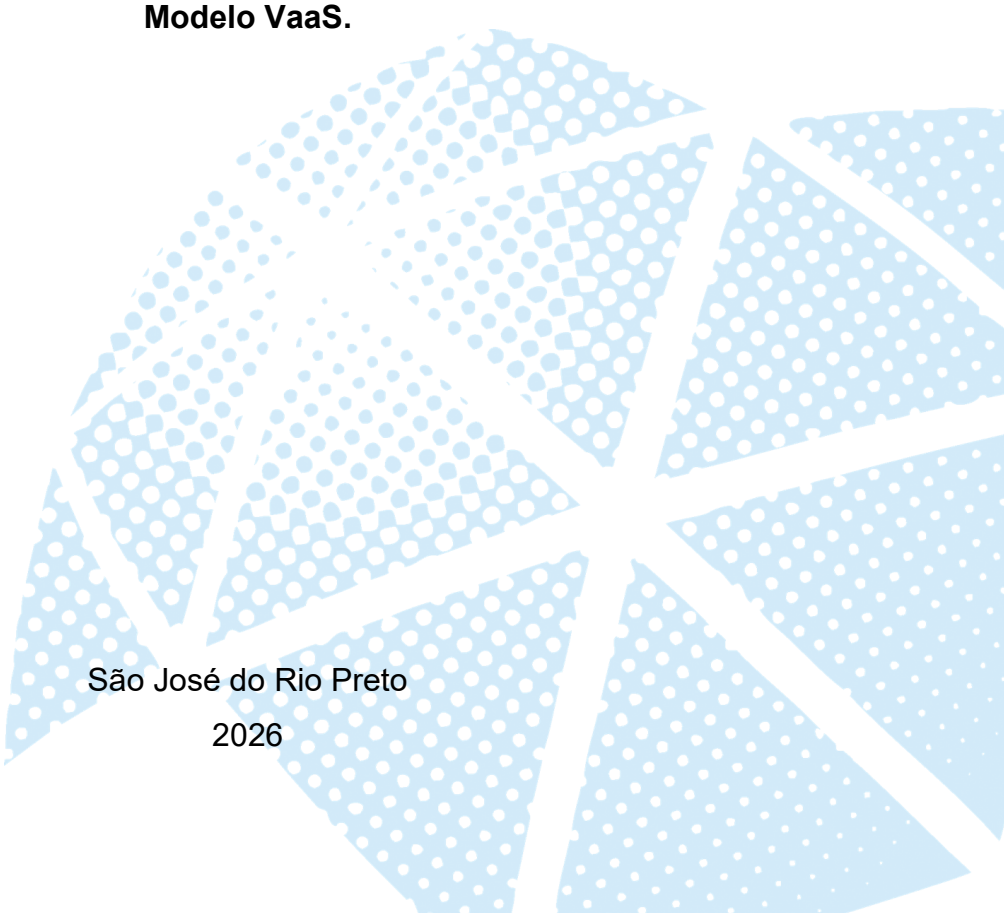
UNIVERSIDADE ESTADUAL PAULISTA – UNESP
Instituto de Biociências, Letras e Ciências Exatas - Campus de São José do Rio Preto

Lucas Henrique de Lima Antonio

Teoria dos Jogos Aplicada à Precificação Dinâmica em Infraestruturas no Modelo VaaS.



São José do Rio Preto
2026

Lucas Henrique de Lima Antonio

Teoria dos Jogos Aplicada à Precificação Dinâmica em Infraestruturas no Modelo VaaS

Dissertação apresentada à Universidade Estadual Paulista (UNESP), Instituto de Biociências, Letras e Ciências Exatas, campus de São José do Rio Preto, para obtenção do título de Mestre em Ciência da Computação.

Área de Concentração: Computação Aplicada

Orientador(a): Prof. Dr. Rodolfo Ipolito Meneguette

São José do Rio Preto

2026

A635t

Antonio, Lucas Henrique de Lima
Teoria dos jogos aplicada à precificação dinâmica em infraestruturas no modelo vaas. / Lucas Henrique de Lima Antonio. -- São José do Rio Preto, 2026
106 p. : il., tabs.

Dissertação (mestrado) - Universidade Estadual Paulista (UNESP), Instituto de Biociências Letras e Ciências Exatas, São José do Rio Preto
Orientador: Rodolfo Ipolito Meneguette

1. Ciência da computação. 2. Teoria dos jogos. 3. Alocação de recursos. 4. Redes ad hoc veiculares (Redes de computadores). I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Dados fornecidos pelo autor(a).

IMPACTO POTENCIAL DESTA PESQUISA

Esta pesquisa propõe o framework SHADAI, inspirado na Teoria dos Jogos de Stackelberg, para alocar recursos em ambientes *Vehicle-as-a-Service* (VaaS). Ao considerar reputação, disponibilidade energética e incentivos econômicos, o modelo poderá apoiar o uso eficiente e sustentável de recursos veiculares nas cidades.

POTENTIAL IMPACT OF THIS RESEARCH

This research proposes the SHADAI framework, inspired by Stackelberg Game Theory, to allocate resources in *Vehicle-as-a-Service* (VaaS) environments. Considering reputation, energy availability, and economic incentives, the model may support more efficient and sustainable use of vehicular resources in cities.

Lucas Henrique de Lima Antonio

Teoria dos Jogos Aplicada à Precificação Dinâmica em Infraestruturas no Modelo VaaS

Dissertação apresentada à Universidade Estadual Paulista (UNESP), Instituto de Biociências, Letras e Ciências Exatas, São José do Rio Preto, para obtenção do título de Mestre em Ciência da Computação.

Área de Concentração: Computação Aplicada

Data da defesa: 02/10/2026

Banca Examinadora:

_____

Prof. Dr. Rodolfo Ipolito Meneguette
USP - Ciências Matemáticas e de Computação- Campus de São Carlos

_____

Prof. Dr. Geraldo Donegá Zafalon
UNESP – Universidade Estadual Paulista

_____

Prof. Dr. Roger Kreutz Immich
UFRN - Universidade Federal do Rio Grande do Norte

_____

Prof. Dr. Caetano Mazzoni Ranieri
UNESP – Universidade Estadual Paulista

_____

Prof. Dr. Daniel Ludovico Guidoni
UFOP – Universidade Federal de Ouro Preto

AGRADECIMENTOS

Primeiramente, agradeço a Deus, por Sua graça, cuidado e direção ao longo de toda esta caminhada. Ao Senhor Jesus Cristo, por ser meu fundamento, minha esperança e minha força em todos os momentos. Ao Espírito Santo, pela presença, consolo, sabedoria e auxílio.

Aos meus pais, por todo o amor, apoio, incentivo e pelos ensinamentos que contribuíram para que eu chegasse até aqui. Sou profundamente grato por todo o esforço, compreensão e confiança depositados em mim.

Ao meu orientador, Prof. Dr. Rodolfo Ipolito Meneguette, pela orientação, confiança, disponibilidade e pelos conhecimentos compartilhados durante o desenvolvimento deste trabalho. Agradeço pelas contribuições acadêmicas e pelo acompanhamento ao longo do mestrado.

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

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pelo apoio financeiro concedido por meio de bolsa de mestrado, processo nº 196671/2025-6.

Por fim, agradeço a todos que, direta ou indiretamente, contribuíram para minha formação e para a realização deste trabalho.

“Porque estou certo de que nem a morte, nem a vida, nem os anjos, nem os principados, nem as potestades, nem o presente, nem o porvir, nem a altura, nem a profundidade, nem alguma outra criatura nos poderá separar do amor de Deus, que está em Cristo Jesus, nosso Senhor”
(Romanos 8:38–39, ACF)

RESUMO

O avanço das cidades inteligentes tem ampliado a demanda por mecanismos eficientes de gerenciamento e compartilhamento de recursos computacionais em ambientes veiculares. Nesse contexto, o paradigma Veículos como Serviço (VaaS) permite que veículos conectados atuem como provedores de recursos computacionais, de sensoriamento e de comunicação. Entretanto, a alocação eficiente desses recursos permanece um desafio devido à heterogeneidade dos veículos, à disponibilidade dinâmica dos recursos e à necessidade de conciliar eficiência operacional, qualidade de serviço e incentivos aos participantes. Esta dissertação propõe o framework SHADAI, voltado à alocação de recursos e ao gerenciamento de incentivos em ambientes VaaS, inspirado na estrutura hierárquica dos jogos de Stackelberg. No SHADAI, os veículos atuam como agentes racionais que avaliam solicitações de serviço com base em sua utilidade esperada, enquanto uma plataforma central seleciona os provedores considerando critérios de reputação, disponibilidade energética e proximidade em relação às tarefas solicitadas. O framework foi implementado e avaliado por meio de simulações utilizando o SUMO, considerando três densidades veiculares, quatro estratégias de seleção e dois cenários de comportamento malicioso. Os resultados demonstraram que o SHADAI apresentou os maiores valores de *score* médio entre as quatro estratégias avaliadas, com desempenho aproximadamente 25% superior ao da seleção aleatória. Além disso, a utilidade média dos veículos permaneceu positiva nas três densidades veiculares analisadas, sem apresentar degradação abrupta ao longo das simulações. Esses resultados evidenciam que a combinação de critérios reputacionais, energéticos e operacionais contribui para decisões de seleção mais consistentes, reforçando o potencial do SHADAI para a alocação adaptativa de recursos e o gerenciamento de incentivos em ambientes VaaS.

Palavras-chave: veículos como serviço; teoria dos jogos de Stackelberg; alocação de recursos; qualidade de serviço; cidades inteligentes.

ABSTRACT

The advancement of smart cities has increased the demand for efficient mechanisms for managing and sharing computational resources in vehicular environments. In this context, the Vehicle-as-a-Service (VaaS) paradigm enables connected vehicles to provide computational, sensing, and communication resources, creating new opportunities for intelligent urban mobility applications. However, efficient resource allocation remains challenging due to heterogeneous vehicle capabilities, dynamic resource availability, energy constraints, and the need to balance operational efficiency, Quality of Service (QoS), and participant incentives. This dissertation proposes SHADAI, a framework for resource allocation and incentive management in VaaS environments, inspired by the hierarchical structure of Stackelberg games. In SHADAI, vehicles act as rational agents that evaluate service requests based on their expected utility, while a centralized platform selects service providers by jointly considering reputation, energy availability, and proximity to the requested tasks. The framework was implemented and evaluated through SUMO-based simulations considering three traffic densities, four provider selection strategies, and two malicious behavior scenarios. The results showed that SHADAI achieved the highest average allocation score among the four evaluated strategies, outperforming random selection by approximately 25%. Furthermore, average vehicle utility remained positive across all three evaluated traffic densities, without abrupt performance degradation throughout the simulations. These findings indicate that the combination of reputation-based, energy-related, and operational criteria contributes to more consistent provider selection decisions, highlighting the potential of SHADAI for adaptive resource allocation and incentive management in VaaS environments.

Keywords: vehicle-as-a-service; Stackelberg game theory; resource allocation; quality of service; smart cities.

