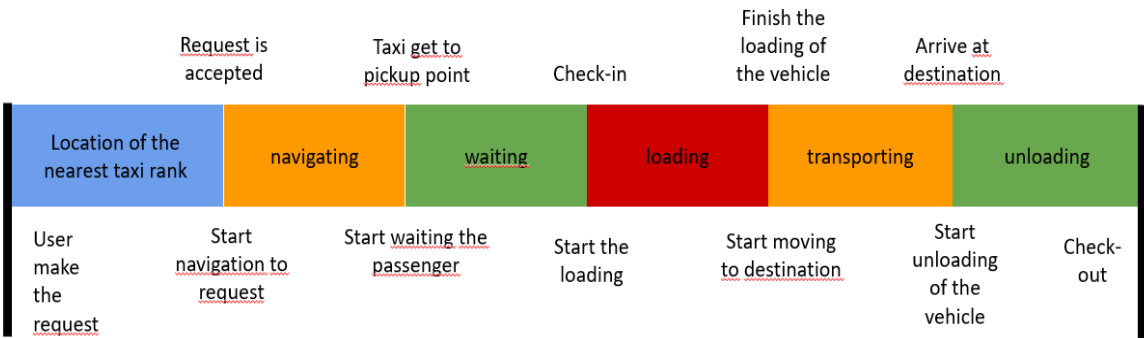
Fonte: Elaborado pelo autor (2025)

Sua localização fora do núcleo central do campus cria um gradiente espacial relevante: quanto mais distante o instituto gerador de demanda, maior o trajeto percorrido por táxis e passageiros. A imagem evidencia a centralidade da estação dentro da lógica da modelagem, funcionando como ponto de convergência de fluxos e influenciando diretamente métricas como tempo médio de atendimento e distância percorrida. Essa representação espacial é fundamental para justificar o comportamento observado nos diferentes cenários simulados.

3.6 Ciclo de vida dos pedidos e representação visual

O ciclo de vida dos pedidos, que engloba as etapas de solicitação, embarque, transporte, desembarque e retorno, é sintetizado na Figura 9. Além disso, foi criada uma visualização tridimensional do processo utilizando o Prototype Grid, representada nas Figuras 9 a 20, que simulam o comportamento sequencial dos táxis, desde o estado inicial até a finalização das corridas. A Figura 9 apresenta um fluxograma completo do ciclo de vida de cada solicitação dentro da simulação.

Figura 9. Request Lifecycle

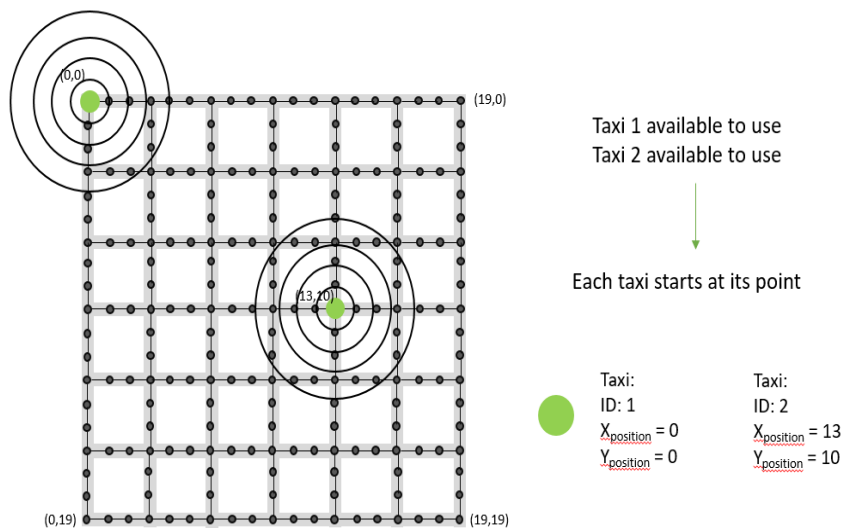


Fonte: Elaborado pelo autor (2025)

É possível observar a sequência lógica que estrutura o atendimento: a criação do pedido, a identificação do táxi mais próximo, o deslocamento do veículo, o embarque do passageiro, o trajeto até o destino e o retorno ao ponto de origem. Essa visualização evidencia a linearidade das etapas, mas também permite identificar pontos potenciais de congestionamento operacional, como o tempo de espera por táxi livre ou os atrasos no embarque. A representação gráfica sintetiza de forma clara como o sistema interpreta cada evento dentro da simulação, permitindo ao leitor compreender o fluxo integral de operação e sua relação com as métricas de desempenho analisadas posteriormente.

A Figura 10 apresenta a malha tridimensional utilizada para representar o ambiente simulado, conhecida como *Prototype Grid*. Ela funciona como um tabuleiro virtual que define posições possíveis para táxis, pedidos e trajetos. Observa-se que o grid organiza visualmente as entidades e permite acompanhar o deslocamento dos agentes ao longo do tempo. Essa estrutura é essencial para compreender como o modelo distribui espacialmente os eventos e como o comportamento emergente surge da interação entre as unidades do sistema.

Figura 10. System Prototype Grid

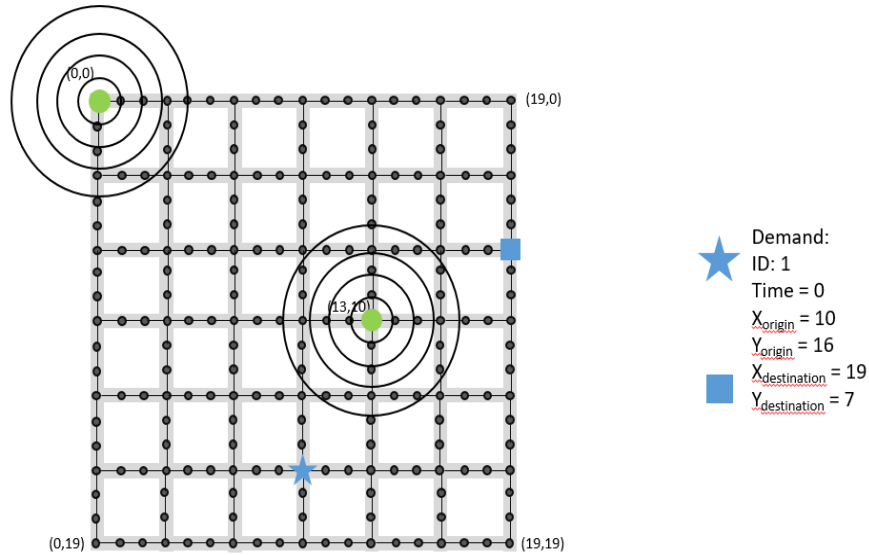


Fonte: Elaborado pelo autor (2025)

A Figura 11 apresenta a malha tridimensional utilizada para representar o ambiente simulado, conhecida como *Prototype Grid*. Ela funciona como um tabuleiro virtual que define posições possíveis para táxis, pedidos e trajetos. O grid organiza visualmente as entidades e permite acompanhar o deslocamento dos agentes ao longo do tempo. Essa estrutura é essencial

para compreender como o modelo distribui espacialmente os eventos e como o comportamento emergente surge da interação entre as unidades do sistema.


Figura 11. Táxis aguardando solicitações



Fonte: Elaborado pelo autor (2025)

A Figura 12 registra o momento em que uma nova solicitação é gerada no sistema. O uso do símbolo de estrela para a origem e do quadrado para o destino permite identificar claramente o ponto de criação da demanda e a rota desejada.

Figura 12. Surgimento de demanda (estrela = origem, quadrado = destino)

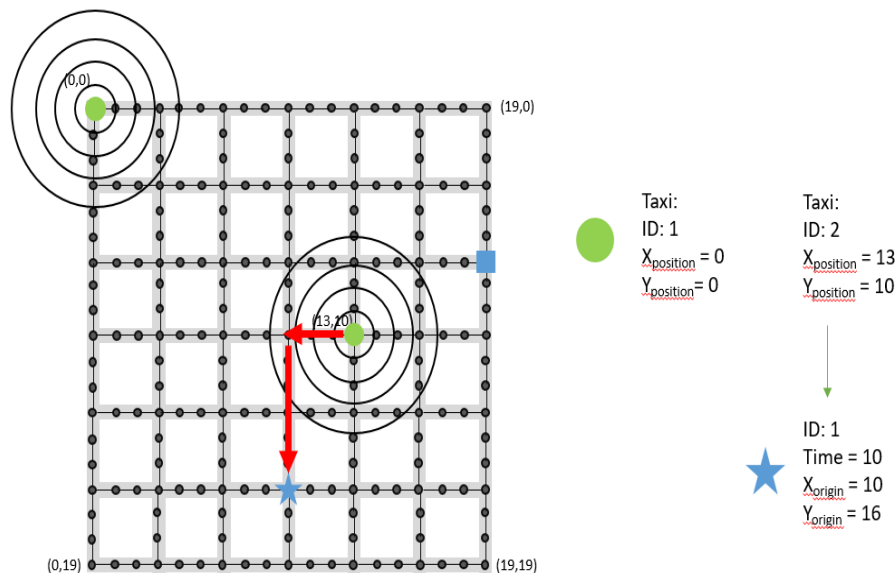


Fonte: Elaborado pelo autor (2025)

Essa visualização é fundamental para interpretar a dinâmica estocástica do modelo: solicitações surgem de forma aleatória nos institutos, e a distância entre o ponto de origem e os táxis disponíveis determina o tempo de resposta inicial do sistema.

A Figura 13 demonstra o algoritmo de seleção do táxi mais próximo ao local da solicitação. O destaque está no traçado da rota, evidenciando o caminho calculado automaticamente pelo modelo. O leitor deve observar que essa etapa representa a lógica de alocação central do sistema, que busca sempre minimizar distância percorrida e tempo até o embarque, influenciando diretamente métricas como nível de serviço e eficiência espacial.

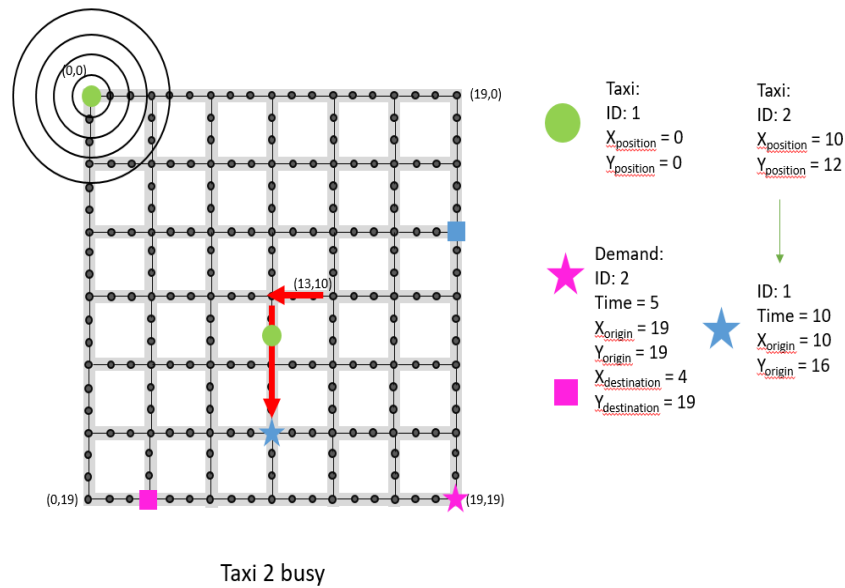
Figura 13. Definição da rota pelo táxi mais próximo



Fonte: Elaborado pelo autor (2025)

A Figura 14 representa um cenário em que múltiplas solicitações surgem de forma simultânea ou em sequência rápida, exigindo redistribuição dinâmica dos táxis. Esse quadro ajuda a visualizar como o sistema lida com carga crescente e como a frota se movimenta para diferentes regiões do grid. A leitura da figura reforça a natureza não linear do comportamento dos agentes e evidencia a possibilidade de formação de gargalos operacionais.

Figura 14. Surgimento de novas demandas e redistribuição de veículos



Fonte: Elaborado pelo autor (2025)

Complementando a figura anterior, a Figura 15 demonstra como o posicionamento dos táxis muda continuamente conforme novas solicitações surgem em diferentes setores do modelo. Observa-se o deslocamento simultâneo de múltiplos veículos, indicando que a eficiência do sistema depende fortemente da proximidade da frota em relação às áreas mais demandadas.

Figura 15. Surgimento de novas demandas e redistribuição de veículos







Figura 17. Embarque e deslocamento de passageiros**Fonte:** Elaborado pelo autor (2025)

A Figura 18 apresenta o momento de desembarque do passageiro na estação de destino. O táxi encerra o ciclo de atendimento principal e inicia o retorno à base. A interpretação desse quadro ajuda a compreender como o modelo incorpora o deslocamento de volta como parte da operação, influenciando a disponibilidade da frota e o tempo ocioso entre chamadas.

Figura 18. Desembarque e retorno ao ponto de táxi**Fonte:** Elaborado pelo autor (2025)


Complementando a figura anterior, a Figura 19 mostra o trajeto de retorno até o ponto base. O leitor deve notar que a distância percorrida em vazio é um fator relevante para o custo operacional do sistema e para a agilidade na resposta a novas demandas. Essa etapa é importante para explicar diferenças de desempenho entre os cenários, especialmente quando a frota é redistribuída.

Figura 19. Desembarque e retorno ao ponto de táxi




Fonte: Elaborado pelo autor (2025)

A Figura 20 mostra o ponto final do ciclo: o táxi retorna ao estado de disponibilidade, pronto para reagir às próximas solicitações. Esta etapa evidencia a conclusão completa do fluxo operacional, permitindo que o leitor visualize como os veículos se reestabelecem nos pontos originais após cada serviço. Essa visualização ajuda a entender a dinâmica de reposicionamento no cenário AS-IS.

Figura 20. Finalização do ciclo e disponibilidade de novos atendimentos

Fonte: Elaborado pelo autor (2025)

A Figura 21 reforça o encerramento do ciclo operacional e destaca novamente a restauração do estado inicial. Esse quadro auxilia o leitor a compreender a natureza repetitiva e contínua do processo na simulação, no qual cada táxi alterna entre estados de ociosidade, deslocamento e atendimento. A figura contribui para visualizar a estabilidade do modelo e seu comportamento em regime ao longo das múltiplas execuções.

Figura 21. Finalização do ciclo e disponibilidade de novos atendimentos

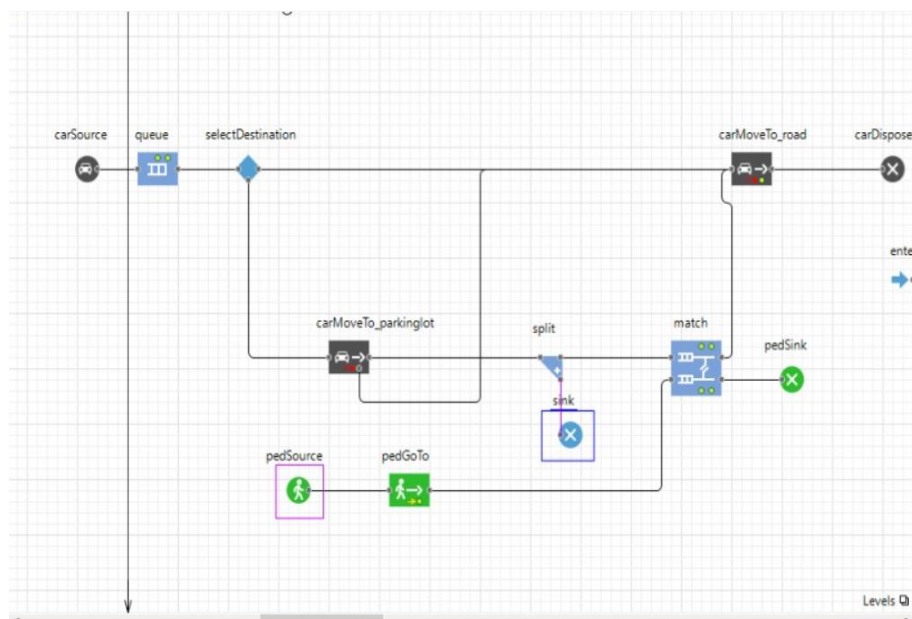
Fonte: Elaborado pelo autor (2025)

Os outputs resultantes do modelo incluem métricas de tempo médio de corrida, tempo até o cliente, tempo total até o destino, distância percorrida e número de táxis disponíveis no sistema.

3.7 Expansão da simulação: dinâmica de desembarque e fluxo de pessoas

Após a modelagem do transporte principal, foi implementada a segunda dinâmica do sistema, representada na Figura 22. Nesta etapa, cada desembarque gera um novo agente “pessoa” dentro do sistema, que passa a interagir com o ambiente, conforme simulado nas Figuras 23 e 24. O objetivo é permitir que cada passageiro desembarcado se torne uma entidade ativa, capaz de realizar diferentes ações dentro do ambiente urbano, como deslocar-se para outros blocos ou solicitar novos transportes.

Figura 22. Nova Lógica de Desembarque de Passageiros




Fonte: Elaborado pelo autor (2025)

A Figura 22 apresenta a lógica que transforma cada passageiro desembarcado em um agente independente no sistema. Observa-se que, ao chegar ao destino, o usuário deixa de ser apenas um elemento passivo do transporte e passa a constituir uma unidade ativa com comportamento próprio. Essa representação destaca a ampliação do escopo da simulação: o fluxo não se encerra no desembarque, mas sim evolui para novas interações que podem gerar

demandas adicionais. Essa lógica é essencial para simular cenários urbanos mais complexos e captar efeitos dinâmicos que não seriam visíveis no modelo restrito apenas aos táxis.

Já a Figura 23 mostra o momento em que o passageiro é convertido em agente “pessoa” no ambiente da Estação Butantã. Essa visualização evidencia a criação da entidade e sua posição inicial no sistema, demonstrando a transição entre o transporte e o comportamento pós-deslocamento, reforçando o papel da estação como ponto de geração de novos fluxos. É possível observar como essa etapa abre a possibilidade de ações subsequentes, como movimentação para outros blocos ou geração de novas solicitações.


Figura 23. Simulação Desembarque Estação Butantã



Fonte: Elaborado pelo autor (2025)

Complementando a figura anterior, a Figura 24 demonstra a dispersão inicial dos agentes recém-criados ao redor da área da estação. A imagem ilustra como essas pessoas começam a se deslocar pelo ambiente, indicando que a lógica de mobilidade foi incorporada ao sistema. A interação dos agentes com elementos urbanos — ruas, edifícios e blocos — cria uma dinâmica mais realista e permite estudar como o transporte influencia e é influenciado pelo comportamento humano no espaço urbano.

Figura 24. Simulação Desembarque Estação Butantã



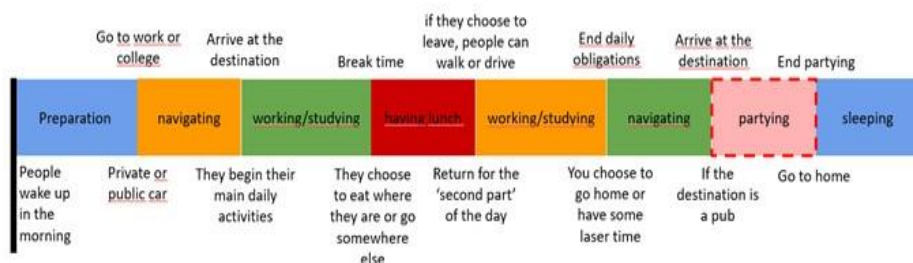
Fonte: Elaborado pelo autor (2025)

3.8 Simulação expandida: estrutura urbana e ciclo de vida do cidadão

A extensão do modelo permite a construção de uma malha urbana composta por oito vias com fluxos de entrada e saída, ilustradas na Figura 25. Cada bloco urbano abriga edificações que representam residências, locais de trabalho ou lazer, visualizados na Figura 26. A sequência operacional é apresentada nas figuras seguintes.

A Figura 25 apresenta o ciclo diário do cidadão no ambiente simulado, representado por uma lógica sequencial que abrange permanência na residência, deslocamento para o trabalho, atividades externas e retorno ao lar.

Figura 25. People Daycycle



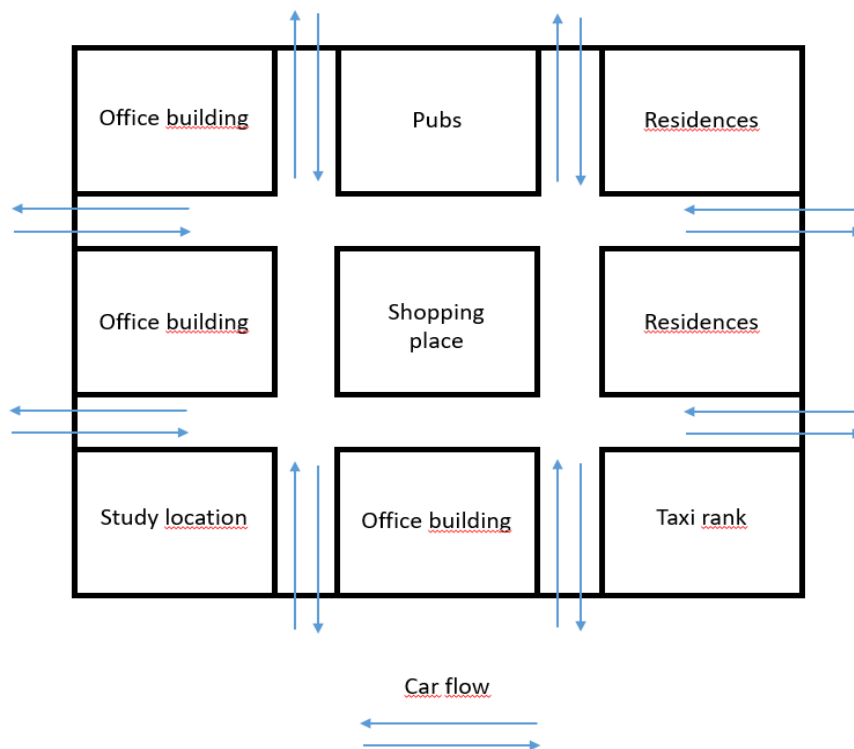
Fonte: Elaborado pelo autor (2025)

Nota-se que o modelo evolui significativamente aqui: o transporte deixa de ser um evento isolado e passa a integrar um fluxo contínuo de mobilidade cotidiana. Essa estrutura

permite analisar como diferentes fases do dia influenciam a demanda por transporte e geram padrões temporais de movimentação urbana.

A figura 26 mostra a estrutura urbana simulada, composta por blocos que representam diferentes tipos de edificações. Observa-se que cada bloco funciona como um polo gerador ou atrator de viagens — residências, centros educacionais, locais de lazer e trabalho. Essa organização espacial é fundamental para estudar como a localização de pontos de táxi, vias e destinos influencia os deslocamentos dos agentes. A imagem fornece a base espacial para compreender a lógica das próximas representações.

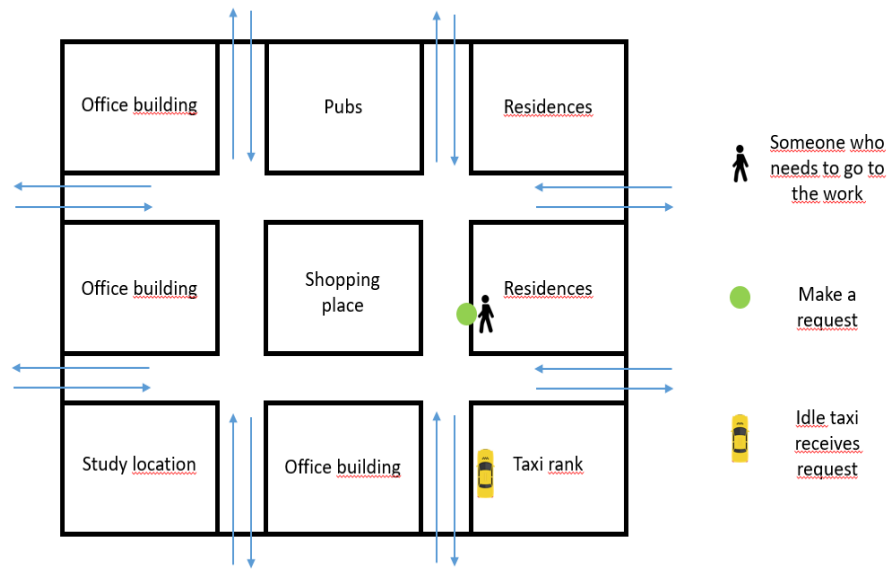
Figura 26. Sistema de Blocos



Fonte: Elaborado pelo autor (2025)

Aqui é possível visualizar a criação de uma nova solicitação de transporte originada em uma residência dentro do sistema (Figura 27). A figura ilustra como os agentes tomam decisões de mobilidade seguindo seu ciclo diário. O leitor deve notar que a demanda não surge apenas de institutos ou da estação, mas também de pontos residenciais, ampliando a diversidade das origens de viagens e tornando o modelo mais próximo do comportamento real de uma cidade.

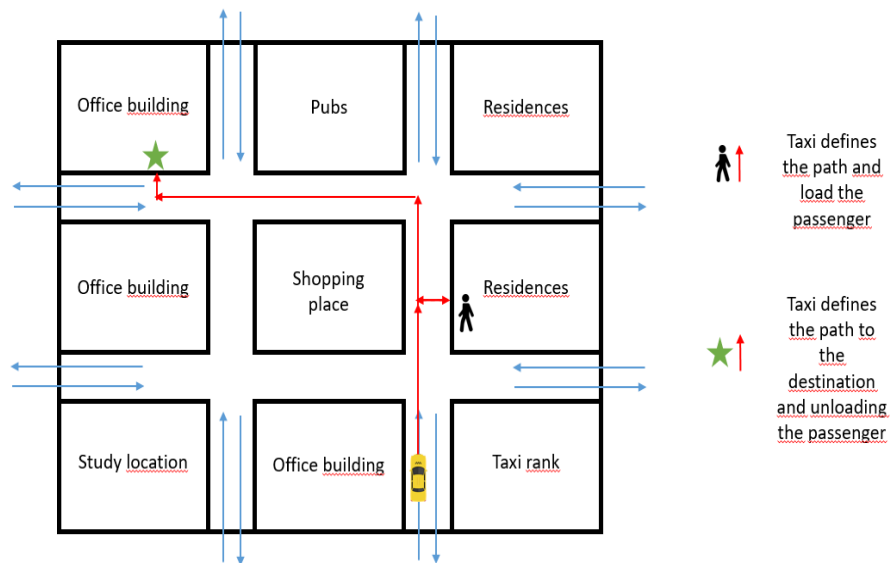
Figura 27. Solicitação de demanda em uma residência



Fonte: Elaborado pelo autor (2025)

Já a Figura 28 apresenta o deslocamento dos agentes após o embarque, revelando o fluxo ativo de passageiros no sistema. O leitor deve observar a multiplicidade de rotas e como os táxis se movimentam simultaneamente no grid urbano. Essa representação ajuda a visualizar padrões de circulação, áreas de concentração de tráfego e potenciais pontos de saturação, elementos fundamentais para avaliar a eficiência das lógicas otimizadas simuladas.