Lista de Figuras

1 Delegação de tarefas computacionais em VaaS: Incluindo veículo-a-veículo, dispositivo-a-veículo e ponto de acesso-a-veículo 7
2 Inteligência de borda veicular em cidades inteligentes com aprendizado distribuído em estacionamentos. 10
3 Veículos equipados com SCCSI regulam proativamente o tráfego para aliviar possíveis congestionamentos. 11
4 Percepção Colaborativa Multiagente: Sistema para melhorar a precisão de percepção e reduzir a largura de banda 12
5 VaaS para segurança pública: Cena de crime gravada por veículos ao redor (em movimento e estacionados) e analisada colaborativamente. . 12

6 Diagrama conceitual do framework SHADAI. 41
7 Arquitetura funcional e fluxo de decisão do framework SHADAI. 42

8 Matriz de correlação entre métricas finais do framework SHADAI. 70
9 Relação entre energia residual e utilidade dos veículos. 71
10 Evolução temporal do score médio dos veículos. 73
11 Evolução temporal da reputação média em diferentes densidades veiculares. 74
12 Evolução temporal do score médio em diferentes densidades veiculares. 76
13 Evolução temporal da utilidade média em diferentes densidades veiculares. 77
14 Comparação temporal da reputação média entre estratégias de seleção. 80
15 Evolução temporal do score médio em diferentes estratégias de seleção. 81
16 Evolução temporal da utilidade média em diferentes estratégias de seleção. 83
17 Evolução temporal da reputação média sob diferentes cenários de ataque. 85
18 Evolução temporal da utilidade média sob diferentes cenários de ataque. 86

19 Evolução temporal da taxa de seleção de veículos maliciosos sob diferentes cenários de ataque. 88

Lista de Tabelas

1 Revisão bibliográfica de trabalhos relacionados 36

2 Variáveis e parâmetros do framework SHADAI 46

3 Comparação entre o SHADAI e os trabalhos mais relacionados 92

Lista de Símbolos

Símbolo	Descrição
V	Conjunto de veículos disponíveis no sistema
S	Conjunto de serviços ou tarefas demandadas
v_i	Índice que representa o veículo i
s	Índice que representa o serviço s
t	Tempo de execução da simulação (em segundos)
p_s	Preço ou remuneração associada ao serviço s
E_s	Quantidade de energia necessária para a execução do serviço s
T_s	Duração estimada ou tempo de execução do serviço s
C_i	Custo operacional base atribuído ao veículo v_i (em unidades arbitrárias).
E_i	Energia atualmente disponível no veículo v_i (em unidades arbitrárias)
R_i	Reputação acumulada do veículo v_i
d_i	Distância do veículo v_i até o local de execução da tarefa
U_i	Utilidade total obtida pelo veículo v_i
S_i	Score composto utilizado para ranqueamento e seleção de veículos
T_{max}	Limite temporal máximo estabelecido para a simulação
N_{req}	Número de requisições processadas
N_{max}	Número máximo de tarefas simuladas

Lista de Abreviaturas e Siglas

Sigla	Significado
3GPP	*3rd Generation Partnership Project*
C-V2X	*Cellular Vehicle-to-Everything*
DSRC	*Dedicated Short-Range Communications*
EHLO	*Elephant Herding Lion Optimizer*
Fed-DDQN	*Federated Double Deep Q-Network*
IEEE	*Institute of Electrical and Electronics Engineers*
IoT	*Internet of Things*
IP	*Internet Protocol*
IPA	*Iterative Proximal Algorithm*
MCC	*Mobile Cloud Computing*
MEC	*Mobile Edge Computing*
MFCM	*Modified Fuzzy C-Means*
MIMO	*Multiple Input Multiple Output*
MPA	*Marine Predator Algorithm*
QoS	*Quality of Service*
SCCSI	*Smart Connected and Coordinated Shared Intersection*
SHADAI	*Stackelberg-inspired Hybrid Algorithm for Dynamic Allocation and Incentives*
SUMO	*Simulation of Urban Mobility*
TIC	Tecnologias da Informação e Comunicação
TraCI	*Traffic Control Interface*
V2I	*Vehicle-to-Infrastructure*
V2N	*Vehicle-to-Network*
V2P	*Vehicle-to-Pedestrian*
V2V	*Vehicle-to-Vehicle*
V2X	*Vehicle-to-Everything*
VaaS	*Vehicle-as-a-Service*
VANETs	*Vehicular Ad-hoc Networks*
VCC	*Vehicular Cloud Computing*
VCG	*Vickrey–Clarke–Groves (Mechanism)*
VEC	*Vehicular Edge Computing*
VoIP	*Voice over IP*

Sumário

1 INTRODUÇÃO **1**

1.1 MOTIVAÇÃO E JUSTIFICATIVA 2

1.2 OBJETIVOS 3

2 FUNDAMENTAÇÃO TEÓRICA **5**

2.1 VEÍCULOS COMO SERVIÇO (VEHICLE-AS-A-SERVICE) 6

2.2 COMUNICAÇÃO VEHICLE-TO-EVERYTHING (V2X) 7

2.3 COMPUTAÇÃO VEICULAR EM NUVEM (VCC) 8

2.4 APLICAÇÕES E BENEFÍCIOS VAAS 9

2.5 DESAFIOS DA IMPLEMENTAÇÃO DO VAAS 13

2.6 QUALIDADE DE SERVIÇO EM AMBIENTES VEICULARES 13

2.7 QOS NO CONTEXTO DO VAAS E SUA RELAÇÃO COM ALOCAÇÃO DE RECURSOS 14

2.8 MODELOS DE INCENTIVOS E PRECIFICAÇÃO EM INFRAESTRUTURAS DISTRIBUÍDAS 15

2.9 PRECIFICAÇÃO EM INFRAESTRUTURAS DISTRIBUÍDAS 17

2.10 FUNDAMENTOS DA TEORIA DOS JOGOS 19

2.10.1 Jogos Cooperativos e Não Cooperativos 20

2.11 EQUILÍBRIO DE NASH 20

2.12 CONCEITO DE JOGOS DE STACKELBERG 21

2.13 SISTEMAS DE *BILLING* EM INFRAESTRUTURAS DISTRIBUÍDAS . . 23

2.14 PRECIFICAÇÃO DINÂMICA 24

3 TRABALHOS RELACIONADOS **26**

4 FRAMEWORK SHADAI **37**

4.1 ARQUITETURA E FUNCIONAMENTO DO FRAMEWORK SHADAI . . 38

4.2 JUSTIFICATIVA DO DESENVOLVIMENTO DO FRAMEWORK 42
4.3 FUNÇÕES EMBARCADAS E DEPENDENTES DE CONECTIVIDADE NO FRAMEWORK SHADAI 43
4.4 MODELAGEM MATEMÁTICA DO FRAMEWORK SHADAI 45
4.4.1 Definições e variáveis do framework 45
4.4.2 Função de utilidade dos veículos 47
4.4.3 Estratégia de decisão e restrições 50
4.4.4 Função de score da plataforma 51
4.4.5 Atualização dinâmica da reputação 53
4.4.6 Heurística do framework SHADAI 54
4.4.7 Considerações finais da modelagem 56
4.5 CENÁRIO DE EXECUÇÃO DO FRAMEWORK 58
4.6 FERRAMENTAS E TECNOLOGIAS UTILIZADAS 59
4.7 MÉTRICAS E INDICADORES DE AVALIAÇÃO 60

5 RESULTADOS E DISCUSSÕES 62
5.1 CONFIGURAÇÃO DO AMBIENTE EXPERIMENTAL 63
5.2 DEFINIÇÃO DOS CENÁRIOS EXPERIMENTAIS 65
5.3 ANÁLISE DOS RESULTADOS 69
5.4 DISCUSSÃO DOS RESULTADOS À LUZ DO ESTADO DA ARTE 90
5.5 SÍNTESE E IMPLICAÇÕES DOS RESULTADOS 92
5.6 CONTRIBUIÇÕES 95

6 CONCLUSÃO 97

REFERÊNCIAS 100

DADOS CURRICULARES 106

1 INTRODUÇÃO

As cidades contemporâneas enfrentam desafios crescentes decorrentes do rápido crescimento populacional e da necessidade de oferecer serviços públicos mais eficientes e sustentáveis (SUN et al., 2016). Para lidar com essas demandas, o conceito de cidades inteligentes configura-se como uma abordagem estratégica, integrando Tecnologias da Informação e Comunicação para aprimorar a qualidade de vida da população, otimizar a gestão dos serviços urbanos e garantir o uso eficiente dos recursos disponíveis (SILVA; KHAN; HAN, 2018; CHEN et al., 2024).

Uma cidade inteligente é caracterizada pela implementação de uma infraestrutura tecnológica avançada, composta por sensores, dispositivos interconectados e plataformas digitais capazes de coletar, processar e analisar dados em tempo real. Essas informações são essenciais para a operação e a melhoria contínua de serviços urbanos essenciais, como mobilidade, segurança pública, fornecimento de energia e assistência à saúde. Com a utilização dessas tecnologias, torna-se possível aumentar a eficiência dos serviços prestados, reduzir desperdícios e aprimorar a capacidade de resposta a desafios urbanos (ZANELLA et al., 2014; SUN et al., 2016; AKPAKWU et al., 2018).

Nesse contexto, a Internet das Coisas (IoT) desempenha um papel fundamental na implementação e evolução das cidades inteligentes, ao viabilizar a comunicação direta entre dispositivos e sistemas urbanos por meio de redes inteligentes. Essa conectividade possibilita a automação de processos, reduzindo a necessidade de intervenção humana e aumentando a eficiência operacional dos serviços públicos. Suas aplicações abrangem desde a gestão inteligente do tráfego e do transporte até o monitoramento da infraestrutura urbana e o gerenciamento sustentável de resíduos, promovendo uma maior integração entre os diferentes setores da cidade e aprimorando a qualidade de vida da população (SUN et al., 2016; AKPAKWU et al., 2018; SILVA; KHAN; HAN, 2018).

Dentro desse ecossistema, os veículos conectados representam uma das inovações mais promissoras. Equipados com tecnologias avançadas de comunicação, como as Comunicações de Curto Alcance Dedicadas (DSRC), a comunicação Veículo a Veículo (V2V) e a comunicação Veículo a Tudo (V2X) esses veículos podem trocar informações em tempo real sobre condições do tráfego, riscos na estrada e outras variáveis críticas para a segurança e eficiência da mobilidade urbana (HASAN et al., 2020; HIGASHIYAMA et al., 2020; GARCíA et al., 2021; NAIR; TANWAR, 2024).

A integração desses veículos em sistemas urbanos permitiu a evolução do conceito de Veículos como Serviço (VaaS). Diferente do modelo tradicional de uso exclusivo para transporte, os veículos conectados podem atuar como fornecedores de recursos computacionais e de comunicação, contribuindo com processamento, armazenamento e transmissão de dados para diversas aplicações urbanas. Dessa forma, tornam-se componentes essenciais da infraestrutura digital das cidades inteligentes, ampliando a eficiência dos serviços distribuídos e fortalecendo a conectividade urbana (CHEN et al., 2024; LIAO et al., 2019).

1.1 MOTIVAÇÃO E JUSTIFICATIVA

A viabilização do modelo VaaS enfrenta desafios críticos relacionados à precificação, sustentabilidade e alocação eficiente dos recursos (CHEN et al., 2024).

Um dos principais entraves para a implementação do modelo VaaS está relacionado à assimetria de informação entre a plataforma gestora e os proprietários de veículos. Nesse cenário, os operadores urbanos e gestores da infraestrutura não possuem conhecimento preciso sobre os custos operacionais reais enfrentados pelos proprietários de veículos ao disponibilizarem seus recursos computacionais ou de comunicação. Essa falta de transparência cria oportunidades para comportamentos estratégicos, nos quais os proprietários podem declarar custos superiores aos reais para obter maior remuneração pelos serviços prestados. Como consequência, ocorre uma distorção no processo de precificação, comprometendo a relação custo-benefício da infraestrutura e podendo reduzir a eficiência econômica e a adesão ao modelo VaaS (CHEN et al., 2024).

Além disso, a ausência de um mecanismo de precificação eficiente e transparente pode comprometer a viabilidade do sistema. Sem incentivos bem estruturados, os pro-

prietários podem exigir compensações superiores aos seus custos reais, prejudicando a sustentabilidade econômica da infraestrutura (LIAO et al., 2019; CHEN et al., 2024).

Outro desafio crucial está na alocação de recursos e QoS. Diferentemente de infraestruturas tradicionais, onde os serviços são ofertados por entidades centrais, no VaaS os veículos fornecem múltiplos tipos de serviços (processamento, transmissão de dados e sensoriamento). Para garantir a eficiência desse modelo, é necessário um mecanismo de incentivos que alinhe a oferta desses serviços às demandas reais da cidade, evitando tanto a escassez quanto o desperdício de recursos (CHEN et al., 2024).

Além dos desafios econômicos e operacionais, destaca-se a necessidade de mecanismos de coordenação e precificação que reduzam a suscetibilidade do sistema a manipulações de mercado, incentivando a participação contínua dos proprietários de veículos sem comprometer o custo-benefício para os operadores urbanos (CHEN et al., 2024). Modelos baseados em Teoria dos Jogos, incluindo leilões reversos e contratos inteligentes, surgem como soluções promissoras para mitigar esses desafios e otimizar a distribuição dos incentivos de maneira equitativa.

Considerando esses desafios, esta pesquisa busca responder à seguinte questão: **"Como estruturar um modelo de incentivos e precificação baseado em Teoria dos Jogos para aprimorar a compensação de proprietários de veículos em infraestruturas VaaS, buscando conciliar viabilidade econômica e qualidade dos serviços urbanos?"**

1.2 OBJETIVOS

Embora existam trabalhos que exploram mecanismos de incentivo e precificação para ambientes de computação veicular, muitos desses modelos consideram apenas aspectos econômicos ou tratam separadamente o processo de definição de incentivos e a seleção operacional dos veículos participantes. Essa separação pode limitar a eficiência da alocação de recursos em cenários dinâmicos e heterogêneos, nos quais fatores como reputação dos participantes, eficiência energética e qualidade de serviço também influenciam a tomada de decisão.

Nesse contexto, este trabalho propõe o framework SHADAI, um mecanismo de coordenação e precificação para ambientes VaaS, que busca integrar aspectos eco-

nômicos e critérios operacionais no processo de alocação de recursos. A estrutura do modelo e seus componentes serão apresentados em detalhes nas seções posteriores desta dissertação.

O objetivo geral deste trabalho é desenvolver e avaliar um modelo de alocação de recursos e gerenciamento de incentivos, inspirado na Teoria dos Jogos de Stackelberg, para ambientes do tipo VaaS, buscando promover a seleção eficiente de provedores de serviço a partir de critérios econômicos e operacionais.

A partir desse objetivo geral, definem-se os seguintes objetivos específicos, que orientam o desenvolvimento e a avaliação do modelo proposto:

- Desenvolver um modelo de decisão inspirado na Teoria dos Jogos de Stackelberg, considerando a interação entre uma plataforma central e os veículos participantes, com base em critérios de utilidade individual e incentivos econômicos;
- Definir uma estratégia de alocação de tarefas entre veículos participantes, considerando decisões racionais dos agentes e critérios operacionais, como reputação, disponibilidade energética e proximidade em relação às tarefas solicitadas;
- Avaliar o modelo proposto por meio de simulações e análises comparativas, considerando diferentes densidades veiculares, estratégias de seleção e cenários de comportamento malicioso, com base nas métricas de desempenho definidas para o framework SHADAI.

O restante deste trabalho está organizado da seguinte forma: no Capítulo 2, apresentam-se os principais fundamentos teóricos que embasam esta pesquisa, incluindo conceitos de Teoria dos Jogos, modelos de precificação dinâmica e o modelo VaaS. No Capítulo 3, examinam-se os trabalhos correlatos, destacando abordagens semelhantes na literatura. No Capítulo 4, detalha-se o framework SHADAI, descrevendo sua arquitetura conceitual, as etapas de funcionamento, os mecanismos de decisão e incentivo, além da formalização matemática e das ferramentas utilizadas no desenvolvimento da proposta. No Capítulo 5, expõem-se e analisam-se os resultados obtidos por meio das simulações realizadas. Por fim, no Capítulo 6, sintetizam-se as conclusões do estudo e as perspectivas de trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo apresenta os fundamentos teóricos que sustentam a proposta desta dissertação, estabelecendo uma relação entre os desafios da computação veicular, os mecanismos de garantia de qualidade de serviço (QoS) e os modelos de tomada de decisão baseados em teoria dos jogos.

Inicialmente, é introduzido o conceito de Veículos como Serviço (VaaS) no contexto das cidades inteligentes, destacando o papel dos veículos conectados como componentes ativos de uma infraestrutura computacional distribuída. Nesse contexto, são considerados aspectos relacionados à provisão e ao compartilhamento de recursos, incluindo características frequentemente associadas a esses ambientes, como a heterogeneidade dos dispositivos, a mobilidade dos veículos e a presença de múltiplos agentes.

Em seguida, são apresentados modelos de precificação, com ênfase em abordagens dinâmicas e sua relação com mecanismos de QoS e sistemas de billing. Esses modelos são fundamentais para lidar com a variabilidade da demanda e incentivar o uso eficiente dos recursos disponíveis, embora apresentem limitações quando aplicados a cenários com múltiplos agentes e objetivos potencialmente conflitantes.

Diante dessas limitações, introduz-se a Teoria dos Jogos como uma abordagem adequada para modelar interações estratégicas em ambientes distribuídos. São discutidos diferentes paradigmas, incluindo jogos não cooperativos e modelos hierárquicos, com destaque para os jogos de Stackelberg, que permitem representar relações assimétricas entre agentes.

Essa construção teórica fornece a base necessária para compreender os mecanismos de decisão estratégica adotados neste trabalho, bem como para justificar a escolha do modelo de jogo utilizado na formulação da proposta de alocação de recursos e incentivos em ambientes veiculares.

2.1 VEÍCULOS COMO SERVIÇO (VEHICLE-AS-A-SERVICE)

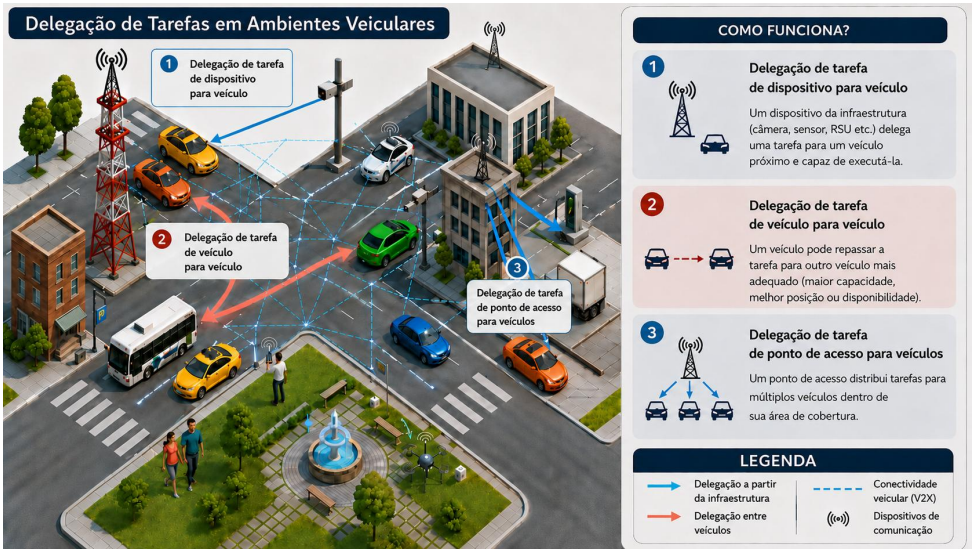
O modelo Veículos como Serviço representa uma abordagem relevante no contexto das cidades inteligentes, na qual veículos passam a atuar como elementos ativos da infraestrutura urbana. Essa proposta integra infraestruturas computacionais distribuídas com redes veiculares, possibilitando o processamento, armazenamento e compartilhamento de dados de forma descentralizada. Nesse cenário, os veículos deixam de ser apenas meios de transporte e passam a atuar como nós móveis em uma rede distribuída, colaborando com a infraestrutura urbana em aplicações relacionadas à mobilidade, segurança e gestão de recursos, como ilustrado na Figura 1.

A ideia central do VaaS consiste em aproveitar recursos disponíveis nos veículos modernos, como capacidade computacional, armazenamento e comunicação, o que permite sua utilização em diferentes serviços no ambiente urbano. Veículos conectados e autônomos apresentam um potencial computacional significativo, que pode ser explorado para suportar aplicações distribuídas e serviços inteligentes (BONOMI et al., 2012; HOU et al., 2016; KLEIN et al., 2022; CHEN et al., 2024). Nesse contexto, os veículos podem interagir com sensores, dispositivos de infraestrutura e outros elementos da rede urbana, contribuindo para a formação de um ambiente computacional distribuído e dinâmico (BONOMI et al., 2012; HOU et al., 2016; CHEN et al., 2024).

No entanto, a utilização desses recursos em larga escala introduz desafios relacionados à sua disponibilidade, variabilidade e compartilhamento entre múltiplos agentes, especialmente em função da mobilidade dos veículos e da natureza dinâmica do ambiente. Esses aspectos tornam a provisão de recursos mais complexa, exigindo mecanismos capazes de lidar com a alocação eficiente e coordenada desses recursos.

A implementação do VaaS depende da integração de tecnologias que viabilizam a comunicação, o processamento e a gestão de recursos. Nesse contexto, destaca-se a Comunicação V2X, que permite a troca de informações entre veículos e infraestrutura, além do suporte de mecanismos de computação distribuída para a execução de serviços nesse ambiente.

Figura 1 – Delegação de tarefas computacionais em VaaS: Incluindo veículo-a-veículo, dispositivo-a-veículo e ponto de acesso-a-veículo



Fonte: Elaborado pelo autor, com auxílio de inteligência artificial generativa para a composição visual, 2026.

2.2 COMUNICAÇÃO VEHICLE-TO-EVERYTHING (V2X)

A Comunicação V2X desempenha um papel fundamental na infraestrutura do VaaS, viabilizando a troca de informações entre veículos, infraestrutura urbana e outros dispositivos conectados. Essa tecnologia abrange diferentes formas de comunicação, como V2V (Vehicle-to-Vehicle), V2I (Vehicle-to-Infrastructure), V2P (Vehicle-to-Pedestrian) e V2N (Vehicle-to-Network), o que permite uma integração mais eficiente dos veículos ao ambiente urbano (ZHOU et al., 2020; DING et al., 2022).

A comunicação V2X pode ser implementada por meio de diferentes tecnologias, destacando-se o DSRC e as redes celulares. O DSRC, baseado no padrão IEEE 802.11p, foi projetado para permitir trocas rápidas de dados entre veículos e infraestrutura, sendo amplamente utilizado em aplicações de segurança viária (JIANG et al., 2006). No entanto, apresenta limitações relacionadas ao alcance e à escalabilidade em cenários de alta densidade (DING et al., 2022).

Por outro lado, a C-V2X (Cellular Vehicle-to-Everything), baseada em redes celulares, oferece maior cobertura e suporte à mobilidade, sendo continuamente aprimorada por padrões do 3GPP, que incorporam funcionalidades voltadas a aplicações avançadas, como condução cooperativa e serviços inteligentes (DING et al., 2022; 3GPP, 2018a; 3GPP, 2018b; 3GPP, 2020).

Apesar desses avanços, a comunicação V2X introduz desafios importantes relacionados ao gerenciamento eficiente dos recursos de rede, especialmente em cenários com alta densidade de veículos. A limitação de espectro e a interferência entre dispositivos podem impactar diretamente métricas como latência e confiabilidade, tornando necessária a adoção de mecanismos de coordenação e alocação de recursos que garantam o atendimento aos requisitos de QoS (GYAWALI et al., 2021; DING et al., 2022).

Nesse contexto, embora a comunicação V2X seja responsável por viabilizar a troca de informações, a execução eficiente dos serviços depende do suporte de infraestruturas computacionais distribuídas, como a computação veicular em nuvem, que permitem o processamento e a gestão desses dados em ambientes dinâmicos.

2.3 COMPUTAÇÃO VEICULAR EM NUVEM (VCC)

A Computação em Nuvem Veicular (VCC) é outra tecnologia essencial para a viabilização do VaaS, que se desenvolve como um avanço natural da Computação em Nuvem Móvel (MCC). O conceito de MCC foi introduzido para ampliar as capacidades dos dispositivos móveis, o que permite que utilizem recursos computacionais robustos disponíveis em servidores remotos na nuvem. Isso possibilita que smartphones e outros dispositivos realizem tarefas complexas, como processamento de dados e armazenamento, sem sobrecarregar seus próprios recursos internos (DINH et al., 2013; HOU et al., 2016; BOUKERCHE; GRANDE, 2018).