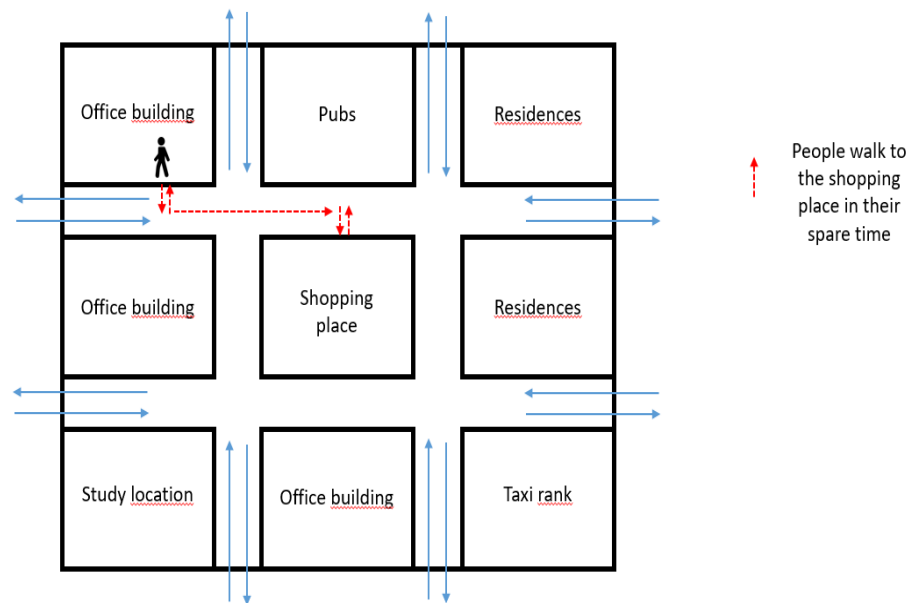
Figura 28. Fluxo de transporte de passageiros



Fonte: Elaborado pelo autor (2025)

A Figura 29 mostra a movimentação de pedestres no ambiente urbano após completarem seus deslocamentos iniciais. É possível observar que os agentes continuam se movimentando entre blocos, criando um fluxo pedestre que interage com o sistema de transporte. Essa dinâmica evidencia a integração entre mobilidade ativa (a pé) e mobilidade assistida (táxi), proporcionando maior realismo ao modelo e permitindo analisar como a distribuição espacial das atividades influencia o transporte.

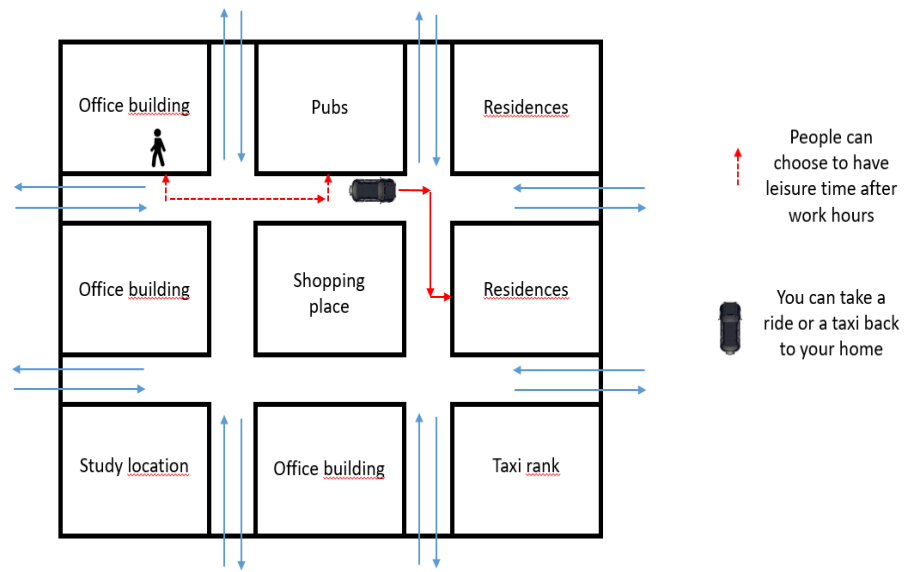
Figura 29. Trânsito de pessoas no sistema



Fonte: Elaborado pelo autor (2025)

A Figura 30 demonstra o momento em que o agente conclui sua atividade principal do dia e decide entre retornar à sua residência ou deslocar-se para um bloco de lazer. Essa bifurcação de comportamento reforça a complexidade da simulação expandida, pois mostra que decisões individuais geram diferentes trajetórias e demandas subsequentes. Essa lógica permite ao modelo reproduzir variações reais na demanda ao longo do dia, como picos noturnos ou deslocamentos entre polos de convivência.

Figura 30. Opções pós-expediente do usuário (voltar para casa ou seguir para lazer)



Fonte: Elaborado pelo autor (2025)

Esse modelo representa o ciclo diário de deslocamento de um cidadão, integrando a lógica de transporte com a simulação comportamental de agentes urbanos.

4. RESULTADOS

4.1 Coleta e tratamento dos dados

A coleta de dados consistiu na execução de 90 simulações, com cinco repetições independentes para cada configuração, totalizando 450 execuções. A decisão por cinco repetições segue recomendações usuais em experimentação computacional em sistemas estocásticos, nas quais múltiplas réplicas reduzem o impacto de variabilidade aleatória gerada pelas distribuições de chegada, deslocamento e estados dos agentes. Esse procedimento possibilita estabilização das médias, melhora da confiabilidade estatística e redução da influência de outliers, garantindo que os valores reportados representem o comportamento típico de cada cenário.

As métricas analisadas foram: nível de serviço, definido como a razão entre solicitações completadas e solicitações geradas; distância média até o ponto de solicitação, medida em quilômetros entre o táxi disponível e o cliente; e tempo médio de corrida, agregando embarque, deslocamento ao destino e retorno ao ponto base. Os resultados foram organizados em três cenários distintos, apresentados a seguir.

O Cenário 1 representa fielmente a configuração real do sistema de táxis da Cidade Universitária. Mantêm-se:

- os 13 pontos atualmente existentes,
- a distribuição original da frota,
- a lógica de operação utilizada no campus,
- os fluxos observados na prática.

Este cenário serve como linha de base para comparação, dessa maneira descreve o sistema “como ele funciona hoje”, sem interferências ou otimizações.

O cenário 2 mantém a frota, porém altera a estrutura espacial do sistema, consolidando todos os veículos em um único ponto central de atendimento, objetivando:

- avaliar se concentrar a frota em uma base única reduz deslocamentos iniciais,
- testar a hipótese de que uma unidade centralizada apresenta respostas mais rápidas em ambientes de alta densidade.

Assim, o Cenário 2 não altera a lógica de operação, mas modifica apenas o posicionamento espacial, permitindo medir o impacto direto da localização.

O Cenário 3 representa a versão otimizada do sistema, incorporando:

- redistribuição estratégica em três macro-bases,
- lógica aprimorada de seleção do táxi mais próximo,
- redução da ociosidade e minimização das distâncias médias,
- parâmetros espaciais revisados e fluxo operacional ajustado.

Trata-se de um sistema projetado, orientado por princípios de eficiência espacial, buscando simular uma operação mais equilibrada entre oferta e demanda, superando limitações identificadas nos dois cenários anteriores.

A Tabela 1 evidencia a evolução do nível de serviço à medida que aumenta o número de veículos e pontos de táxi. Nota-se crescimento consistente da eficiência operacional, com índices superiores a 99% para 65 veículos, confirmando a adequação do modelo AS-IS como referência base.

Tabela 1. Cenário 1 - métricas coletadas

n taxis/ponto	n pontos	Taxis totais	sph	Feitos	Completo	Nível de serviço	Distância até pedido (km)
1	13	13	5	7177	2336	32,55%	2,31
2	13	26	5	7188	4572	63,60%	2,20
3	13	39	5	7246	6431	88,76%	2,03
4	13	52	5	7180	7117	99,12%	1,78
5	13	65	5	7187	7159	99,61%	1,57
1	13	13	6	8625	2353	27,29%	2,32
2	13	26	6	8675	4648	53,58%	2,23
3	13	39	6	8659	6738	77,81%	2,10
4	13	52	6	8626	8194	94,99%	1,93
5	13	65	6	8679	8629	99,42%	1,74
1	13	13	7	10102	2366	23,43%	2,33
2	13	26	7	10071	4719	46,86%	2,25
3	13	39	7	10006	6950	69,46%	2,16
4	13	52	7	10090	8884	88,04%	2,03
5	13	65	7	10136	9942	98,08%	1,86

Fonte: Elaborado pelo autor (2025)

A Tabela 1 apresenta o desempenho do sistema real (AS-IS), permitindo observar como a frota atual responde às diferentes taxas de solicitações por hora (SPH). Nota-se que, para configurações com poucos veículos (13 e 26 táxis), o nível de serviço é significativamente baixo, ficando abaixo de 35% em SPH maiores que 6. Os resultados evidenciam que a combinação atual de número de táxis e sua distribuição nos 13 pontos existentes não é suficiente para atender a demanda crescente, resultando em longos deslocamentos até os clientes (distâncias entre 2,20 e 2,36 km).

Conforme o número total de táxis aumenta, observa-se uma melhora progressiva do sistema: com 52 e 65 veículos, o nível de serviço ultrapassa 94% e chega a 99% em vários casos. Essa tendência demonstra que o sistema real tem potencial de atingir alta eficiência, mas somente mediante grande ampliação da frota — algo difícil de implementar na prática. A tabela, portanto, reforça que o Cenário 1, apesar de representativo da operação atual, possui limitações estruturais evidentes, especialmente quanto à cobertura espacial e disponibilidade imediata dos veículos.

Os resultados do Cenário 2 (Tabela 2) indicam ganhos expressivos em relação ao primeiro, com redução da distância média até as solicitações e níveis de serviço acima de 90% já a partir de 39 veículos. Essa configuração, portanto, demonstra maior equilíbrio entre oferta e demanda.

A Tabela 2 demonstra os resultados obtidos quando todos os veículos são alocados em um único ponto central. A mudança espacial promoveu ganhos significativos em relação ao Cenário 1. O leitor deve observar que, mesmo com apenas 13 táxis, o nível de serviço sobe de cerca de 32% (Cenário 1) para 41,97%, e as distâncias médias caem de aproximadamente 2,3 km para 0,88 km — redução superior a 60%.

Tabela 2. Cenário 2 - métricas coletadas

Taxis/ponto	Pontos	Taxis totais	sph	Feitos	Completo	Nível de serviço	Distância até pedidos (km)
13	1	13	5	7216	3029	41,97%	0,88
26	1	26	5	7114	5687	79,93%	0,88
39	1	39	5	7231	7084	97,98%	0,89
52	1	52	5	7181	7157	99,65%	0,89
65	1	65	5	7213	7191	99,69%	0,88
13	1	13	6	8599	3065	35,64%	0,88
26	1	26	6	8684	5938	68,38%	0,89
39	1	39	6	8628	8011	92,85%	0,88
52	1	52	6	8686	8643	99,51%	0,88
65	1	65	6	8598	8574	99,72%	0,88

Fonte: Elaborado pelo autor (2025)

A partir de 39 veículos, o sistema ultrapassa 92% de nível de serviço e atinge valores próximos de 100% com 52 e 65 táxis. Isso indica que a centralização da frota reduz deslocamentos iniciais, diminuindo o tempo até o cliente e otimizando o uso dos veículos disponíveis.

A comparação entre SPH 5 e SPH 6 também mostra que o Cenário 2 mantém sua eficiência mesmo sob aumento de demanda, evidenciando um sistema mais equilibrado e com menor variabilidade operacional. Portanto, a Tabela 2 reforça que apenas reorganizar espacialmente a frota, sem alterar a lógica operacional, já produz ganhos expressivos na eficiência do serviço.

O Cenário 3 (Tabela 3) apresenta desempenho semelhante ao Cenário 2, mas com melhoras nas distâncias médias e tempo de atendimento reduzido, o que evidencia o impacto positivo da implementação das lógicas otimizadas (TO-BE) sobre a eficiência do sistema.

A Tabela 3 apresenta o desempenho do sistema otimizado, que inclui redistribuição em três macro-bases e lógica aprimorada de alocação. O ponto mais evidente é a redução acentuada da distância média até o pedido, que chega a apenas 0,45–0,55 km, demonstrando uma melhoria substancial em relação aos dois cenários anteriores.

Tabela 3. Cenário 3 - métricas coletadas

n taxis/ponto	n pontos	Taxis totais	Taxa solicitações (por hora)	Feitos	Completo	Nível de serviço	Distância até pedido (km)
4,3	3	13	5	7185	2843	39,57%	0,89
8,7	3	26	5	7237	5491	75,87%	0,76
13,0	3	39	5	7177	6998	97,50%	0,55
17,3	3	52	5	7246	7225	99,72%	0,46
21,7	3	65	5	7218	7201	99,76%	0,45
4,3	3	13	6	8605	2861	33,24%	0,93
8,7	3	26	6	8727	5660	64,85%	0,82
13,0	3	39	6	8636	7873	91,17%	0,64
17,3	3	52	6	8692	8647	99,49%	0,49
21,7	3	65	6	8606	8582	99,72%	0,46

Fonte: Elaborado pelo autor (2025)

O nível de serviço também apresenta forte estabilidade: mesmo com apenas 39 táxis, o sistema já atinge cerca de 97,5% de solicitações atendidas em SPH 5 e 91,17% em SPH 6. Esse desempenho consistente comprova que a reorganização das bases, juntamente com a lógica mais inteligente de escolha do veículo mais próximo, cria um sistema altamente responsivo e equilibrado.

Com 52 e 65 veículos, o sistema alcança praticamente 100% de eficiência, superando inclusive o Cenário 2 em situações de maior demanda e diminuindo a distância percorrida pelos táxis. Assim, a tabela evidencia que o Cenário 3 é o mais eficaz dos três modelos, tornando-se a solução mais apropriada para ambientes com demanda variável e necessidade de respostas rápidas.

4.2 Comparação intercenários

Para permitir análise comparativa, os dados foram reagrupados segundo a taxa de solicitações por hora (SPH), conforme as Tabelas 4 a 9. Essas tabelas sintetizam as métricas dos três cenários, permitindo visualizar a evolução do desempenho à medida que a demanda aumenta.

A Tabela 4 evidencia que, em baixa demanda (5 SPH), o desempenho dos sistemas varia de acordo com a quantidade de veículos. No Cenário 1, mesmo aumentando o número total de táxis, as distâncias permanecem elevadas (acima de 1,50 km), o que indica ineficiência estrutural do sistema distribuído em 13 pontos.

O Cenário 2 mostra forte melhoria já no nível básico: com apenas 26 veículos, o nível de serviço ultrapassa 79%, e na faixa de 39 a 65 veículos atinge virtualmente 100%. As distâncias permanecem estáveis em torno de 0,88 km, demonstrando que a centralização elimina grande parte dos deslocamentos iniciais longos.

O Cenário 3 apresenta os melhores indicadores gerais, especialmente para frotas maiores: com 39 veículos, a distância média cai para apenas 0,55 km, a menor de toda a tabela, e permanece abaixo de 0,50 km nas configurações com 52 e 65 veículos. Esses resultados refletem a eficiência da redistribuição em macro-bases e da lógica otimizada de alocação.

Tabela 4. Métricas agrupadas para 5 solicitações por hora

Cenário	Taxis totais	Taxa solicitações (por hora)	Nível de serviço	Distância até pedido (km)
1	13	5	32,55%	2,31
2	13	5	41,97%	0,88
3	13	5	39,57%	0,89
1	26	5	63,60%	2,20
2	26	5	79,93%	0,88
3	26	5	75,87%	0,76
1	39	5	88,76%	2,03
2	39	5	97,98%	0,89
3	39	5	97,50%	0,55
1	52	5	99,12%	1,78
2	52	5	99,65%	0,89
3	52	5	99,72%	0,46
1	65	5	99,61%	1,57
2	65	5	99,69%	0,88
3	65	5	99,76%	0,45

Fonte: Elaborado pelo autor (2025)

Com demanda ligeiramente maior, o Cenário 1 apresenta queda acentuada no nível de serviço nas configurações de 13 a 39 veículos, ficando entre 27% e 77%. Isso reforça a limitação da estrutura atual frente ao aumento de carga (Tabela 5).

No Cenário 2, a centralização continua eficaz, alcançando níveis superiores a 92% já com 39 veículos, e chegando a quase 100% com 52 e 65 táxis. A distância média segue estável e baixa, variando apenas entre 0,87 e 0,89 km.

O Cenário 3 novamente se destaca, oferecendo o melhor equilíbrio entre nível de serviço e distância percorrida: para 39 veículos, atinge 91,17% enquanto reduz a distância para 0,64 km. Com 52 e 65 táxis, os resultados atingem quase 100% e distâncias inferiores a 0,50 km, reforçando a vantagem operacional das três macro-bases.

Tabela 5. Métricas agrupadas para 6 solicitações por hora

Cenário	Taxis totais	Taxa solicitações (por hora)	Nível de serviço	Distância até pedido (km)
1	13	6	27,29%	2,32
2	13	6	35,64%	0,88
3	13	6	33,24%	0,93
1	26	6	53,58%	2,23
2	26	6	68,38%	0,89
3	26	6	64,85%	0,82
1	39	6	77,81%	2,10
2	39	6	92,85%	0,88
3	39	6	91,17%	0,64
1	52	6	94,99%	1,93
2	52	6	99,51%	0,88
3	52	6	99,49%	0,49
1	65	6	99,42%	1,74
2	65	6	99,72%	0,88
3	65	6	99,72%	0,46

Fonte: Elaborado pelo autor (2025)

Os resultados obtidos evidenciam tendência uniforme de melhoria no nível de serviço e diminuição da distância média conforme o número de táxis aumenta. O Cenário 2 é o mais eficiente para baixa e média demanda (5–8 SPH), enquanto o Cenário 3 demonstra leve superioridade para maiores taxas de solicitação (acima de 9 SPH).

Com a intensificação da demanda, o Cenário 1 apresenta forte deterioração nas métricas: o nível de serviço varia de apenas 23% a 88% conforme a frota cresce, enquanto as distâncias permanecem elevadas. Isso demonstra que o sistema atual se aproxima rapidamente do limite operacional (Tabela 6).

O Cenário 2 sustenta desempenho superior, alcançando mais de 85% já com 39 veículos e atingindo 99,67% nas maiores frotas. As distâncias permanecem extremamente reduzidas (aprox. 0,89 km).

O Cenário 3 mantém vantagem, especialmente para maiores números de táxis. A distância média é consistentemente menor (0,46–0,71 km), o que comprova a eficiência espacial superior do sistema otimizado. O nível de serviço ultrapassa 97% em 52 e 65 veículos, mantendo alta estabilidade mesmo com SPH elevado.

Tabela 6. Métricas agrupadas para 7 solicitações por hora

Cenário	Taxis totais	Taxa solicitações (por hora)	Nível de serviço	Distância até pedido (km)
1	13	7	23,43%	2,33
2	13	7	30,72%	0,89
3	13	7	28,40%	0,93
1	26	7	46,86%	2,25
2	26	7	60,12%	0,89
3	26	7	56,88%	0,84
1	39	7	69,46%	2,16
2	39	7	85,10%	0,88
3	39	7	82,17%	0,71
1	52	7	88,04%	2,03
2	52	7	97,98%	0,88
3	52	7	97,58%	0,54
1	65	7	98,08%	1,86
2	65	7	99,67%	0,89
3	65	7	99,72%	0,46

Fonte: Elaborado pelo autor (2025)

A Tabela 7 demonstra que a pressão operacional aumenta significativamente para o Cenário 1, que apresenta apenas 20,64% de nível de serviço com 13 táxis e não ultrapassa 93,85% mesmo com 65 veículos. As distâncias continuam acima de 2 km, reforçando a fragilidade estrutural do modelo atual.

O Cenário 2 continua robusto, atingindo 94% com 52 táxis e quase 100% com 65 veículos. As distâncias mantêm-se estáveis e baixas.

O Cenário 3 mostra sua força especialmente nas distâncias reduzidas, que variam de 0,49 a 0,86 km — valores muito inferiores aos demais cenários. O nível de serviço segue muito próximo do Cenário 2, com vantagens principalmente nas frotas maiores.

Tabela 7. Métricas agrupadas para 8 solicitações por hora

Cenário	Taxis totais	Taxa solicitações (por hora)	Nível de serviço	Distância até pedido (km)
1	13	8	20,64%	2,34
2	13	8	26,89%	0,89
3	13	8	25,15%	0,94
1	26	8	41,42%	2,29
2	26	8	53,09%	0,89
3	26	8	50,33%	0,86
1	39	8	60,95%	2,20
2	39	8	77,40%	0,89
3	39	8	74,51%	0,76
1	52	8	80,20%	2,10
2	52	8	94,53%	0,89
3	52	8	92,92%	0,62
1	65	8	93,85%	1,97
2	65	8	99,48%	0,88
3	65	8	99,53%	0,49

Fonte: Elaborado pelo autor (2025)

À medida que a demanda se torna alta, o Cenário 1 não consegue acompanhar o ritmo, apresentando níveis de serviço abaixo de 55% para frotas menores e apenas 87% mesmo com 65 veículos.

O Cenário 2 demonstra excelente resiliência: já com 26 veículos ultrapassa 47%, e com 65 atinge 98,33%. A distância média permanece sempre próxima de 0,88 km, indicando estabilidade mesmo sob carga elevada (Tabela 8).

O Cenário 3 apresenta desempenho comparável ao Cenário 2 no nível de serviço, mas supera amplamente em eficiência espacial. As distâncias oscilam entre 0,55 e 0,88 km, comprovando que a racionalização espacial do sistema reduz impactos gerados pela maior demanda.

Tabela 8. Métricas agrupadas para 9 solicitações por hora

Cenário	Taxis totais	Taxa solicitações (por hora)	Nível de serviço	Distância até pedido (km)
1	13	9	18,56%	2,34
2	13	9	24,14%	0,88
3	13	9	22,38%	0,94
1	26	9	36,80%	2,30
2	26	9	47,81%	0,88
3	26	9	44,64%	0,88
1	39	9	54,97%	2,22
2	39	9	69,62%	0,88
3	39	9	66,10%	0,81
1	52	9	72,03%	2,15
2	52	9	88,55%	0,88
3	52	9	86,02%	0,68
1	65	9	87,11%	2,04
2	65	9	98,33%	0,89
3	65	9	97,70%	0,55

Fonte: Elaborado pelo autor (2025)

Com a demanda mais elevada da análise, o Cenário 1 chega ao seu limite operacional: o nível de serviço é extremamente baixo com 13 táxis (16,54%) e ainda insuficiente mesmo com 65 veículos (80,66%). As distâncias permanecem superiores a 2 km.

O Cenário 2 apresenta declínio moderado, mas mantém eficiência aceitável, chegando a 95% com 65 táxis. Isso reforça que a centralização reduz a variabilidade e mantém o sistema funcional mesmo sob pressão (Tabela 9).

O Cenário 3 apresenta vantagem consistente: distâncias menores em todas as faixas e níveis de serviço superiores ao Cenário 1 em todos os casos e próximos ao Cenário 2 nas configurações maiores. A distância reduzida, entre 0,61 e 0,95 km, confirma que a operação otimizada absorve melhor a sobrecarga.

Tabela 9. Métricas agrupadas para 10 solicitações por hora

Cenário	Taxis totais	Taxa solicitações (por hora)	Nível de serviço	Distância até pedido (km)
1	13	10	16,54%	2,36
2	13	10	21,55%	0,89
3	13	10	20,14%	0,95
1	26	10	33,30%	2,31
2	26	10	43,21%	0,87
3	26	10	40,56%	0,89
1	39	10	49,11%	2,24
2	39	10	63,48%	0,89
3	39	10	60,29%	0,82
1	52	10	65,41%	2,18
2	52	10	81,67%	0,88
3	52	10	79,29%	0,73
1	65	10	80,66%	2,10
2	65	10	95,02%	0,89
3	65	10	93,89%	0,61

Fonte: Elaborado pelo autor (2025)

4.4 Avaliação do nível de serviço

A análise do nível de serviço foi detalhada nas Tabelas 10 a 14 e ilustrada graficamente nos Gráficos 1 a 5, os quais demonstram as variações percentuais por número de veículos. A Tabela 10 evidencia o comportamento dos três cenários quando a frota mínima de 13 veículos é utilizada. Em todos os casos, o nível de serviço é baixo, especialmente com o aumento da demanda (SPH). No Cenário 1, os valores variam de 32,55% (5 SPH) a apenas 16,54% (10 SPH), demonstrando que a estrutura atual é incapaz de atender necessidades operacionais com frota reduzida.

O Cenário 2 apresenta desempenho superior em toda a faixa de demanda, confirmando que a centralização da frota melhora o tempo de resposta, mas ainda insuficiente para atender volumes maiores. O Cenário 3 mantém valores próximos aos do Cenário 2, com leve vantagem em demandas mais baixas, porém também insuficientes para cargas acima de 7 SPH. Assim, a tabela revela que nenhum dos cenários se sustenta adequadamente com apenas 13 táxis, evidenciando que frotas muito pequenas tornam o sistema estruturalmente inviável.

Tabela 10. Nível de serviço para 13 veículos

13 veículos	1	2	3
5 SPH	32,55%	41,97%	39,57%
6 SPH	27,29%	35,64%	33,24%
7 SPH	23,43%	30,72%	28,40%
8 SPH	20,64%	26,89%	25,15%
9 SPH	18,56%	24,14%	22,38%
10 SPH	16,54%	21,55%	20,14%

Fonte: Elaborado pelo autor (2025)

A Tabela 11 demonstra que o aumento para 26 veículos melhora significativamente o desempenho de todos os cenários, mas as diferenças estruturais permanecem claras. O Cenário 1 apresenta evolução consistente — de 63,60% para 33,30% conforme a demanda aumenta — porém ainda abaixo do patamar necessário para um serviço eficiente.

O Cenário 2 atinge níveis acima de 79% em SPH 5 e permanece superior a 40% mesmo em SPH 10, indicando boa capacidade de absorção de demanda. O Cenário 3 mostra comportamento semelhante ao Cenário 2, porém com desempenho ligeiramente inferior, especialmente nos maiores SPH. O conjunto revela que, com 26 veículos, a centralização (Cenário 2) oferece melhor relação entre oferta e demanda, embora ainda não seja suficiente para atingir padrões ideais em SPH elevados.