A VCC, por sua vez, leva essa abordagem a um novo nível ao explorar as capacidades computacionais dos veículos conectados. Essa tecnologia permite que veículos utilizem seus recursos ociosos, como poder de processamento, armazenamento e conectividade em rede, para criar uma infraestrutura distribuída em nuvem. Assim, os veículos passam a atuar como nós dentro de uma rede colaborativa, onde os recursos são compartilhados de forma dinâmica entre os próprios veículos e servidores em nuvem. Esse modelo viabiliza uma ampla gama de serviços voltados ao ambiente veicular, incluindo gerenciamento de tráfego, coordenação de veículos autônomos e aplicações voltadas à segurança viária (BOUKERCHE; GRANDE, 2018; TENG; SATO, 2024).

Uma das aplicações da VCC são as Cloudlets Veiculares, que consistem em agru-

pamentos temporários de veículos interconectados para compartilhamento de recursos. Esses agrupamentos podem ser formados dinamicamente, dependendo do ambiente e da mobilidade dos veículos. Em rodovias, por exemplo, veículos em movimento podem estabelecer cloudlets móveis, facilitando a disseminação de dados e serviços de entretenimento. Essa flexibilidade possibilita a troca ágil de informações, sendo fundamental para aplicações que exigem atualizações contínuas, como navegação em tempo real, streaming de mídia e informações sobre o tráfego. Já em estacionamentos, os veículos podem formar cloudlets estáticas, que proporcionam maior estabilidade e são ideais para armazenamento de dados e execução de tarefas computacionais mais complexas (BOUKERCHE; GRANDE, 2018).

Além da utilização de servidores remotos na nuvem e dos próprios veículos como recursos computacionais, abordagens complementares têm sido exploradas para suportar o processamento distribuído nesses ambientes. Nesse contexto, destaca-se o *fog computing*, que introduz uma camada intermediária entre os dispositivos e os servidores centrais, o que permite a distribuição do processamento ao longo da rede, incluindo veículos e infraestruturas próximas (BONOMI et al., 2012; LIN et al., 2018; HOU et al., 2016; KLEIN et al., 2022; NAZIH et al., 2024). Essa abordagem possibilita a execução de serviços em diferentes níveis da infraestrutura, contribuindo para maior flexibilidade na gestão dos recursos.

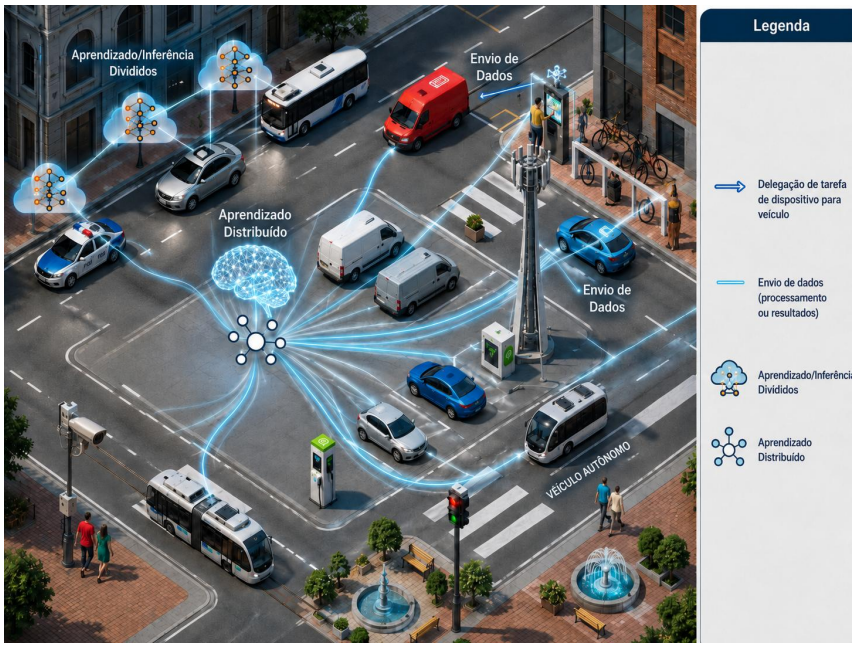
A integração entre recursos locais, intermediários e servidores em nuvem, aliada à mobilidade dos veículos e à variabilidade na disponibilidade de recursos, caracteriza um ambiente altamente dinâmico. Nesse cenário, o compartilhamento de recursos entre múltiplos agentes torna-se mais complexo, exigindo mecanismos que considerem a distribuição e a dinâmica desses recursos para sua utilização eficiente.

2.4 APLICAÇÕES E BENEFÍCIOS VAAS

A adoção do VaaS nas cidades inteligentes possibilita diversas aplicações que vão além da mobilidade urbana, incluindo eficiência operacional, sustentabilidade e maior capacidade de resposta a demandas urbanas. Em áreas urbanas densas, por exemplo, veículos estacionados podem atuar como nós de processamento e armazenamento de dados, contribuindo para a coleta e o tratamento de informações sobre tráfego e condições ambientais. Esse tipo de utilização evidencia o potencial do uso

distribuído de recursos computacionais no ambiente veicular, conforme ilustrado na Figura 2 (KLEIN et al., 2022; CHEN et al., 2024).

Figura 2 – Inteligência de borda veicular em cidades inteligentes com aprendizado distribuído em estacionamentos.



Fonte: Elaborado pelo autor, com auxílio de inteligência artificial generativa para a composição visual, 2026.

Outra aplicação relevante do VaaS está no gerenciamento de tráfego. Veículos em movimento podem coletar e processar dados sobre as condições das vias, compartilhando essas informações com sistemas de controle de tráfego para reduzir congestionamentos e melhorar a fluidez do trânsito como ilustrado na Figura 3 (BONOMI et al., 2012; HOU et al., 2016; KLEIN et al., 2022; CHEN et al., 2024). Essa abordagem também é aplicada no gerenciamento de estacionamentos inteligentes, onde veículos conectados informam a disponibilidade de vagas em tempo real, diminuindo o tempo gasto na busca por estacionamento e reduzindo o impacto ambiental do tráfego (CHEN et al., 2024).

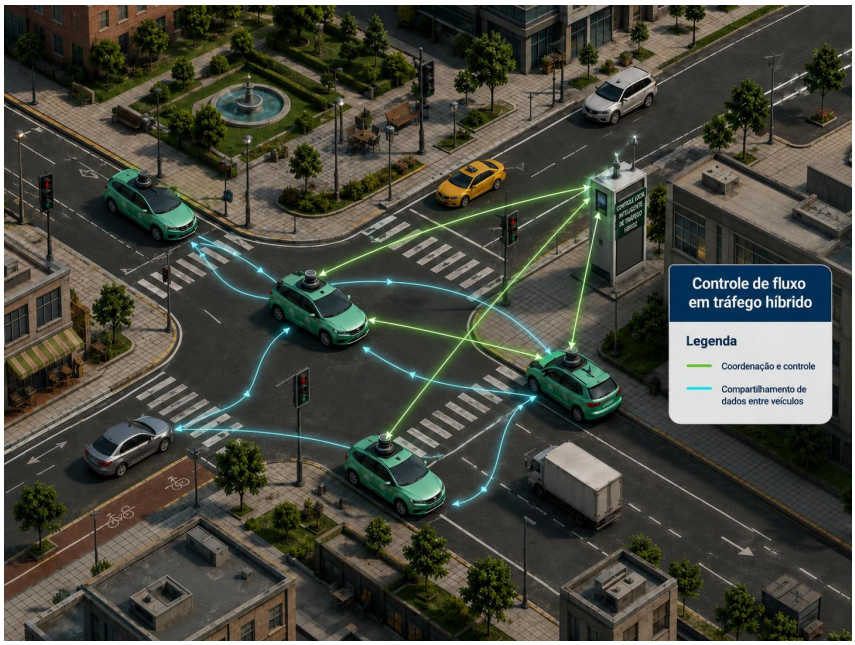
Além da mobilidade, o VaaS pode ser utilizado para melhoria da segurança pública. Veículos conectados podem atuar como sensores móveis, capturando imagens e dados que auxiliam no monitoramento urbano. Em cenários de crime, por exemplo, veículos em movimento ou estacionados podem registrar eventos de forma discreta e compartilhar essas informações com as autoridades. (LIU et al., 2020; CHEN et al., 2024). Evidencia-se na Figura 4 um projeto de percepção colaborativa multiagente

que explora conceito semelhante de veículos como sensores, ao tempo em que na Figura 5 destaca-se como o VaaS pode ser aplicado especificamente em cenários de segurança pública.

No setor da saúde, o VaaS abre novas possibilidades para monitoramento remoto de pacientes e assistência médica móvel. Sensores instalados nos veículos podem coletar sinais vitais de motoristas e passageiros, transmitindo os dados diretamente para serviços de emergência em caso de necessidade (CHEN et al., 2024).

Essas aplicações dependem da disponibilidade e do compartilhamento eficiente de recursos entre veículos e infraestrutura, o que torna o gerenciamento desses recursos um fator relevante para o desempenho dos serviços oferecidos

Figura 3 – Veículos equipados com SCCSI regulam proativamente o tráfego para aliviar possíveis congestionamentos.



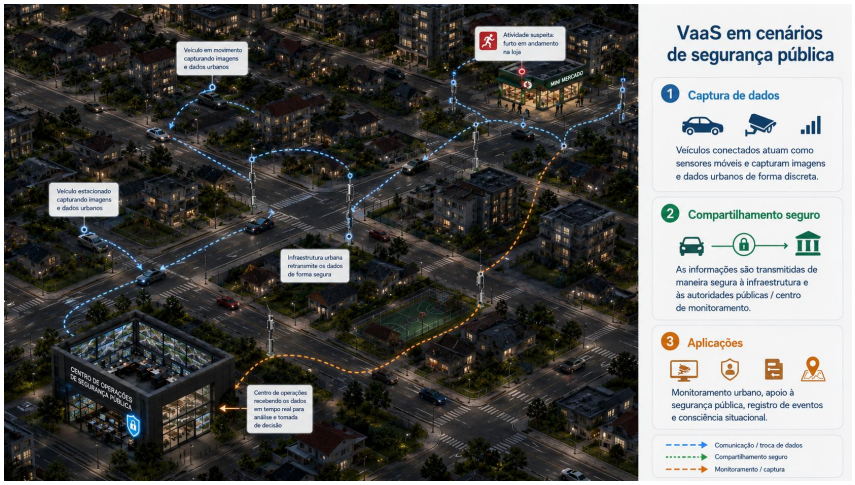
Elaborado pelo autor, com auxílio de inteligência artificial generativa para a composição visual, 2026.

Figura 4 – Percepção Colaborativa Multiagente: Sistema para melhorar a precisão de percepção e reduzir a largura de banda



Elaborado pelo autor, com auxílio de inteligência artificial generativa para a composição visual, 2026.

Figura 5 – VaaS para segurança pública: Cena de crime gravada por veículos ao redor (em movimento e estacionados) e analisada colaborativamente.



Elaborado pelo autor, com auxílio de inteligência artificial generativa para a composição visual, 2026.

Embora o VaaS possibilite uma ampla variedade de aplicações e benefícios, a implementação eficiente desses cenários depende de diversos fatores, incluindo a disponibilidade de recursos, a dinâmica do ambiente veicular e a necessidade de coordenação entre múltiplos agentes. Esses aspectos introduzem desafios importantes para a implementação prática desse modelo, os quais são discutidos na próxima seção.

2.5 DESAFIOS DA IMPLEMENTAÇÃO DO VAAS

Apesar dos benefícios apresentados, a implementação do VaaS envolve diversos desafios. Um deles está relacionado à necessidade de uma infraestrutura de comunicação confiável e com baixa latência, essencial para permitir a troca de dados em tempo real entre veículos e infraestrutura. Tecnologias como C-V2X desempenham papel importante nesse contexto, embora ainda enfrentem limitações associadas à alocação de espectro e à interferência, especialmente em ambientes urbanos densos (GYAWALI et al., 2021; DING et al., 2022).

Outro desafio está relacionado à segurança e à privacidade dos dados. A elevada conectividade dos veículos amplia a superfície de ataque e levanta preocupações quanto ao acesso não autorizado a informações sensíveis. Dessa forma, torna-se importante o desenvolvimento de mecanismos que garantam a integridade e a confidencialidade dos dados trocados nesse ambiente (CHEN et al., 2024).