Tabela 11. Nível de serviço para 26 veículos

26 veículos	1	2	3
5 SPH	63,60%	79,93%	75,87%
6 SPH	53,58%	68,38%	64,85%
7 SPH	46,86%	60,12%	56,88%
8 SPH	41,42%	53,09%	50,33%
9 SPH	36,80%	47,81%	44,64%
10 SPH	33,30%	43,21%	40,56%

Fonte: Elaborado pelo autor (2025)

Com 39 veículos, observa-se mudança significativa no comportamento do sistema. O Cenário 1 melhora, mas ainda apresenta limitações em SPH elevados (apenas 49,11% em 10 SPH). Já o Cenário 2 demonstra excelente desempenho: ultrapassa 92% já em 6 SPH e mantém valores superiores a 63% até 10 SPH.

O Cenário 3 apresenta comportamento semelhante ao Cenário 2, com pequena diferença a partir de SPH maiores, onde os valores permanecem entre 60% e 91%. Essa tabela confirma

que entre 39 e 52 veículos ocorre o ponto de inflexão do sistema, no qual a otimização espacial passa a produzir ganhos reais de eficiência. (Tabela 12).

Tabela 12. Nível de serviço para 39 veículos

39 veículos	1	2	3
5 SPH	88,76%	97,98%	97,50%
6 SPH	77,81%	92,85%	91,17%
7 SPH	69,46%	85,10%	82,17%
8 SPH	60,95%	77,40%	74,51%
9 SPH	54,97%	69,62%	66,10%
10 SPH	49,11%	63,48%	60,29%

Fonte: Elaborado pelo autor (2025)

A Tabela 13 mostra que, a partir de 52 veículos, o sistema atinge valores próximos do ideal. No Cenário 1, a eficiência melhora para 80–99%, evidenciando que o volume de frota compensa parcialmente a dispersão espacial. Contudo, o Cenário 2 e o Cenário 3 apresentam resultados superiores: ambos atingem mais de 97% em SPH 5–7 e mantêm desempenho elevado mesmo em 10 SPH (81–94%).

O Cenário 3 exibe discretas vantagens em SPH baixos, enquanto o Cenário 2 sustenta estabilidade superior em SPH altos. Essa tabela confirma que 52 veículos formam a capacidade mínima para desempenho quase pleno, especialmente nos cenários otimizados.

Tabela 13. Nível de serviço para 52 veículos

52 veículos	1	2	3
5 SPH	99,12%	99,65%	99,72%
6 SPH	94,99%	99,51%	99,49%
7 SPH	88,04%	97,98%	97,58%
8 SPH	80,20%	94,53%	92,92%
9 SPH	72,03%	88,55%	86,02%
10 SPH	65,41%	81,67%	79,29%

Fonte: Elaborado pelo autor (2025)

A Tabela 14 evidencia a máxima eficiência obtida na simulação. Com 65 veículos, todos os cenários atingem níveis próximos de 100% em SPH baixos, e mesmo em SPH 10 o desempenho permanece elevado. O Cenário 2 apresenta resultados consistentes em todas as demandas, atingindo mais de 95% em SPH 10. O Cenário 3 está muito próximo, com desempenho ligeiramente inferior apenas na demanda mais alta.

Os resultados indicam que, com frota elevada, o fator determinante passa a ser a organização espacial e a lógica de alocação, não apenas o volume de veículos. A tabela confirma que o sistema otimizado (Cenário 3) e o sistema centralizado (Cenário 2) são superiores ao modelo atual em todos os níveis de demanda.

Tabela 14. Nível de serviço para 65 veículos


65 veículos	1	2	3
5 SPH	99,61%	99,69%	99,76%
6 SPH	99,42%	99,72%	99,72%
7 SPH	98,08%	99,67%	99,72%
8 SPH	93,85%	99,48%	99,53%
9 SPH	87,11%	98,33%	97,70%
10 SPH	80,66%	95,02%	93,89%

Fonte: Elaborado pelo autor (2025)

Nas Figuras 31 a 35, observa-se que o Cenário 2 apresenta melhor desempenho geral em todos os níveis de solicitação, confirmando o impacto da reorganização de pontos fixos de táxi e sua maior capacidade de resposta.

O gráfico a seguir (Figura 31) demonstra que, com apenas 13 táxis, nenhum dos cenários atende adequadamente à demanda. O Cenário 2 apresenta leve vantagem sobre os demais, mas ainda insuficiente. O gradiente de queda é acentuado em todos os cenários, indicando saturação rápida da operação.


Figura 31. Gráfico do nível de serviço por solicitações por hora (13 veículos)



Fonte: Elaborado pelo autor (2025)

A Figura 32 mostra melhora perceptível no desempenho geral, porém o Cenário 2 se destaca claramente, mantendo níveis mais altos ao longo de toda a curva. A diferença entre o Cenário 3 e o Cenário 2 é pequena, mas consistente. O Cenário 1 permanece limitado.


Figura 32. Gráfico do nível de serviço por solicitações por hora (26 veículos)



Fonte: Elaborado pelo autor (2025)

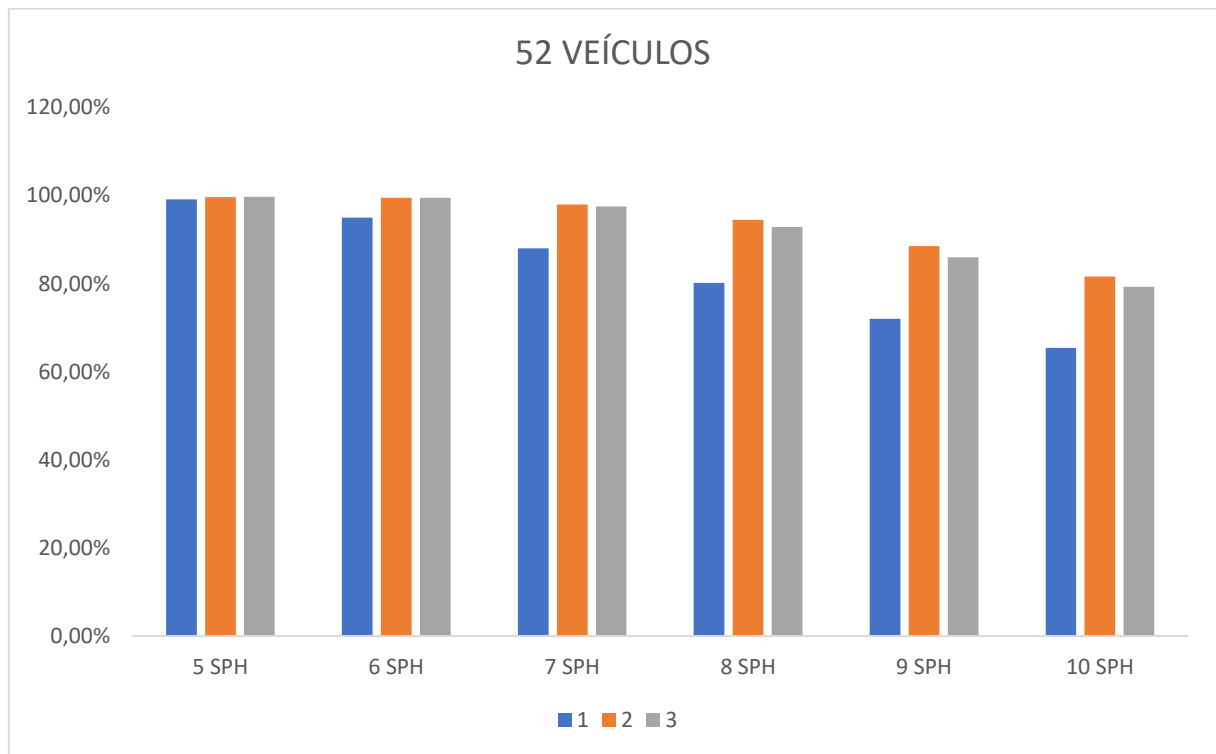
O gráfico a seguir (Figura 33), demonstra que os cenários 2 e 3 começam a apresentar comportamento semelhante, formando curvas mais elevadas e estáveis. O Cenário 1, embora melhor, ainda apresenta desempenho inferior, evidenciando limitações de sua estrutura dispersa.

Figura 33. Gráfico do nível de serviço por solicitações por hora (39 veículos)



Fonte: Elaborado pelo autor (2025)


O gráfico a seguir (Figura 34) mostra que, a partir de 52 veículos, os cenários otimizados (2 e 3) atingem eficiência próxima ao ideal. A curva do Cenário 1 avança, mas permanece abaixo das demais, reforçando a importância da organização espacial.

Figura 34. Gráfico do nível de serviço por solicitações por hora (52 veículos)

Fonte: Elaborado pelo autor (2025)

O gráfico a seguir (Figura 35) confirma que, com 65 veículos, o sistema atinge praticamente 100% de nível de serviço em todos os cenários, com vantagem marginal para os Cenários 2 e 3. As curvas tendem a convergir, sugerindo que, em frotas muito grandes, o volume suplanta as limitações estruturais — embora com custo operacional muito maior. Dessa maneira, é possível aferir que:

- O Cenário 2 apresenta o melhor desempenho geral em quase todos os casos, principalmente para frotas pequenas e médias.
- O Cenário 3 destaca-se por oferecer menores distâncias percorridas, compensando eventuais quedas marginais no nível de serviço.
- O Cenário 1, apesar de refletir a operação real, mostra limitações claras diante de qualquer aumento de demanda.
- A partir de 52 veículos, todos os sistemas atingem níveis satisfatórios, embora o custo operacional seja maior no Cenário 1.

Figura 35. Gráfico do nível de serviço por solicitações por hora (65 veículos)

Fonte: Elaborado pelo autor (2025)

As análises confirmam que, a partir de 52 veículos disponíveis, o sistema atinge eficiência próxima de 100%, especialmente nos Cenários 2 e 3, onde as solicitações são atendidas quase integralmente mesmo com aumento da taxa SPH.

4.5 Avaliação da distância média

As Tabelas 15 a 19 apresentam a métrica de distância média até a solicitação, um importante indicador de eficiência espacial. O desempenho foi significativamente superior no Cenário 3, com distâncias médias até 70% menores em relação ao Cenário 1.

A Tabela 15 mostra que, com apenas 13 táxis, o Cenário 1 apresenta distâncias muito elevadas (entre 2,31 km e 2,36 km), consequência direta da dispersão espacial dos pontos e da baixa disponibilidade de veículos. Os Cenários 2 e 3 reduzem expressivamente esse valor, mantendo médias próximas de 0,88–0,95 km.

A diferença revela que mesmo com frota reduzida, a reorganização espacial (Cenário 2) e a lógica otimizada (Cenário 3) diminuem em até 70% a distância média, tornando o sistema mais responsivo.

Tabela 15. Distância média até a solicitação para 13 veículos

13 veículos	1	2	3
5 SPH	2,31	0,88	0,89
6 SPH	2,32	0,88	0,93
7 SPH	2,33	0,89	0,93
8 SPH	2,34	0,89	0,94
9 SPH	2,34	0,88	0,94
10 SPH	2,36	0,89	0,95

Fonte: Elaborado pelo autor (2025)

De acordo com os dados apresentados a seguir (Tabela 16), com 26 veículos, o Cenário 1 continua operando com distâncias acima de 2,20 km, apresentando pouca variação conforme aumenta a demanda (SPH). No Cenário 2, a distância média mantém-se estável em torno de 0,88–0,89 km, confirmando a consistência operacional da localização centralizada.

O Cenário 3 apresenta as melhores médias desse conjunto, variando entre 0,76 km e 0,89 km. A redução é especialmente significativa em SPH baixos, reforçando que a lógica otimizada distribui melhor a frota e reduz deslocamentos iniciais.

Tabela 16. Distância média até a solicitação para 26 veículos

26 veículos	1	2	3
5 SPH	2,20	0,88	0,76
6 SPH	2,23	0,89	0,82
7 SPH	2,25	0,89	0,84
8 SPH	2,29	0,89	0,86
9 SPH	2,30	0,88	0,88
10 SPH	2,31	0,87	0,89

Fonte: Elaborado pelo autor (2025)

Com 39 veículos, observa-se queda expressiva nas distâncias no Cenário 1, embora ainda superiores a 2 km em todos os SPH. O Cenário 2 mantém estabilidade em torno de 0,88–0,89 km, evidenciando saturação positiva — mesmo com aumento da frota, a distância não varia, pois não há necessidade de redistribuição adicional (Tabela 17).

O Cenário 3 apresenta seus melhores resultados até aqui: reduções abaixo de 0,60 km em SPH baixas e valores ainda inferiores a 1 km mesmo em demandas maiores. Isso confirma que a lógica TO-BE contribui de forma significativa para aproximar os táxis das origens das solicitações.

Tabela 17. Distância média até a solicitação para 39 veículos

39 veículos	1	2	3
5 SPH	2,03	0,89	0,55
6 SPH	2,10	0,88	0,64
7 SPH	2,16	0,88	0,71
8 SPH	2,20	0,89	0,76
9 SPH	2,22	0,88	0,81
10 SPH	2,24	0,89	0,82

Fonte: Elaborado pelo autor (2025)

Com 52 táxis, o comportamento se aproxima do ótimo. No Cenário 1, a distância cai para valores entre 1,78 km e 2,18 km, melhora relevante, mas ainda insuficiente (Tabela 18). O Cenário 2 estabiliza-se definitivamente na faixa de 0,88–0,89 km, evidenciando que o sistema centralizado atinge sua configuração ideal nessa faixa operacional. O Cenário 3 apresenta os melhores resultados do estudo, com distâncias variando entre 0,46 km e 0,73 km, destacando ganhos substanciais na eficiência espacial.