Além disso, a adoção do VaaS depende da existência de modelos de incentivo econômico que estimulem a participação dos agentes envolvidos. A ausência de mecanismos adequados de compensação pode limitar o compartilhamento de recursos por parte dos veículos, comprometendo o funcionamento do sistema como um todo. Esse aspecto está diretamente relacionado à necessidade de estratégias que considerem a interação entre múltiplos agentes e a alocação eficiente de recursos, configurando a problemática central abordada neste trabalho (LIAO et al., 2019; CHEN et al., 2024).

2.6 QUALIDADE DE SERVIÇO EM AMBIENTES VEICULARES

A Qualidade de Serviço (QoS) refere-se a um conjunto de técnicas e métricas utilizadas para garantir o desempenho adequado em redes de comunicação, incluindo parâmetros como largura de banda, latência, jitter e taxa de perda de pacotes (CAMPBELL et al., 1993). Esses indicadores são fundamentais para assegurar a entrega eficiente e confiável de serviços em aplicações que exigem comunicação contínua e em tempo real, como sistemas de transporte, monitoramento urbano e computação distribuída.

Em ambientes distribuídos e redes urbanas inteligentes, a QoS desempenha um papel relevante devido à presença de múltiplos dispositivos e serviços operando si-

multaneamente. Nesse contexto, mecanismos de priorização e controle são utilizados para garantir uma comunicação previsível e eficiente, mesmo diante da variabilidade dos recursos disponíveis. No entanto, a natureza dinâmica desses ambientes torna desafiadora a manutenção de níveis consistentes de QoS ao longo de toda a comunicação, especialmente em cenários que demandam integração entre diferentes camadas da rede (CAMPBELL et al., 1993; AGEED et al., 2020).

De forma geral, a QoS é estruturada com base em princípios como integração entre camadas, separação de funções e uso eficiente dos recursos, que visam garantir a consistência e a previsibilidade na entrega dos serviços. Esses princípios orientam o desenvolvimento de mecanismos capazes de adaptar o comportamento da rede às condições operacionais, contribuindo para a manutenção do desempenho mesmo em sistemas distribuídos e sujeitos a variações contínuas (CAMPBELL et al., 1993; QADIR; ZEEBAREE, 2021).

Em ambientes veiculares, essas características tornam-se ainda mais relevantes, uma vez que a mobilidade dos nós e a variabilidade das condições de comunicação impactam diretamente o desempenho da rede.

2.7 QOS NO CONTEXTO DO VAAS E SUA RELAÇÃO COM ALOCAÇÃO DE RECURSOS

A implementação da Qualidade de Serviço (QoS) pode ser realizada por meio de diferentes mecanismos, que variam conforme a disponibilidade de recursos e as políticas de alocação adotadas. De forma geral, essas abordagens podem ser classificadas em estáticas ou dinâmicas. Enquanto modelos estáticos realizam a alocação prévia de recursos e definem políticas antes da execução das aplicações, abordagens dinâmicas ajustam continuamente essa alocação de acordo com as condições da rede e a demanda dos usuários, sendo mais adequadas a ambientes distribuídos e altamente dinâmicos (MISIK; CELA; BRADAC, 2016; QADIR; ZEEBAREE, 2021).

No contexto do VaaS, a QoS está diretamente relacionada à eficiência da infraestrutura e à confiabilidade dos serviços oferecidos. Como os veículos atuam simultaneamente como provedores e consumidores de recursos computacionais e de comunicação, a manutenção de níveis adequados de desempenho torna-se essencial para garantir o funcionamento adequado das aplicações. A degradação da QoS pode

comprometer serviços críticos, especialmente aqueles que dependem de comunicação em tempo real, como aplicações baseadas em V2X e processamento distribuído (MOREIRA et al., 2020; XU et al., 2023).

A natureza dinâmica dos ambientes veiculares, influenciada por fatores como mobilidade, densidade de veículos e interferência na comunicação, impacta diretamente os níveis de QoS. Nesse cenário, a alocação eficiente de recursos torna-se um elemento central, uma vez que a distribuição inadequada desses recursos pode levar à degradação do desempenho e à instabilidade dos serviços. Assim, métricas de QoS podem ser utilizadas como critérios para apoiar decisões relacionadas à execução de tarefas e ao balanceamento de carga entre os veículos.

Além disso, aplicações como direção autônoma e sistemas de segurança impõem requisitos rigorosos de desempenho, exigindo baixos níveis de latência e alta confiabilidade. Nesses casos, tanto os veículos quanto a infraestrutura podem adaptar seu comportamento com base nas condições de QoS, ajustando estratégias de comunicação e processamento para manter o funcionamento adequado dos serviços (XU et al., 2023).

Nesse contexto, a QoS também pode ser considerada na definição de estratégias de precificação e incentivos. A associação entre níveis de desempenho, como latência, confiabilidade e disponibilidade e mecanismos de remuneração permite explorar modelos mais dinâmicos de alocação de recursos. Dessa forma, torna-se possível alinhar o comportamento dos agentes aos objetivos do sistema, favorecendo o uso eficiente dos recursos disponíveis (STILLER et al., 2003).

2.8 MODELOS DE INCENTIVOS E PRECIFICAÇÃO EM INFRAESTRUTURAS DISTRIBUÍDAS

A implementação de infraestruturas distribuídas, como computação em nuvem, redes veiculares e sistemas descentralizados, requer mecanismos eficientes de incentivos para garantir a participação contínua dos provedores de recursos (DING et al., 2021). Esses modelos são essenciais para equilibrar a oferta e a demanda, além de promover a sustentabilidade econômica das redes distribuídas.

De forma geral, os modelos de incentivo podem ser classificados em financeiros e reputacionais. Os incentivos financeiros baseiam-se na compensação monetária pelo

fornecimento de recursos computacionais, armazenamento ou comunicação, sendo amplamente utilizados em ambientes distribuídos devido à sua flexibilidade e capacidade de estimular a participação dos agentes (IHLE et al., 2023). Esses incentivos podem assumir diferentes formas, incluindo pagamentos diretos, créditos digitais e modelos dinâmicos de precificação. Para que sejam eficazes, características como transferibilidade, divisibilidade e verificabilidade são importantes para garantir confiabilidade e estabilidade nas transações (SCHäR; BERENTSEN, 2020).

Em ambientes distribuídos, modelos de precificação dinâmica têm sido amplamente explorados para ajustar o valor dos recursos de acordo com a oferta e a demanda. Entre essas abordagens, destacam-se mecanismos baseados em leilão, especialmente leilões reversos, nos quais provedores competem para oferecer recursos a determinados preços (KUMAR et al., 2018; IHLE et al., 2023). Essas estratégias permitem uma utilização mais eficiente da infraestrutura e favorecem a adaptação às variações da rede e da disponibilidade de recursos. Entretanto, a eficiência desses modelos depende da capacidade de lidar com cenários dinâmicos, assimetrias de informação e possíveis conflitos de interesse entre os participantes.

Além dos incentivos financeiros, mecanismos reputacionais também podem ser utilizados para estimular comportamentos cooperativos e aumentar a confiabilidade da rede. Esses modelos baseiam-se na avaliação do comportamento dos participantes ao longo do tempo, influenciando futuras interações e oportunidades dentro do sistema (MANTAS et al., 2017; IHLE et al., 2023). Plataformas como Uber e Airbnb utilizam estratégias desse tipo para avaliar a qualidade dos serviços prestados e fortalecer a confiança entre usuários e provedores (CAMPOS et al., 2022).

Em sistemas distribuídos, mecanismos reputacionais podem ser integrados a registros distribuídos para garantir maior transparência e integridade das avaliações (IHLE et al., 2023). No entanto, embora contribuam para reduzir comportamentos oportunistas e incentivar cooperação, esses modelos apresentam limitações relacionadas à previsibilidade do comportamento futuro dos participantes e à dificuldade de representar adequadamente ambientes altamente dinâmicos.

Nesse contexto, a definição de estratégias eficientes de incentivo e precificação torna-se um elemento central para o gerenciamento de recursos em ambientes distribuídos. A necessidade de equilibrar interesses distintos entre provedores e con-

sumidores, associada à dinâmica da rede e à variabilidade dos recursos disponíveis, evidencia a importância de mecanismos capazes de modelar interações estratégicas entre múltiplos agentes.

2.9 PRECIFICAÇÃO EM INFRAESTRUTURAS DISTRIBUÍDAS

A precificação em infraestruturas distribuídas desempenha um papel fundamental no gerenciamento e na alocação eficiente de recursos computacionais e de comunicação. Em ambientes caracterizados por alta variabilidade de demanda e disponibilidade dinâmica de recursos, os modelos de precificação precisam considerar fatores como custo operacional, utilização da infraestrutura e comportamento dos participantes. Além disso, a presença de assimetria de informação, em que provedores podem ocultar custos reais ou agir de forma oportunista, representa um dos principais desafios desses ambientes (WANG; TIANFIELD; MAIR, 2014; DING et al., 2021).

Nesse contexto, modelos de precificação dinâmica têm sido amplamente explorados devido à sua capacidade de adaptar os valores cobrados conforme as condições da rede e a relação entre oferta e demanda. Entre as principais abordagens utilizadas em infraestruturas distribuídas, destacam-se os mecanismos baseados em leilão, especialmente os leilões reversos, nos quais os provedores competem entre si para oferecer recursos pelo menor custo possível (WANG; TIANFIELD; MAIR, 2014; FATIMA; BEGAM; MUNEERA, 2016; ZHANG; LIU, 2021). Essa estratégia tem sido aplicada em ambientes de computação em nuvem e redes distribuídas para otimizar a utilização dos recursos disponíveis, o que permite maior flexibilidade na negociação e adaptação dinâmica da precificação.

Mecanismos de leilão também podem ser empregados em sistemas distribuídos para coordenar a alocação de recursos entre múltiplos provedores e usuários. Nesse contexto, Lam (2015) apresenta um modelo baseado em leilões combinatórios e no mecanismo Vickrey-Clarke-Groves (VCG), no qual diferentes provedores competem para atender solicitações de serviço submetendo lances conforme seus custos operacionais. A seleção dos participantes ocorre por meio de um processo de otimização que busca minimizar o custo total do sistema e, ao mesmo tempo, incentivar comportamentos economicamente eficientes e transparentes. Essa abordagem demonstra como mecanismos econômicos podem ser utilizados para gerenciar recursos compar-

tilhados em ambientes distribuídos, o que permite decisões de alocação mais eficientes mesmo em cenários com múltiplos agentes e interesses distintos (LAM, 2015).

Além dos mecanismos de precificação dinâmica, infraestruturas distribuídas também podem incorporar tecnologias voltadas à automação e gerenciamento seguro das transações realizadas entre os participantes da rede. Nesse contexto, os contratos inteligentes surgem como uma alternativa para automatizar acordos e operações em ambientes descentralizados.

Os contratos inteligentes (*smart contracts*), introduzidos por Nick Szabo, foram definidos como “protocolos de transação computacional que executam automaticamente os termos de um contrato” (SZABO, 1996). Sua proposta consistia em converter cláusulas contratuais tradicionais em código computacional autoexecutável, reduzindo a necessidade de intermediários confiáveis e mitigando riscos relacionados a falhas ou fraudes durante a execução dos contratos (SZABO, 1997).

Esse mecanismo permite automatizar negociações, validações e pagamentos entre participantes, garantindo maior transparência, auditabilidade e integridade das transações (CHRISTIDIS; DEVETSIKIOTIS, 2016). Além disso, os smart contracts possibilitam o gerenciamento de interações baseadas em dados em sistemas distribuídos, sendo utilizados em aplicações como registros digitais, sistemas financeiros descentralizados e gerenciamento de recursos computacionais (CHRISTIDIS; DEVETSIKIOTIS, 2016).

No contexto do VaaS, os modelos de precificação e incentivo possuem papel central para estimular a participação dos proprietários de veículos no compartilhamento de recursos computacionais e de comunicação. Como os veículos atuam como nós móveis dentro da infraestrutura urbana, torna-se necessário estabelecer mecanismos capazes de conciliar a remuneração dos provedores, a eficiência da alocação de recursos e a sustentabilidade econômica do sistema. (LIAO et al., 2019; CHEN et al., 2024).