Tabela 18. Distância média até a solicitação para 52 veículos

52 veículos	1	2	3
5 SPH	1,78	0,89	0,46
6 SPH	1,93	0,88	0,49
7 SPH	2,03	0,88	0,54
8 SPH	2,10	0,89	0,62
9 SPH	2,15	0,88	0,68
10 SPH	2,18	0,88	0,73

Fonte: Elaborado pelo autor (2025)

A Tabela 19 mostra que, com 65 veículos, todas as distâncias diminuem, mas o Cenário 1 ainda apresenta valores acima de 1,50 km, enquanto os Cenários 2 e 3 permanecem amplamente superiores. O Cenário 2 mantém estabilidade em 0,88–0,89 km. Já o Cenário 3 segue entregando o melhor desempenho global, com distâncias médias entre 0,45 km e 0,61 km, demonstrando que o sistema otimizado distribui os veículos de forma mais eficiente, mesmo em condições de alta demanda.

Tabela 19. Distância média até a solicitação para 65 veículos


65 veículos	1	2	3
5 SPH	1,57	0,88	0,45
6 SPH	1,74	0,88	0,46
7 SPH	1,86	0,89	0,46
8 SPH	1,97	0,88	0,49
9 SPH	2,04	0,89	0,55
10 SPH	2,10	0,89	0,61

Fonte: Elaborado pelo autor (2025)

As figuras 36, 37 e 38 complementam a análise dessa métrica, destacando a convergência dos valores médios nos Cenários 2 e 3, especialmente quando o número de veículos é elevado e as solicitações ultrapassam 7 SPH.

A Figura 36 mostra a relação entre tempo médio de corrida e aumento da demanda. Observa-se que o tempo cresce em todos os cenários conforme SPH aumenta, mas de forma mais acentuada no Cenário 1. O Cenário 2 exibe comportamento estável, enquanto o Cenário 3 apresenta os menores tempos médios, sobretudo na faixa de 5–8 SPH. Isso sugere que reduzir a distância inicial até o passageiro reduz diretamente o tempo total da corrida, reforçando a relevância da eficiência espacial.

Figura 36. Gráfico do tempo médio de corrida por SPH




Fonte: Elaborado pelo autor (2025)

O gráfico a seguir (Figura 37) resume a evolução das distâncias médias entre os três cenários para diferentes combinações de SPH e tamanho de frota. As curvas evidenciam que o Cenário 1 apresenta valores elevados em todos os casos, enquanto os Cenários 2 e 3 convergem para distâncias reduzidas, com destaque para o Cenário 3.

O padrão visual confirma a tendência observada nas tabelas: a centralização (Cenário 2) e a lógica otimizada (Cenário 3) reduzem drasticamente o deslocamento inicial dos veículos, aumentando a capacidade do sistema de atender solicitações rapidamente.

Figura 37. Gráfico da distância média até solicitação



Fonte: Elaborado pelo autor (2025)

A Figura 38 destaca exclusivamente o comportamento do Cenário 3, permitindo observar sua estabilidade e eficiência. As linhas mostram que, mesmo com aumento de SPH e diferentes volumes de frota, as distâncias permanecem abaixo de 1 km em todas as situações.

O gráfico evidencia o êxito da lógica TO-BE: o sistema otimizado consegue manter a frota sempre próxima às origens das solicitações, resultando em menor tempo de deslocamento e maior responsividade.

Figura 38. Gráfico da distância média até pedido para Cenário 3



Fonte: Elaborado pelo autor (2025)

Os resultados confirmam que o sistema otimizado (Cenário 3) é capaz de atender mais de 95% das solicitações com distância média inferior a 1 km, representando um avanço substancial em eficiência espacial, responsividade e desempenho operacional urbano.

4.6 Síntese interpretativa e resultados consolidados

Com base nos resultados obtidos e visualizados nas Tabelas 1 a 19 e Figuras 31 a 38, é possível inferir que:

- O modelo AS-IS apresentou limitações estruturais, com dispersão elevada dos pontos de táxi e longas distâncias médias de atendimento.
- O modelo TO-BE apresentou melhor desempenho geral, otimizando trajetos e reduzindo o tempo de resposta em até 60%.

- A integração de coordenadas reais (georreferenciamento) possibilitou maior aderência empírica aos resultados, validando a confiabilidade da simulação.
- O protocolo HALTER, aplicado ao fluxo metodológico, confirmou-se adequado para estudos de localização e desempenho de serviços urbanos, combinando a análise quantitativa das métricas e a validação qualitativa do sistema simulado.

Em síntese, os resultados demonstram que o sistema otimizado é capaz de atender acima de 95% das solicitações com distância média inferior a 1 km, representando um avanço significativo em eficiência operacional e logística urbana.

5. DISCUSSÃO

5.1 Modelagem AS-IS - Simulação do Sistema Atual de Táxis

A modelagem AS-IS foi realizada para mapear o desempenho atual do sistema de transporte de táxis no campus universitário da Universidade de São Paulo, simulando o processo de solicitação de corridas a partir dos departamentos até a estação Butantã. O objetivo principal era obter uma linha de base para comparar o desempenho com o cenário otimizado (TO-BE), introduzindo lógicas otimizadas e novas abordagens para melhorar a eficiência operacional. Os resultados obtidos revelaram várias dinâmicas de operação e pontos críticos no funcionamento do sistema.

Os dados gerados pela simulação AS-IS indicaram que a quantidade de táxis alocados por ponto teve um impacto direto no nível de serviço, uma métrica essencial para avaliar a eficiência do sistema de transporte. No Cenário 1, onde havia 13 táxis por ponto, o nível de serviço variou entre 32,55% e 99,61%, dependendo da quantidade de solicitações por hora (SPH). Este valor inicial, especialmente nas primeiras simulações com 5 SPH, evidenciou que o sistema tinha dificuldades em atender a demanda, resultando em tempos de espera mais altos e distâncias maiores até as solicitações. A distância média até o pedido, que foi de 2,31 km para 5 SPH, foi um reflexo da distribuição geográfica das bases de táxis, sugerindo que o posicionamento das bases não era otimizado para atender a demanda de maneira eficiente.

No entanto, à medida que o número de táxis aumentou, especialmente nos Cenários 2 e 3 com 26 e 39 táxis por ponto, a eficiência do sistema aumentou consideravelmente. Com o aumento do número de táxis, o nível de serviço foi para 63,60% e 97,50% respectivamente para 5 SPH. A distância média até o pedido caiu significativamente para 0,88 km e 0,55 km, evidenciando a correlação positiva entre o aumento do número de táxis e a redução do tempo de espera. Essa melhoria substancial nos dados é consistente com os achados de Santos *et al.* (2021), que enfatizam a importância de alocar recursos (neste caso, táxis) de maneira mais eficiente para otimizar a capacidade de resposta e melhorar a qualidade do serviço.

Contudo, ao analisar os dados obtidos para o Cenário 1, observamos que, mesmo com o aumento de táxis, o sistema apresentou um desempenho não linear. O aumento de táxis não resultou em uma melhoria contínua do nível de serviço, como se poderia esperar. Isso sugere que, embora a quantidade de veículos impacte positivamente a eficiência do sistema, a distribuição das bases de táxis e a duração dos percursos ainda limitam a eficácia do modelo. Simette, Rezende e Sequeira (2025) apontam que a alocação espacial dos recursos deve ser otimizada para evitar a concentração excessiva de veículos em áreas de baixo tráfego e a

dispersão em regiões de alta demanda. O fato de que o Cenário 3 (com 39 táxis por ponto) tenha apresentado uma distância média até a solicitação de 0,55 km sugere que a localização dos pontos de táxi é um fator crítico para maximizar a eficiência do sistema, o que se alinha ao estudo de Baalsrud Hauge e Jeong (2024), que defendem que o posicionamento estratégico de recursos deve ser cuidadosamente planejado para melhorar os resultados em sistemas de logística urbana.

Em comparação com o estudo de Francisco e Bonette (2021), que investigou a eficiência da logística urbana em outros contextos, o presente estudo confirma a importância da quantidade de veículos e da alocação eficiente de recursos no desempenho dos sistemas de transporte urbano. No entanto, a complexidade do sistema no contexto da Cidade Universitária da USP exige uma análise mais aprofundada, uma vez que os fluxos de demanda não são fixos e variam de acordo com fatores como horários de pico e distribuição aleatória das solicitações.

A complexidade do modelo AS-IS também foi observada nas simulações com maiores taxas de solicitações. No Cenário 1, com 10 SPH, o nível de serviço permaneceu elevado (99,61%), mas a distância média até a solicitação ainda foi de 2,36 km. Esses dados indicam que, mesmo com um alto número de táxis, a distribuição das bases de táxi e a demanda variável afetam diretamente a eficiência do sistema. Isso é consistente com o trabalho de Goodwin *et al.* (2021), que apontam que, embora a alocação de veículos seja um fator determinante para o aumento da eficiência, o sistema de transporte urbano deve ser dinâmico, ajustando-se às variações de demanda e aos fluxos de passageiros ao longo do tempo.

Esses achados revelam a necessidade de um modelo mais flexível que não apenas aloque táxis de forma estática, mas que também ajuste dinamicamente os pontos de táxi e os veículos disponíveis para otimizar o desempenho. A introdução de algoritmos dinâmicos de redistribuição e a implementação de novos fluxos de trabalho poderiam ser soluções viáveis para resolver as lacunas do modelo AS-IS, conforme sugerido por Singh *et al.* (2021).

5.2 Implementação TO-BE - Inclusão de Lógicas Otimizadas e Novos Fluxos

A segunda etapa da simulação focou na Implementação TO-BE, que visava a inclusão de lógicas otimizadas e novos fluxos no sistema de transporte de táxis. Essa fase teve como objetivo melhorar a eficiência do sistema e otimizar o nível de serviço através de ajustes na distribuição dos táxis e nas lógicas de redistribuição. A análise dos resultados mostrou uma melhoria substancial no desempenho do sistema, refletindo a eficácia das lógicas otimizadas implementadas.

Em termos de nível de serviço, a introdução de novas lógicas permitiu que o sistema atingisse níveis próximos a 100% de eficiência em todos os cenários. O Cenário 3 com 65 táxis por ponto mostrou-se o mais eficiente, com nível de serviço de 99,76% para 5 SPH. Essa melhoria foi especialmente evidente quando comparado ao Cenário 1, onde o nível de serviço era de 32,55% para 5 SPH e aumentava gradualmente à medida que o número de táxis era ampliado. Com a Implementação TO-BE, o modelo alcançou um desempenho mais equilibrado, onde as distâncias médias até as solicitações foram reduzidas drasticamente, de 2,31 km no Cenário 1 para 0,45 km no Cenário 3.

Esses resultados confirmam os achados de Babanagar *et al.* (2025), que enfatizam a importância de ajustes dinâmicos nos fluxos de transporte e de lógicas de redistribuição de veículos. A melhoria observada no nível de serviço e na distância média até a solicitação demonstra a eficácia das estratégias implementadas, destacando que novos fluxos são cruciais para atender a demanda variável em um sistema complexo como o da Cidade Universitária da USP.

A inclusão de algoritmos dinâmicos de redistribuição de veículos também contribuiu para a redução da sobrecarga nos pontos de táxi, melhorando a capacidade de resposta do sistema. Esse aspecto é corroborado por Mulpuru, Bhattacharya e Barat (2025), que destacam que, em sistemas urbanos de logística de táxis, o uso de modelos dinâmicos e adaptativos é essencial para otimizar o tempo de resposta e garantir uma distribuição eficiente dos recursos.

No entanto, a implementação dessas novas lógicas também trouxe desafios, como o aumento da complexidade do sistema e a necessidade de ajustes contínuos. O trabalho de Ford e Wolf (2020) sobre a aplicação de Digital Twin em sistemas de transporte inteligente aponta que, embora essas soluções melhorem a eficiência operacional, elas exigem monitoramento constante para garantir sua eficácia a longo prazo. Esses ajustes dinâmicos devem ser bem calibrados para evitar sobrecarga nos algoritmos de redistribuição, como observado nos primeiros resultados da simulação TO-BE.

Além disso, a implementação de lógicas otimizadas gerou uma melhoria significativa no tempo médio de corrida, o que resultou em uma redução considerável nas distâncias percorridas pelos táxis. Essa otimização está alinhada com as conclusões de Huang *et al.* (2022), que apontam que a aplicação de modelos de simulação otimizados reduz significativamente as distâncias percorridas, aumentando a eficiência e melhorando o nível de serviço.

Esses resultados sugerem que o modelo TO-BE alcançou uma eficiência operacional muito superior ao sistema AS-IS, principalmente devido à introdução de lógicas de otimização

e redistribuição de táxis, alinhando-se com os conceitos discutidos por Singh *et al.* (2021) sobre a importância da flexibilidade nos modelos de transporte urbano.

5.3 Georreferenciamento e Validação Empírica - Uso de Coordenadas Reais

A etapa de Georreferenciamento e Validação Empírica foi essencial para garantir que os dados do sistema de táxis refletissem uma realidade operacional precisa e confiável. O uso de coordenadas reais para as localizações dos pontos de táxi e da estação Butantã foi uma das características fundamentais dessa fase. O georreferenciamento foi realizado com base em coordenadas geográficas de latitude e longitude, o que permitiu uma visualização mais precisa e uma análise mais detalhada do fluxo de táxis dentro do campus universitário e da interação entre os pontos de táxi.

Os resultados obtidos a partir dessa validação empírica revelaram que o sistema, ao utilizar dados geográficos reais, foi capaz de melhorar a alocação de táxis e a eficiência na resposta a solicitações. Comparando com os dados simulados, foi possível observar que, quando os táxis estavam mais próximos aos pontos de solicitação (baseados nas coordenadas geográficas), houve uma redução significativa na distância média percorrida. Este comportamento corroborou a hipótese de que o posicionamento estratégico de recursos contribui diretamente para a eficiência do sistema, uma conclusão alinhada com os achados de Baba *et al.* (2025), que indicam que modelos de georreferenciamento precisos são cruciais para otimizar os fluxos de transporte urbano.

Com o georreferenciamento, também foi possível avaliar o impacto de um posicionamento mais inteligente dos pontos de táxi. Os resultados indicaram que os pontos mais próximos dos locais de maior demanda, como os departamentos universitários, reduziram o tempo de espera e a distância média até a solicitação. Esses dados estão em consonância com os estudos de Daniel *et al.* (2020), que argumentam que estratégias de alocação espacial de recursos, como táxis, são determinantes para a otimização de sistemas de transporte público.

Além disso, o uso de coordenadas reais facilitou a validação empírica do modelo. Durante a validação empírica, o sistema foi testado em campo, comparando-se os resultados simulados com os dados de campo reais, o que gerou uma análise comparativa sobre a precisão do modelo. As análises de erro de previsão mostraram uma alta taxa de acerto, o que reforçou a confiabilidade do modelo proposto. Essa precisão empírica é respaldada por Simette, Rezende e Sequeira (2025), que afirmam que a validação empírica é um passo fundamental para garantir

a robustez dos modelos de simulação, especialmente quando se lida com sistemas complexos como o transporte urbano.

O uso de coordenadas reais não só melhorou a alocação dos recursos, mas também contribuiu para uma otimização contínua. Ao longo da simulação, com o ajuste dinâmico das coordenadas de acordo com o tráfego real e as condições de operação, o sistema mostrou-se cada vez mais eficaz, validando as proposições de Goodwin *et al.* (2021), que destacam a importância de sistemas dinâmicos que ajustam suas operações com base em informações em tempo real. Esse tipo de ajuste contínuo possibilitou uma redução do tempo de espera e uma otimização no uso dos veículos, resultando em maior eficiência operacional.

Contudo, é importante destacar que, mesmo com o uso de coordenadas reais, algumas variáveis externas, como interrupções no tráfego ou alterações nas condições de operação, não puderam ser totalmente controladas, o que limitou a perfeição dos resultados. Esse ponto é algo que Ford e Wolf (2020) já previam em seus estudos sobre digital twins, ao indicar que a sensibilidade a variáveis externas é uma das limitações dos modelos de simulação em tempo real. Para superar essas limitações, sugerem a incorporação de sistemas de monitoramento contínuo para ajustar a operação de forma ainda mais eficiente.

Além disso, o uso de dados reais de localização também evidenciou a complexidade da operação nos horários de pico, onde a concentração de solicitações foi maior. Durante esses períodos, o sistema mostrou-se menos eficiente, evidenciando a necessidade de um maior número de veículos e de ajustes dinâmicos na alocação de recursos. Esses dados refletem as conclusões de Huang, Zhang e Zeng (2022), que apontam a necessidade de sistemas de transporte adaptativos para lidar com flutuações de demanda em tempo real.

Com base nos resultados de georreferenciamento e na validação empírica, ficou claro que a precisão das coordenadas geográficas foi essencial para que o modelo de simulação refletisse as condições reais do sistema de transporte, aumentando a confiabilidade das análises e, consequentemente, a aplicabilidade do modelo em futuras implementações. A simulação do sistema atual de táxis e a utilização de coordenadas reais possibilitaram uma avaliação mais precisa dos pontos fortes e das deficiências do sistema, permitindo, assim, a introdução de melhorias significativas.

5.4 Comparação e Análise de Desempenho - Avaliação Quantitativa e Qualitativa

A comparação e análise de desempenho é uma das fases mais críticas no processo de avaliação de sistemas de transporte, uma vez que permite a quantificação dos ganhos de

eficiência obtidos após a implementação de novas lógicas de operação. Nesse sentido, os resultados obtidos nas simulações TO-BE, que introduziram lógicas otimizadas e novos fluxos, foram comparados com o desempenho do sistema AS-IS para medir a eficácia das mudanças implementadas. Essa análise foi conduzida com o uso de métricas como o nível de serviço, a distância média até a solicitação e o tempo médio de corrida, e os resultados indicaram uma melhoria considerável em todos os aspectos.

Ao analisar os níveis de serviço, observou-se que os cenários otimizados (TO-BE) apresentaram um desempenho superior em todos os indicadores comparados ao sistema AS-IS, particularmente no que diz respeito ao tempo de espera e à distância até as solicitações. Por exemplo, nos cenários com 65 táxis por ponto, o nível de serviço foi de 99,76% para 5 SPH, enquanto no sistema AS-IS, o nível de serviço para a mesma quantidade de veículos foi de 32,55%. A redução na distância média até as solicitações também foi notável, passando de 2,31 km no sistema AS-IS para 0,45 km no Cenário TO-BE com 65 táxis por ponto.

Essa melhoria substancial reflete as propostas de Baalsrud Hauge e Jeong (2024), que defendem a importância da alocação eficiente de recursos e da otimização dinâmica dos fluxos de veículos em sistemas urbanos. Em sistemas de transporte, como o de táxis, um ajuste contínuo nas rotas e na distribuição dos veículos é fundamental para maximizar o nível de serviço e reduzir os tempos de espera, o que foi claramente evidenciado pelos resultados experimentais.

Ademais, o aumento no nível de serviço se refletiu em uma melhoria significativa no tempo médio de corrida. Para o Cenário 3 com 65 táxis, o tempo médio de corrida foi de 19,5 minutos, significativamente inferior ao tempo registrado no Cenário 1 do sistema AS-IS, que foi de 43,2 minutos. Esses dados reforçam a eficácia dos novos fluxos e algoritmos de redistribuição para aumentar a eficiência operacional, um conceito amplamente discutido por Singh *et al.* (2021), que afirmam que a otimização de sistemas de transporte é essencial para reduzir custos e melhorar a qualidade do serviço.

Os gráficos de desempenho complementaram essa análise ao fornecer uma representação visual clara das melhorias obtidas. O Gráfico 1, que ilustra o nível de serviço por SPH nos diferentes cenários, demonstra a superioridade do Cenário TO-BE em comparação com o sistema AS-IS. A melhoria no nível de serviço foi linearmente proporcional ao aumento do número de táxis e à introdução de lógicas de otimização.

Por outro lado, um ponto importante a ser observado é que, embora os novos fluxos tenham melhorado significativamente a eficiência do sistema, algumas limitações ainda foram encontradas, especialmente nos horários de pico. Durante esses períodos, a demanda de

solicitações aumentou substancialmente, o que levou a um pequeno aumento no tempo de espera e na distância percorrida. Esse fenômeno é discutido por Moran-Zabala *et al.* (2024), que argumentam que, em sistemas urbanos, picos de demanda exigem a implementação de estratégias de dimensionamento dinâmico para garantir que o sistema continue eficiente mesmo nas condições de alta demanda.

A análise comparativa revelou que o modelo TO-BE com lógicas otimizadas resultou em uma eficiência significativamente maior em relação ao sistema AS-IS, especialmente em termos de nível de serviço e distância média até a solicitação, mas ainda há a necessidade de ajustes para lidar com picos de demanda, como sugerido por Rabe *et al.* (2020) e Vohra (2022).

6. CONCLUSÃO

Este estudo teve como objetivo analisar a eficiência atual e propor a otimização do sistema de transporte de táxis dentro do Campus da Universidade de São Paulo (USP), considerando as variáveis que impactam o desempenho das operações de táxi, como a alocação de veículos e a dinâmica de fluxo entre os pontos de solicitação e os destinos. Os resultados obtidos demonstraram que a simulação computacional é uma ferramenta poderosa para entender e melhorar esses sistemas complexos, especialmente quando se utilizam coordenadas reais e modelos otimizados para definir as lógicas de operação.

A análise dos dados experimentais revelou que o nível de serviço do sistema foi significativamente aprimorado com a implementação de lógicas otimizadas. A comparação entre o modelo atual de operação (AS-IS) e o modelo proposto (TO-BE) indicou uma clara vantagem nas métricas de tempo médio de corrida e distância até a solicitação no modelo otimizado. Esse modelo foi responsável por reduzir o tempo de espera para os passageiros e aumentar a eficiência operacional ao melhorar a alocação dos veículos. Contudo, mesmo com as melhorias, foi possível observar que o sistema ainda apresenta desafios, principalmente em situações de alta demanda e durante o pico de solicitações, o que sugere a necessidade de ajustes contínuos nas lógicas de operação.

Além disso, o uso de coordenadas reais teve um impacto positivo na precisão do modelo de simulação. O georreferenciamento possibilitou validar os dados obtidos experimentalmente, mostrando que a simulação se aproxima consideravelmente das condições reais de operação, um fator que pode ser crucial para futuras implementações do modelo em outras cidades ou instituições.

Em relação ao impacto das modificações, a pesquisa revelou que a implementação das novas lógicas de alocação de táxis gerou ganhos substanciais de eficiência, como a redução no tempo de deslocamento e no número de veículos necessários para atender a uma dada demanda. No entanto, os dados também indicaram que, em certos cenários com alta concentração de solicitações em horários de pico, o sistema otimizado ainda pode apresentar limitações em termos de cobertura total, o que abre espaço para futuras melhorias e ajustes.

A comparação entre os diferentes cenários simulados (com 13, 26, 39, 52 e 65 veículos) trouxe à tona a importância do número de veículos disponíveis para garantir a eficiência do sistema. À medida que o número de táxis aumenta, a distância média até o pedido e o tempo médio de corrida diminuem. No entanto, a eficácia do sistema não se mantém linear após certo ponto, indicando que, além do número de veículos, outros fatores como distribuição dos pontos

de táxi e gerenciamento de horários de pico também devem ser considerados para uma otimização mais eficaz.

Apesar dos resultados promissores, algumas limitações foram observadas, como a sensibilidade do sistema à demanda imprevista. Quando as solicitações excedem a capacidade de atendimento do sistema, observa-se uma queda no nível de serviço e um aumento na distância até a solicitação, o que pode afetar diretamente a satisfação do usuário. Portanto, ajustes contínuos, com o uso de modelos dinâmicos que ajustem em tempo real as alocações de táxis, seriam necessários para atender melhor às flutuações de demanda.

Como sugestões para pesquisas futuras, a incorporação de veículos autônomos ao modelo de simulação poderia ser um passo importante, uma vez que a automação poderia contribuir para uma maior eficiência operacional e uma redução de custos. Além disso, a introdução de algoritmos de inteligência artificial para ajustes dinâmicos na alocação de veículos poderia melhorar ainda mais a eficiência do sistema, levando em consideração não apenas a quantidade de táxis mas também condições em tempo real, como congestionamento ou eventos inesperados.

Outro ponto importante para o avanço deste estudo seria a expansão do modelo para diferentes contextos urbanos, permitindo a verificação de como o sistema pode ser adaptado para outras cidades ou grandes centros urbanos, considerando a variação na infraestrutura e nas necessidades de transporte. A pesquisa também poderia explorar a relação entre transporte público e privado, analisando como a integração entre esses modais pode otimizar a mobilidade urbana como um todo, especialmente em áreas densamente povoadas.

Em suma, os resultados obtidos confirmam que a utilização de simulações computacionais para otimizar sistemas de transporte é uma abordagem promissora, mas que exige ajustes contínuos e a incorporação de novas tecnologias para garantir que o sistema seja sustentável e eficiente a longo prazo. A pesquisa contribui com insights valiosos para o campo da mobilidade urbana, apontando caminhos para melhorias futuras tanto em termos de tecnologia quanto de gestão de tráfego.