Nesse cenário, mecanismos de precificação dinâmica e leilões reversos podem ser utilizados para selecionar veículos com base em critérios econômicos e operacionais, considerando fatores como disponibilidade de recursos, custo e níveis de QoS. Além disso, a adaptação dinâmica dos preços permite responder às variações de demanda da infraestrutura, incentivando maior participação dos provedores em momentos de

alta utilização e reduzindo custos em períodos de menor demanda (SANTOS; ZANON; MORES, 2019; QIAO et al., 2024).

Entretanto, a tomada de decisão em ambientes VaaS envolve múltiplos agentes com interesses potencialmente conflitantes, além de condições altamente dinâmicas relacionadas à mobilidade e à disponibilidade de recursos. Essas características evidenciam limitações de abordagens puramente estáticas ou baseadas apenas em mecanismos econômicos tradicionais, reforçando a necessidade de modelos capazes de representar interações estratégicas entre os participantes da infraestrutura distribuída.

2.10 FUNDAMENTOS DA TEORIA DOS JOGOS

A Teoria dos Jogos é um campo da matemática voltado ao estudo de interações estratégicas entre agentes racionais, sendo amplamente aplicada em áreas como economia, ciência política, biologia e ciência da computação. Seu objetivo é analisar situações em que as decisões tomadas por um participante influenciam diretamente os resultados obtidos pelos demais, o que permite modelar comportamentos estratégicos em cenários competitivos ou cooperativos (KUHN; TUCKER, 1969; MYERSON, 1997; NOROZPOUR; SAFAEI, 2020).

Os primeiros estudos da área concentraram-se em jogos de soma zero, nos quais o ganho de um jogador corresponde exatamente à perda de outro. Esse conceito foi formalizado por John von Neumann, estabelecendo uma das bases matemáticas da teoria moderna dos jogos (KUHN; TUCKER, 1969). Posteriormente, a expansão da teoria para jogos de soma não zero permitiu representar cenários em que os participantes podem obter benefícios mútuos por meio de cooperação ou coordenação estratégica (NEUMANN; MORGENSTERN, 1944; NOROZPOUR; SAFAEI, 2020).

A partir da década de 1950, a Teoria dos Jogos expandiu-se significativamente, sendo aplicada à economia e à tomada de decisões sob incerteza. John Nash, em sua tese de doutorado intitulada Non-Cooperative Games, introduziu um dos conceitos mais relevantes da área: o Equilíbrio de Nash (NOROZPOUR; SAFAEI, 2020).

Dessa forma, a Teoria dos Jogos fornece um arcabouço matemático sólido para a análise de decisões estratégicas em diversos cenários, o que permite a modelagem de interações entre agentes racionais e contribuindo para a formulação de políticas econômicas, estratégias empresariais e modelos de precificação eficientes em infra-

estruturas distribuídas.

2.10.1 Jogos Cooperativos e Não Cooperativos

A Teoria dos Jogos pode ser dividida em duas grandes categorias: jogos cooperativos e jogos não cooperativos. Nos jogos não cooperativos, os jogadores tomam decisões individualmente, buscando maximizar seus próprios interesses sem a existência de acordos formais entre os participantes. Nesse contexto, cada agente define sua estratégia de forma autônoma e racional, considerando as possíveis ações dos demais jogadores (ROMP, 2005; NOROZPOUR; SAFAEI, 2020).

Já nos jogos cooperativos, os participantes podem formar coalizões com o objetivo de obter benefícios mútuos. Nesses modelos, os jogadores cooperam quando a atuação conjunta proporciona resultados mais vantajosos do que aqueles obtidos individualmente. Dessa forma, além da definição das estratégias, torna-se necessário estabelecer mecanismos para distribuição dos ganhos gerados pela cooperação (LEMAIRE, 1993; BRANZEI; FRAGNELLI; TIJS, 2008; ROTHE, 2016).

A principal diferença entre essas abordagens está na possibilidade de coordenação entre os agentes. Enquanto os jogos não cooperativos enfatizam decisões independentes e competitivas, os jogos cooperativos concentram-se na formação de grupos e na divisão dos benefícios obtidos coletivamente. Em ambos os casos, a Teoria dos Jogos fornece mecanismos matemáticos para modelar interações estratégicas e analisar o comportamento racional dos participantes em diferentes cenários.

2.11 EQUILÍBRIO DE NASH

O Equilíbrio de Nash é um conceito fundamental da Teoria dos Jogos, utilizado para representar situações de estabilidade estratégica entre agentes racionais. Formalizado por John Nash, esse equilíbrio ocorre quando nenhum jogador pode melhorar sua utilidade ao modificar unilateralmente sua estratégia, considerando que as escolhas dos demais participantes permanecem inalteradas. Dessa forma, cada agente adota uma estratégia que representa sua melhor resposta às decisões dos outros jogadores. Entretanto, a existência de um equilíbrio não implica necessariamente uma solução coletivamente ótima, uma vez que decisões individualmente racionais podem resultar em situações subótimas para o conjunto dos participantes (KREPS, 1989;

NOROZPOUR; SAFAEI, 2020).

Embora o Equilíbrio de Nash seja tradicionalmente associado a jogos nos quais os participantes tomam decisões sem uma estrutura hierárquica explícita, seus fundamentos também contribuem para a compreensão de modelos estratégicos mais específicos. Entre esses modelos, destacam-se os jogos de Stackelberg, caracterizados por uma relação hierárquica entre líder e seguidores, na qual as decisões são realizadas de maneira sequencial.

2.12 CONCEITO DE JOGOS DE STACKELBERG

O conceito de jogos de Stackelberg teve origem nos estudos de Heinrich von Stackelberg, em 1934, como uma forma de representar situações de mercado onde existem relações hierárquicas entre os agentes, com um deles assumindo o papel de líder e o outro de seguidor (STACKELBERG, 1952). Diferente dos jogos simultâneos tradicionais da teoria dos jogos, esse modelo contempla uma estrutura sequencial: o líder toma uma decisão estratégica inicialmente, antecipando a melhor resposta racional do seguidor, que por sua vez reage a essa ação com base em sua própria função objetivo (STANKOVA, 2009; LI; SETHI, 2017).

A formulação clássica desses jogos é estática, envolvendo decisões únicas realizadas de forma sequencial entre líder e seguidor. No entanto, a literatura posterior ampliou esse modelo para contextos dinâmicos e multietapas, levando à concepção de jogos de Stackelberg em tempo contínuo e discreto. Do ponto de vista dinâmico, as decisões do líder podem ser realizadas de duas maneiras principais: por meio de políticas open-loop ou feedback. No regime open-loop, o líder define sua estratégia para todo o horizonte temporal do jogo antecipadamente, sem responder a mudanças no estado do sistema durante a evolução do jogo. Já no modelo feedback, o líder observa o estado atual do sistema em cada instante e adapta sua estratégia continuamente, o que se assemelha a abordagens de programação dinâmica (STANKOVA, 2009; LI; SETHI, 2017).

Tais modelos ganharam espaço em aplicações modernas que envolvem coordenação estratégica sob restrições de informação e tempo, como é o caso da alocação de recursos em ambientes de computação de borda. Nesse cenário, o nó de borda atua como o agente líder, controlando a oferta de capacidade computacional ao longo

do tempo. Já os dispositivos terminais, que demandam esses recursos, respondem com base em suas necessidades específicas e no preço estipulado pelo nó (LIU et al., 2023).

A estrutura de Stackelberg se mostra particularmente adequada para modelar tais interações, pois captura a natureza assimétrica da relação entre o fornecedor central e os usuários consumidores de recursos. Em termos práticos, isso se traduz em jogos dinâmicos nos quais o nó de borda maximiza seus lucros ajustando sua política de fornecimento, enquanto os dispositivos terminais tomam decisões racionais de consumo considerando tanto suas demandas computacionais quanto os custos associados (LIU et al., 2023).

Quando o jogo é formulado em tempo contínuo, a derivação do equilíbrio envolve sistemas de equações diferenciais acopladas. A abordagem de programação dinâmica, fundamentada no princípio da otimalidade, leva à formulação da equação de Hamilton-Jacobi-Bellman (HJB), que descreve a política ótima em tempo contínuo (STANKOVA, 2009). Aplicações mais recentes têm empregado esse formalismo para derivar soluções ótimas em cenários de Stackelberg dinâmicos, especialmente na alocação de recursos computacionais (LI; SETHI, 2017; LIU et al., 2023).

Essas formulações têm se mostrado eficazes na modelagem de alocação dinâmica de recursos, precificação de serviços, coordenação entre elos de uma cadeia de suprimentos e outras situações em que há interdependência estratégica entre agentes com diferentes níveis de autoridade e informação (STANKOVA, 2009; LI; SETHI, 2017). No contexto de computação de borda, o modelo de Stackelberg fornece uma estrutura robusta para lidar com a distribuição eficiente de recursos escassos em tempo real, oferecendo uma base teórica sólida para a tomada de decisão descentralizada e estratégica.

A formulação matemática genérica de um jogo de Stackelberg é convencionalmente expressa como um problema de otimização hierárquica, onde a decisão do líder antecipa a melhor resposta do seguidor (BASAR; OLSDER, 1999). Essa estrutura pode ser representada conforme a Equação 1:

$$\max_{x \in X} f_L(x, y^*(x)) \quad \text{sujeito a} \quad y^*(x) = \arg\max_{y \in Y} f_F(x, y) \tag{1}$$

Em que:

- **x** representa a ação do líder;
- **y** representa a ação do seguidor;
- ***f*L(x,y)** é a função de utilidade do líder;
- ***f*F(x,y)** é a função de utilidade do seguidor;
- **y*(x)** é a melhor resposta do seguidor à ação x do líder.

Em infraestruturas distribuídas e ambientes veiculares, jogos de Stackelberg podem ser utilizados para modelar interações hierárquicas entre entidades responsáveis pela coordenação da infraestrutura e agentes que disponibilizam ou consomem recursos computacionais e de comunicação. Nesse tipo de cenário, uma entidade central pode definir políticas de precificação ou alocação de recursos, enquanto os demais participantes respondem estrategicamente conforme seus interesses e condições operacionais. Diferentemente de abordagens cooperativas, que dependem da formação de coalizões e objetivos compartilhados, os jogos de Stackelberg permitem representar decisões descentralizadas em ambientes dinâmicos, considerando a racionalidade dos agentes e a relação líder-seguidor presente nessas infraestruturas.

2.13 SISTEMAS DE *BILLING* EM INFRAESTRUTURAS DISTRIBUÍDAS

Os sistemas de *billing* são utilizados na gestão financeira de infraestruturas distribuídas, sendo responsáveis pelo registro do consumo de recursos, cálculo de tarifas e gerenciamento de cobranças e pagamentos. Esses sistemas são empregados em setores como telecomunicações, computação em nuvem e plataformas digitais, permitindo organizar as informações relacionadas à utilização dos serviços e às respectivas compensações financeiras (SHABAN; NOORY; YASEEN, 2012).

De forma geral, o funcionamento desses sistemas envolve a coleta de informações sobre a utilização dos recursos e a aplicação de critérios previamente definidos para o cálculo dos valores correspondentes. Em ambientes distribuídos, esses critérios podem considerar fatores como volume de recursos consumidos, tempo de utilização e características dos serviços disponibilizados. Dessa forma, os mecanismos de *billing* podem atuar de maneira complementar aos modelos de precificação e incentivo,

permitindo representar os valores associados ao compartilhamento de recursos entre diferentes participantes (SHABAN; NOORY; YASEEN, 2012; SWATHI et al., 2020).

No contexto do modelo VaaS, o conceito de *billing* está relacionado à possibilidade de registrar e calcular compensações associadas ao fornecimento de recursos computacionais e de comunicação pelos veículos participantes.

2.14 PRECIFICAÇÃO DINÂMICA

A precificação dinâmica consiste em um modelo de definição de preços capaz de ajustar valores automaticamente conforme alterações nas condições da infraestrutura, disponibilidade de recursos e variações na demanda. Diferentemente de modelos estáticos, essa abordagem permite adaptar os custos dos serviços em tempo real, promovendo maior eficiência na utilização dos recursos disponíveis e melhor equilíbrio entre oferta e demanda (SANTOS; ZANON; MORES, 2019; QIAO et al., 2024). Esse modelo tem sido amplamente aplicado em setores como transporte, computação em nuvem e plataformas digitais, especialmente em cenários caracterizados por elevada variabilidade operacional e compartilhamento dinâmico de recursos.

A implementação da precificação dinâmica normalmente envolve mecanismos computacionais capazes de monitorar continuamente parâmetros do sistema, como utilização da infraestrutura, disponibilidade de recursos, volume de requisições e indicadores de desempenho. Em ambientes distribuídos, essa abordagem permite ajustar os valores cobrados de acordo com as condições da rede e os níveis de QoS oferecidos, contribuindo para uma alocação mais eficiente dos recursos computacionais e de comunicação (SANTOS; ZANON; MORES, 2019; QIAO et al., 2024). Trabalhos clássicos sobre precificação em redes distribuídas também exploraram mecanismos econômicos para controle de congestionamento e compartilhamento eficiente de recursos. Nesse contexto, Key e McAuley (KEY; MCAULEY, 1999) investigaram um modelo baseado em Teoria dos Jogos no qual os usuários são cobrados conforme o consumo de largura de banda, enquanto sinais de congestionamento são utilizados para ajustar dinamicamente a alocação dos recursos da rede. A proposta demonstra como mecanismos de precificação podem ser utilizados para influenciar o comportamento dos usuários e promover maior eficiência na utilização da infraestrutura compartilhada.

No contexto do VaaS, modelos de precificação dinâmica tornam-se particularmente

relevantes devido à mobilidade dos veículos e à variabilidade da disponibilidade de recursos, possibilitando adaptar os incentivos financeiros e os custos operacionais conforme o estado da infraestrutura e a demanda dos serviços.

3 TRABALHOS RELACIONADOS

A precificação em infraestruturas VaaS constitui uma linha de pesquisa relativamente recente, impulsionada pelo avanço da computação veicular, da computação em borda e das tecnologias de comunicação veicular. Embora essas áreas tenham motivado o desenvolvimento de mecanismos para alocação de recursos, descarregamento de tarefas e incentivo à participação dos veículos, os estudos voltados especificamente à precificação em ambientes VaaS ainda são limitados. Essa característica decorre, em parte, da complexidade do paradigma, que envolve fatores como elevada mobilidade, heterogeneidade dos recursos veiculares, disponibilidade dinâmica dos participantes e requisitos relacionados à qualidade de serviço, confiabilidade e incentivos econômicos. Como consequência, a literatura existente tende a abordar esses aspectos de forma isolada, concentrando-se em problemas específicos.

Diante desse cenário, esta seção examina trabalhos relacionados que, embora não sejam especificamente voltados para VaaS, oferecem contribuições relevantes para a construção de um modelo adequado. Para isso, são analisadas abordagens de incentivos em infraestruturas distribuídas, estratégias de precificação baseadas em Teoria dos Jogos, mecanismos de alocação de recursos e modelos voltados ao gerenciamento de reputação e preservação da privacidade em ambientes veiculares. Ao final, são discutidas as limitações dos estudos existentes, evidenciando as lacunas que motivam o desenvolvimento do framework SHADAI.

A identificação dos trabalhos relacionados foi realizada por meio de uma revisão exploratória da literatura, com o objetivo de reunir estudos relevantes sobre mecanismos de precificação, incentivos econômicos, alocação de recursos e gerenciamento de reputação em infraestruturas distribuídas e ambientes veiculares. A seleção priorizou trabalhos que apresentam abordagens relacionadas aos principais conceitos investigados nesta dissertação, permitindo identificar diferentes estratégias propostas na literatura e suas respectivas limitações. Dessa forma, a revisão possui caráter

exploratório, não seguindo um protocolo formal de revisão sistemática da literatura.

Liu et al. (2023) propõe um modelo de precificação dinâmica baseado na Teoria dos Jogos de Stackelberg para otimizar a alocação de recursos em ambientes de computação de borda. No modelo, os provedores de serviços de borda assumem o papel de líderes, definindo os preços dos recursos computacionais, enquanto os usuários atuam como seguidores, decidindo sobre suas demandas com base nesses preços. A interação é modelada como um jogo dinâmico, onde o objetivo é maximizar simultaneamente a utilidade dos usuários e o lucro dos provedores, levando em consideração restrições de capacidade e variações na demanda. A proposta incorpora uma estratégia iterativa para alcançar o equilíbrio de Stackelberg, assegurando que nenhuma das partes envolvidas tenha incentivos para alterar unilateralmente sua decisão. Os experimentos realizados demonstram que o modelo melhora a eficiência no uso dos recursos, promove justiça na distribuição e responde bem a mudanças nas condições da rede.

Entretanto, uma limitação importante é que o modelo assume uma previsibilidade racional e contínua no comportamento dos usuários, o que pode não se sustentar em cenários reais com usuários heterogêneos, atrasos na resposta ou comportamentos não cooperativos. Além disso, a implementação prática dessa abordagem pode demandar infraestrutura de monitoramento e comunicação em tempo real, o que nem sempre está disponível em sistemas distribuídos, especialmente em redes veiculares com alta mobilidade e instabilidade de conexão.

Em uma perspectiva semelhante, Liu, Liu e Li (2026) propõem um mecanismo *strategyproof* para alocação de recursos e compartilhamento de custos em ambientes de Computação de Borda Assistida por Veículos (Edge-Assisted Vehicle Computing). Nesse modelo, servidores MEC são responsáveis pelo processamento computacional, enquanto os veículos disponibilizam seus recursos de sensoriamento para atender múltiplos usuários simultaneamente. Considerando que os dados produzidos por um mesmo sensor podem ser compartilhados entre diferentes solicitações, os autores formulam um mecanismo de divisão de custos no qual os usuários atendidos compartilham o custo associado ao veículo provedor do serviço. A proposta busca garantir propriedades como racionalidade individual, equilíbrio orçamentário, soberania do consumidor e resistência a comportamentos estratégicos, tanto de usuários indivi-

duais quanto de grupos de usuários, promovendo uma alocação mais justa e eficiente dos recursos disponíveis.

Entretanto, a abordagem concentra-se predominantemente na robustez econômica do mecanismo de compartilhamento de custos e na prevenção de manipulações estratégicas durante a alocação de recursos, sem considerar aspectos relacionados ao histórico de confiabilidade dos participantes, à heterogeneidade operacional dos veículos ou a mecanismos adaptativos de reputação capazes de influenciar decisões futuras de seleção em ambientes veiculares dinâmicos.

Complementando essa linha de pesquisa, Zhao et al. (2026) propõem um framework para alocação de tarefas e precificação de recursos em ambientes de Computação de Borda Assistida por Veículos Estacionados (Parked Vehicle-assisted Edge Computing – PVEC), integrando Teoria dos Jogos de Stackelberg e Teoria dos Contratos para coordenar a interação entre veículos usuários, veículos estacionados, unidades de beira de estrada e um controlador baseado em Redes Definidas por Software (SDN). O modelo considera explicitamente a dependência entre tarefas computacionais, o que permite que parte do processamento seja descarregada para veículos estacionados com recursos ociosos quando a infraestrutura de borda apresenta capacidade insuficiente. Para maximizar o bem-estar social do sistema, a proposta realiza conjuntamente a decisão de descarregamento de tarefas, a alocação de recursos e a definição das estratégias de precificação, empregando um algoritmo híbrido baseado em Otimização por Enxame de Partículas e Algoritmos Genéticos (PSOPG) para obtenção de soluções aproximadas.

Apesar da abrangência da abordagem, o modelo concentra-se na otimização do desempenho computacional e da eficiência econômica do processo de offloading, sem incorporar mecanismos capazes de avaliar continuamente a confiabilidade ou o comportamento histórico dos participantes. Além disso, a estratégia pressupõe disponibilidade de infraestrutura de comunicação e coordenação compatível com arquiteturas baseadas em SDN, o que pode representar desafios em cenários veiculares altamente dinâmicos e sujeitos a frequentes mudanças de conectividade.

Outros autores exploraram modelos de incentivo descentralizados com foco em ambientes distribuídos. Liu et al. (2020) investigaram a alocação de recursos computacionais em ambientes de nuvem ad hoc, abordando a precificação e os incentivos

para organizações que disponibilizam seus recursos ociosos para outros usuários da nuvem. O problema foi modelado como um jogo não cooperativo de Nash, onde cada organização busca maximizar seu lucro ao definir a quantidade de recursos ofertados e sua estratégia de precificação. O modelo integra múltiplos fatores, como lucro líquido e tempo de resposta, e utiliza um Algoritmo Proximal Iterativo (IPA) para viabilizar decisões ótimas de forma descentralizada e com mínima troca de informações. Apesar dos avanços, o modelo parte do pressuposto de que os recursos computacionais são homogêneos, o que limita sua aplicabilidade em contextos mais heterogêneos, além de apresentar desafios de escalabilidade.

No contexto da mobilidade urbana, diversos trabalhos analisam a precificação dinâmica em sistemas veiculares. Han, Chen e Fang (2019) propõem uma estratégia de precificação dinâmica para otimizar o uso de veículos como servidores temporários em um sistema de Computação em Borda Móvel (MEC) assistido por veículos. Nesse modelo, um nó de ponto de acesso (AP) gerencia servidores MEC fixos e um estacionamento onde veículos equipados com unidades computacionais podem oferecer poder de processamento adicional. A principal inovação do trabalho está na formulação de um mecanismo de preços dinâmicos, ajustado a cada intervalo de tempo, para incentivar os motoristas a permanecerem estacionados e disponibilizarem seus recursos computacionais conforme a demanda do sistema.

A dinâmica do sistema é modelada como uma cadeia de Markov bidimensional, onde o estado é definido pelo número de veículos estacionados e pela quantidade de tarefas em processamento, considerando que tanto a chegada e saída de veículos quanto a chegada e término das tarefas seguem processos estocásticos de Bernoulli. Essa variação no número de servidores disponíveis e na carga de trabalho exige ajustes contínuos na política de precificação, que influencia diretamente as taxas de chegada e partida dos veículos, estabelecendo um equilíbrio entre oferta e demanda de recursos computacionais. Para minimizar os custos operacionais do sistema MEC sem comprometer a qualidade do serviço, os autores formulam um problema de otimização baseado em programação linear, no qual a função objetivo representa o custo total, e as restrições garantem que a taxa de perda de pacotes permaneça dentro de um limite aceitável. A estratégia proposta é comparada com abordagens tradicionais, como precificação fixa e um método baseado em otimização de Lyapunov, com

os resultados demonstrando que a precificação dinâmica reduz significativamente os custos ao mesmo tempo em que mantém um nível satisfatório de QoS, evidenciando a importância da adaptação contínua dos preços às condições do sistema.

Apesar dos avanços apresentados, o modelo assume que todos os veículos possuem a mesma capacidade computacional, desconsiderando a diversidade real dos dispositivos disponíveis. Além disso, a estratégia baseia-se na premissa de que os motoristas respondem de forma previsível às mudanças de preço, sem levar em conta fatores externos, como a disponibilidade de outros estacionamentos, congestionamento urbano ou incentivos alternativos.

Expandindo essa lógica, Wang, Guo e Yu (2023) propõem um modelo de precificação cooperativa para a interseção entre tráfego de veículos, redes elétricas e redução de emissões de carbono, introduzindo um framework baseado em aprendizado profundo federado chamado Fed-DDQN. O modelo proposto adota uma arquitetura federada vertical baseada em uma rede dupla de aprendizado Q profundo que permite que operadores de redes elétricas e de tráfego aprendam políticas de precificação para incentivar a descarbonização. Para viabilizar o treinamento do modelo, os autores desenvolveram um simulador de ambiente capaz de gerar amostras de treinamento suficientes, o que permite interações entre o sistema real e o modelo sem necessidade de um ajuste preciso da modelagem (WANG; GUO; YU, 2023).

A abordagem proposta estrutura a rede de tráfego como um grafo expandido, onde os nós representam pontos de origem e destino, enquanto as ligações podem ser vias normais, pontos de carregamento ou desvios. Essa modelagem possibilita representar o comportamento de carregamento dos veículos elétricos e suas decisões de rota em função dos sinais de preço emitidos pelo sistema. O método de aprendizado federado empregado garante privacidade e colaboração entre os agentes do sistema, resultando em um esquema de precificação dinâmico que contribui para a redução das emissões de carbono.