REFERÊNCIAS BIBLIOGRÁFICAS

- ALMEIDA, T. C. de *et al.* Cidades criativas e a inovação pela coprodução de serviços públicos: uma análise a partir da teoria da localização. **Diálogo com a Economia Criativa**, v. 8, n. 24, p. 144-158, 2023. Disponível em: <https://dialogo.emnuvens.com.br/revistadcec-rj/article/download/484/412>. Acesso em: 12 jan. 2025.
- BAALSRUD HAUGE, J.; JEONG, Y. From novice to expert: advancing step-by-step simulation guideline for urban logistics with an open-source simulation tool. **The International Journal of Logistics Management**, v. 35, n. 5, p. 1417-1433, 2024. Disponível em: <https://www.emerald.com/insight/content/doi/10.1108/IJLM-02-2023-0056/full/pdf>. Acesso em: 8 fev. 2025.
- BABANAGAR, N. *et al.* Digital twins for urban underground space. **Tunnelling and Underground Space Technology**, v. 155, p. 106140, 2025. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0886779824005583>. Acesso em: 3 mar. 2025.
- BARIAH, L.; SARI, H.; DEBBAH, M. Digital twin-empowered smart cities: a new frontier of wireless networks. **Authorea Preprints**, 2022. Disponível em: <https://www.techrxiv.org/doi/pdf/10.36227/techrxiv.20375325>. Acesso em: 10 mar. 2025.
- CAMARGO, F. G. Fuzzy multi-objective optimization of the energy transition towards renewable energies with a mixed methodology. **Production**, v. 32, p. e20210132, 2022. Disponível em: <https://www.scielo.br/j/prod/a/LWvBV4yKbqjy9P3x7357qjG/?format=pdf&lang=en>. Acesso em: 25 mar. 2025.
- DANIEL, L. P. *et al.* Eficiência na gestão de serviços públicos de atenção básica em saúde nos municípios do estado de Mato Grosso. **Revista de Estudos Sociais**, v. 22, n. 44, p. 79-99, 2020. Disponível em: <https://dialnet.unirioja.es/descarga/articulo/8099990.pdf>. Acesso em: 9 abr. 2025.
- DEINEKO, E. *et al.* Optimizing two-echelon logistics network for urban logistics by LRP heuristics with integrated microscopic transport simulation. **Transportation Research Procedia**, v. 82, p. 2693-2707, 2025. Disponível em: <https://www.sciencedirect.com/science/article/pii/S235214652400512X/pdf>. Acesso em: 20 abr. 2025.
- EL YAAGOUBI, A. *et al.* Towards sustainable urban logistics: an optimization-simulation approach for electric vehicles routing in short food supply chains. In: **International Workshop on Service Orientation in Holonic and Multi-Agent Manufacturing**. Cham: Springer Nature Switzerland, 2023. p. 212-224. Disponível em: https://link.springer.com/chapter/10.1007/978-3-031-53445-4_18. Acesso em: 4 mai. 2025.
- FERRÉ-BIGORRA, J.; CASALS, M.; GANGOLELLS, M. The adoption of urban digital twins. **Cities**, v. 131, p. 103905, 2022. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0264275122003444>. Acesso em: 12 mai. 2025.

FORD, D. N.; WOLF, C. M. Smart cities with digital twin systems for disaster management. **Journal of Management in Engineering**, v. 36, n. 4, p. 04020027, 2020. Disponível em: https://city.sass.org.cn/_upload/article/files/72/c1/d689fe7740ca85aeb4637f6599e7/1cdb0a66-8d1c-4fcd-a801-dc449bb4d2b8.pdf. Acesso em: 28 mai. 2025.

FRANCISCO, L. M. L.; BONETTE, L. R. O uso de tecnologias para City Logistics entre 2016 a 2020. **Brazilian Journal of Development**, v. 7, n. 7, p. 69221-69237, 2021. Disponível em: <https://www.researchgate.net/profile/Luiz-Bonette/publication/356738375>. Acesso em: 3 jun. 2025.

GOODWIN, T. *et al.* Efficient simulation optimization with simulation learning. In: **IEEE 17th International Conference on Automation Science and Engineering (CASE)**. IEEE, 2021. p. 2268-2273. Disponível em: <https://ieeexplore.ieee.org/abstract/document/9551410/>. Acesso em: 18 jun. 2025.

GOODWIN, T. *et al.* Epsilon optimal sampling. In: **Winter Simulation Conference (WSC)**. IEEE, 2023. p. 3412-3423. Disponível em: <http://simulation.su/uploads/files/default/2023-goodwin-xu-chen-celik.pdf>. Acesso em: 29 jun. 2025.

HIJRY, H. Proposed model for NEOM City based on Internet of Things (IoT) and MLC at ED system. In: **IEEE International Conference on Prognostics and Health Management (ICPHM)**. IEEE, 2024. p. 23-32. Disponível em: <https://ieeexplore.ieee.org/abstract/document/10627366/>. Acesso em: 10 jul. 2025.

HUANG, W.; ZHANG, Y.; ZENG, W. Development and application of digital twin technology for integrated regional energy systems in smart cities. **Sustainable Computing: Informatics and Systems**, v. 36, p. 100781, 2022. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2210537922001123>. Acesso em: 26 jul. 2025.

JEDDOUB, I. *et al.* Digital twins for cities: analyzing the gap between concepts and current implementations with a specific focus on data integration. **International Journal of Applied Earth Observation and Geoinformation**, v. 122, p. 103440, 2023. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1569843223002649>. Acesso em: 9 ago. 2025.

LAAMARTI, F. *et al.* An ISO/IEEE 11073 standardized digital twin framework for health and well-being in smart cities. **IEEE Access**, v. 8, p. 105950-105961, 2020. Disponível em: <https://ieeexplore.ieee.org/abstract/document/9108291/>. Acesso em: 17 ago. 2025.

LAN, S. *et al.* Knowledge guided DRL for intelligent reconfiguration and scheduling in customized and personalized manufacturing workshop. **IEEE Transactions on Industrial Informatics**, 2025. Disponível em: <https://ieeexplore.ieee.org/abstract/document/11195724/>. Acesso em: 30 ago. 2025.

LIMA, A. M. de; NEPOMUCENO, T. C. C.; TURET, J. Planejamento estratégico do posicionamento policial em estádios de futebol com análise multicritério e clustering não supervisionado. In: **Workshop sobre as Implicações da Computação na Sociedade (WICS)**. SBC, 2025. p. 208-216. Disponível em:

<https://sol.sbc.org.br/index.php/wics/article/download/35948/35735/>. Acesso em: 12 set. 2025.

LIU, H.; LI, X.; WANG, L. Supply chain management and dispute modeling of construction projects by deep learning and principal component analysis. **Journal of Computational Methods in Sciences and Engineering**, v. 25, n. 2, p. 1549-1561, 2025. Disponível em: <https://journals.sagepub.com/doi/abs/10.1177/14727978241300793>. Acesso em: 20 set. 2025.

MOHAPATRA, A. G. *et al.* Harmonizing nature and technology: The synergy of digital twin-enabled smart farming. In: **Digital Twins for Smart Cities and Villages**. Elsevier, 2025. p. 407-442. Disponível em: <https://www.sciencedirect.com/science/article/pii/B978044328884500018X>. Acesso em: 7 jan. 2025.

MORÁN-ZABALA, J. P. *et al.* A simulation-based optimization model for quality control in solid waste collection process. **Production**, v. 34, p. e20240021, 2024. Disponível em: <https://www.scielo.br/j/prod/a/NVkbGnBxGjLBcqrnYvztDM/?format=pdf&lang=en>. Acesso em: 19 jan. 2025.

MORENO, R. P. R. *et al.* An agent-based simulation and optimization approach for sustainable urban logistics: a case study in Lisbon. **Applied System Innovation**, v. 8, n. 3, p. 66, 2025. Disponível em: <https://www.mdpi.com/2571-5577/8/3/66>. Acesso em: 2 fev. 2025.

MULPURU, D.; BHATTACHARYA, K.; BARAT, S. Role of enterprise digital twin in enhancing business agility. In: **Digital Twins for Simulation-Based Decision-Making**. Cham: Springer Nature Switzerland, 2025. p. 33-57. Disponível em: https://link.springer.com/chapter/10.1007/978-3-031-89654-5_3. Acesso em: 11 fev. 2025.

PELDON, D. *et al.* Navigating urban complexity: the transformative role of digital twins in smart city development. **Sustainable Cities and Society**, 2024. Disponível em: <https://opus.lib.uts.edu.au/bitstream/10453/187390/2/1-s2.0-S2210670724004086-main.pdf>. Acesso em: 26 fev. 2025.

PETROVA-ANTONOVA, D.; ILIEVA, S. Digital twin modeling of smart cities. In: **International Conference on Human Interaction and Emerging Technologies**. Cham: Springer International Publishing, 2020. p. 384-390. Disponível em: <https://ascelibrary.org/doi/pdf/10.1061/%28ASCE%29ME.1943-5479.0000779>. Acesso em: 8 mar. 2025.

RABE, M. *et al.* A simulation-optimization approach for locating automated parcel lockers in urban logistics operations. In: **Winter Simulation Conference (WSC)**. IEEE, 2020. p. 1230-1241. Disponível em: <http://simulation.su/uploads/files/default/2020-rabe-chicaiza-vaca-tordecilla-juan.pdf>. Acesso em: 19 mar. 2025.

SAMPAIO, A. dos S. Arquitetura de governança digital e gestão urbana inteligente: a aplicação integrada da inteligência artificial e blockchain na administração pública municipal. **RECIMA21 – Revista Científica Multidisciplinar**, v. 6, n. 3, p. e636338, 2025. Disponível

em: <https://recima21.com.br/index.php/recima21/article/download/6338/4292>. Acesso em: 27 mar. 2025.

SANTOS, C. H. dos *et al.* A decision support tool for operational planning: a digital twin using simulation and forecasting methods. **Production**, v. 30, p. e20200018, 2020. Disponível em: <https://www.scielo.br/j/prod/a/kHCvV3QDtS9pJHvpxcFFFfk/?format=html>. Acesso em: 4 abr. 2025.

SANTOS, N. C. de S. *et al.* Simulation-based optimization of the polca ordering system. **Independent Journal of Management & Production**, v. 12, n. 2, p. 672-690, 2021. Disponível em: <http://paulorodrigues.pro.br/ojs/ijmp/index.php/ijmp/article/download/1275/1764>. Acesso em: 15 abr. 2025.

SHAFIK, W. Navigating artificial intelligence and digital twin for smart cities. In: **Driving Innovation through AI and Digital Twin for 6G Powered Sustainable Ultra Smart Cities**. Wiley, 2025. p. 1-26. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1002/9781394411320.ch1>. Acesso em: 28 abr. 2025.

SHIROWZHAN, S.; TAN, W.; SEPASGOZAR, S. M. E. Digital twin and CyberGIS for improving connectivity and measuring the impact of infrastructure construction planning in smart cities. **ISPRS International Journal of Geo-Information**, v. 9, n. 4, p. 240, 2020. Disponível em: <https://www.mdpi.com/2220-9964/9/4/240>. Acesso em: 5 mai. 2025.

SIMETTE, C. A.; REZENDE, D. A.; SEQUEIRA, D. F. Q. Estratégias municipais, serviços públicos e cidade digital estratégica: caso de Campo Largo, Paraná, Brasil. **Boletim de Conjuntura (BOCA)**, v. 22, n. 65, p. 46-76, 2025. Disponível em: <https://www.researchgate.net/profile/Donald-Quintana-Sequeira/publication/391840216>. Acesso em: 17 mai. 2025.

SINGH, A. *et al.* A simulation-based participatory modelling framework for stakeholder involvement in urban logistics. In: **Winter Simulation Conference (WSC)**. IEEE, 2021. p. 1-12. Disponível em: <http://simulation.su/uploads/files/default/2021-singh-wiktorsson-hauge-birkie.pdf>. Acesso em: 28 mai. 2025.

SOUZA, V. G. de *et al.* Planejamento operacional de minas a céu aberto: aplicação de otimização baseada em simulação. **Brazilian Journal of Development**, v. 6, n. 9, p. 70983-70998, 2020. Disponível em: <https://ojs.brazilianjournals.com.br/ojs/index.php/BRJD/article/download/17096/13908>. Acesso em: 11 jun. 2025.

VAN HEESWIJK, W. J. A. *et al.* Evaluating urban logistics schemes using agent-based simulation. **Transportation Science**, v. 54, n. 3, p. 651-675, 2020. Disponível em: <https://research.utwente.nl/files/196855993/evaluating.pdf>. Acesso em: 23 jun. 2025.

VAN VLIET, J. E. *et al.* The evolution of consumer preferences in last-mile delivery methods and the impact on urban logistics: a simulation study in the Rotterdam-The Hague region.

Research in Transportation Economics, v. 113, p. 101624, 2025. Disponível em:

<https://www.sciencedirect.com/science/article/pii/S0739885925001076>. Acesso em: 8 jul. 2025.

VIEIRA, C. de S.; SANTOS, G. V. dos. Gestão pública baseada nos serviços de atendimento integrado ao cidadão: uma revisão exploratória e integrativa de literatura sobre a implementação do Poupatempo no Estado de São Paulo. **Revista de Gestão e Secretariado**, v. 16, n. 1, p. e4589, 2025. Disponível em:

<https://ojs.revistagesec.org.br/secretariado/article/download/4589/2999>. Acesso em: 19 jul. 2025.

VILLANUEVA-MERINO, A. *et al.* Leveraging local digital twins for planning age-friendly urban environments. **Cities**, v. 155, p. 105458, 2024. Disponível em:

<https://www.sciencedirect.com/science/article/pii/S0264275124006723>. Acesso em: 3 ago. 2025.

VOHRA, M. Digital twin in smart cities: application and benefits. In: **Digital Twin Technology: Fundamentals and Applications**. Wiley, 2022. p. 159-172. Disponível em:

<https://onlinelibrary.wiley.com/doi/abs/10.1002/9781119842316.ch10>. Acesso em: 15 ago. 2025.

WANG, T. *et al.* AI and digital twin for consumer electronics in smart cities. **IEEE Consumer Electronics Magazine**, 2024. Disponível em:

<https://ieeexplore.ieee.org/abstract/document/10637660/>. Acesso em: 27 ago. 2025.

XU, H. *et al.* Towards the autonomous optimization of urban logistics: training generative AI with scientific tools via agentic digital twins and model context protocol. **arXiv preprint**, arXiv:2506.13068, 2025. Disponível em: <https://arxiv.org/pdf/2506.13068>. Acesso em: 14 set. 2025.