No entanto, um ponto de limitação do modelo é a dependência da precisão do simulador, uma vez que sua substituição por interações diretas com sistemas reais pode impactar a convergência e a estabilidade da política de precificação aprendida. Além disso, o tempo de convergência prolongado pode ser um obstáculo em cenários que exigem ajustes rápidos, como congestionamentos inesperados ou variações súbitas

na geração de energia renovável. A abordagem baseada em aprendizado federado também demanda alta capacidade computacional, o que pode ser um entrave em infraestruturas com restrições de processamento ou comunicação entre os agentes do sistema. Por fim, enquanto o tráfego pode ser redistribuído dinamicamente, a alocação da carga elétrica possui menor flexibilidade, o que pode levar a desequilíbrios locais na rede e comprometer a eficiência da precificação em determinadas regiões.

Banerjee, Jain e Sethi (2021) investigam o problema de precificação dinâmica em redes de compartilhamento de veículos sob demanda e de mão única, considerando uma rede com N localizações e K veículos, onde as solicitações de viagens entre as localizações seguem um processo de Poisson. A principal inovação do estudo está na formulação de uma política de precificação dinâmica dependente do estado do sistema, visando maximizar a receita total esperada. O modelo incorpora a avaliação individual dos clientes pelo serviço, representada por uma distribuição de probabilidade, reconhecendo que os clientes podem desistir caso o preço cotado exceda sua disposição a pagar. Além disso, o sistema opera sob uma lógica de perdas, na qual um cliente não é atendido se não houver veículo disponível na sua localização. A duração das viagens é modelada por uma distribuição geral com transformada de Laplace racional que permite capturar diferentes padrões de tempo de deslocamento.

A política de precificação dinâmica proposta ajusta os preços com base no estado do sistema, considerando a disponibilidade de veículos em cada local e em trânsito. Para simplificar a análise, os autores reformulam a política em termos de quantis de aceitação de preço. O sistema é modelado como uma rede de filas fechadas, onde as localizações operam como filas de servidor único e as viagens em andamento como filas de servidor infinito. Devido ao alto custo computacional da precificação dinâmica, o estudo explora políticas estáticas parametrizadas por uma restrição de workload, cuja otimização equilibra a disponibilidade de veículos e a receita esperada.

Uma limitação inerente à abordagem de precificação dinâmica é a alta dimensionalidade do problema, o que dificulta a computação da política ótima e a avaliação de seu desempenho. Diante disso, o artigo também explora políticas de precificação estáticas, que não dependem do estado do sistema, buscando soluções mais tratáveis e com garantias de desempenho.

Complementarmente, Yu, Lam e Lu (2018) propõe um mecanismo de precificação

baseado em leilões duplos combinatórios para otimizar a alocação de veículos autônomos em sistemas públicos de transporte urbano. Nele, tanto os passageiros quanto os operadores de veículos participam de um processo de leilão duplo, onde os primeiros submetem suas propostas com valores máximos dispostos a pagar, e os últimos apresentam lances mínimos aceitáveis para realizar o serviço. A infraestrutura central atua como leiloeira, coordenando a alocação dos veículos às solicitações por meio da resolução de um problema de otimização denominado Winner Determination Problem (WDP), cuja formulação permite o atendimento simultâneo de múltiplas requisições de serviço com diferentes tipos (privado, compartilhado e fracionável). A precificação final é calculada com base em um modelo de dualidade Lagrangiana, garantindo que os preços resultantes estejam alinhados com os custos operacionais declarados e com a maximização do bem-estar social do sistema como um todo.

Apesar de sua sofisticação, o modelo assume homogeneidade entre os assentos ofertados, o que pode limitar sua aplicabilidade em cenários reais nos quais diferentes veículos possuem capacidades, confortos ou eficiências operacionais distintas. Além disso, o sucesso do mecanismo depende da completa racionalidade dos agentes e da disponibilidade de uma infraestrutura computacional robusta para resolver, em tempo hábil, os problemas de programação inteira associados ao leilão, o que pode representar um desafio em ambientes urbanos dinâmicos e com alta carga de solicitações simultâneas.

Com foco na alocação de recursos computacionais em ambientes urbanos inteligentes, Salem et al. (2025) propõem um framework para alocação de recursos computacionais em ambientes urbanos inteligentes, considerando veículos conectados como provedores de recursos de processamento (*Vehicles as Computational Resources* – VaCR). A proposta busca selecionar os veículos mais adequados para a execução das tarefas por meio de um processo de decisão multicritério fundamentado na Qualidade de Experiência (Quality of Experience – QoE) dos usuários. Para isso, o modelo integra uma arquitetura hierárquica baseada em sistemas multiagentes, métodos de Apoio Multicritério à Decisão (MCDM), técnicas de aprendizado de máquina e mecanismos inspirados em Teoria dos Jogos. A seleção dos provedores considera simultaneamente características de hardware, nível de utilização dos recursos computacionais, custo do serviço, capacidade de processamento e indicadores de satisfação dos usu-

ários, o que permite classificar e priorizar os veículos de acordo com seu potencial para prestação dos serviços. Os resultados apresentados pelos autores demonstram ganhos na eficiência da alocação de recursos e na qualidade dos serviços oferecidos em cenários de computação veicular.

Entretanto, embora a abordagem incorpore múltiplos critérios para seleção dos provedores e mecanismos de classificação baseados em aprendizado de máquina, o modelo permanece centrado na otimização da qualidade do serviço percebida pelos usuários. Aspectos relacionados à reputação histórica dos participantes, ao comportamento cooperativo dos agentes e à adaptação contínua das decisões de seleção ao longo das interações não são explorados explicitamente. Além disso, a utilização conjunta de modelos de aprendizado de máquina e técnicas multicritério pode aumentar a complexidade computacional da solução, principalmente em ambientes caracterizados por elevada mobilidade e grande quantidade de veículos participantes.

Isaac et al. (2025) apresentam um modelo de otimização multiobjetivo voltado para a alocação eficiente de recursos em redes de Computação de Borda Veicular (VEC). O objetivo principal é reduzir o atraso nos serviços e minimizar o consumo de energia, ao mesmo tempo em que melhora a distribuição de recursos na nuvem. Para isso, o modelo considera diversos fatores essenciais, como a localização e a capacidade dos nós de borda, a demanda de tráfego entre esses nós e os dispositivos pessoais, os custos de comunicação e a disponibilidade de recursos computacionais na nuvem.

A abordagem proposta se destaca pelo uso do algoritmo adaptativo Elephant Herding Lion Optimizer (EHLO), um método baseado em inteligência de enxame que combina a movimentação coordenada de elefantes e a estratégia de caça de leões para otimizar a seleção de características relevantes, identificando trajetos mais eficientes, reduzindo o tempo de deslocamento dos veículos e melhorando a alocação de tarefas. Para aumentar ainda mais a eficiência do sistema, o modelo também emprega o algoritmo modificado Fuzzy c-means (MFCM), que agrupa veículos com base em sua energia residual e força do sinal, conectando aqueles com capacidades semelhantes para equilibrar a distribuição da carga computacional e minimizar tanto a latência quanto o consumo energético. Por fim, a alocação ideal de recursos na nuvem e a determinação estratégica dos locais das instalações na rede VEC são otimizadas pelo Marine Predator Algorithm (MPA), que utiliza operações de crossover e mutação para

refinar a distribuição dos recursos de forma mais eficiente.

Apesar dos avanços, o modelo enfrenta desafios, pois sua eficácia depende da disponibilidade de informações detalhadas sobre a distribuição espacial dos veículos e os padrões de tráfego, que podem variar de forma imprevisível em cenários dinâmicos. Além disso, o desempenho do EHLO está atrelado à correta parametrização das interações entre elefantes e leões, influenciando a velocidade e a qualidade da convergência da solução. Outro obstáculo reside na implementação prática do sistema, já que a necessidade constante de troca de dados sobre energia residual e qualidade do sinal pode gerar uma sobrecarga na comunicação, impactando a escalabilidade da abordagem. Ainda que o estudo de Isaac et al. (2025) não aborde diretamente modelos de precificação, ele contribui para a compreensão de como a otimização da alocação de recursos em infraestruturas VEC pode impactar a qualidade do serviço em um ambiente VaaS, reforçando a importância de estratégias eficientes de distribuição de carga e alocação de tarefas, que devem ser integradas a modelos de incentivos para garantir a sustentabilidade econômica da plataforma.

Sob outra perspectiva, Wang et al. (2026) propõe uma abordagem híbrida de incentivos baseada em reputação para coleta de dados em ambientes de *Vehicular Crowdsensing* (VCS), denominada *Reputation-based Hybrid Incentive Approach* (RHIA). O modelo considera a interação entre uma plataforma de coleta de dados, veículos sensores e consumidores das informações coletadas, buscando maximizar simultaneamente a utilidade dos diferentes participantes do sistema. Para incentivar a execução eficiente das tarefas de sensoriamento, os autores incorporam um mecanismo de reputação para avaliar a confiabilidade dos veículos, utilizando esse indicador como base para um processo individual de negociação fundamentado em jogos de barganha entre a plataforma e cada veículo participante. Além disso, a proposta integra um algoritmo de planejamento de trajetória dos veículos sensores, o que permite otimizar a execução das tarefas e ampliar a qualidade dos dados coletados. Os resultados experimentais, obtidos a partir de conjuntos de dados reais, demonstram ganhos na utilidade dos participantes e na estabilidade operacional do sistema ao longo do tempo.

Entretanto, embora a abordagem integre mecanismos de reputação e incentivos econômicos para estimular a participação dos veículos, seu foco permanece direci-

onado às aplicações de *Vehicular Crowdsensing*, priorizando a qualidade da coleta de dados e a negociação entre plataforma e participantes. Aspectos relacionados ao gerenciamento conjunto de recursos computacionais, disponibilidade energética dos veículos e critérios operacionais de seleção para execução de serviços em ambientes *Vehicle-as-a-Service* não são tratados explicitamente, restringindo a aplicabilidade do modelo a cenários específicos de sensoriamento colaborativo.

Com foco na preservação da privacidade e no gerenciamento de reputação em ambientes de *Mobile Crowdsensing*, Cheng et al. (2023) propõem um esquema leve de preservação de privacidade com gerenciamento eficiente de reputação para ambientes de Mobile Crowdsensing (MCS) em redes veiculares. A proposta busca conciliar a seleção de veículos confiáveis com a proteção das informações sensíveis dos participantes, incorporando mecanismos capazes de preservar simultaneamente a privacidade da localização, da identidade, dos dados coletados e dos próprios valores de reputação. Para isso, os autores desenvolvem um algoritmo de correspondência entre tarefas e veículos baseado em técnicas de preservação de privacidade, além de mecanismos para verificação da autenticidade dos valores de reputação e comprovação de faixas de reputação sem exposição direta dessas informações. Complementarmente, é proposto um algoritmo de atualização de reputação baseado em três fatores, responsável por atualizar continuamente a confiabilidade dos veículos ao longo das interações. Os resultados experimentais demonstram melhorias nos aspectos de segurança, robustez e eficiência quando comparados a abordagens existentes.

Entretanto, embora o modelo apresente avanços significativos na proteção da privacidade e no gerenciamento da reputação dos participantes, sua aplicação permanece direcionada a ambientes de Mobile Crowdsensing, nos quais o objetivo principal é garantir a confiabilidade da coleta colaborativa de dados. A proposta não considera mecanismos de incentivo econômico, estratégias de precificação ou critérios operacionais relacionados à disponibilidade de recursos computacionais e energéticos dos veículos, limitando sua utilização em cenários mais amplos de alocação de serviços em ambientes Vehicle-as-a-Service.

Em conjunto, observa-se que os estudos existentes abordam aspectos específicos do problema, como mecanismos de precificação, estratégias de alocação de recursos, reputação ou preservação da privacidade. Entretanto, nenhum deles integra si-

multaneamente mecanismos de precificação dinâmica, heterogeneidade dos veículos, reputação adaptativa e seleção baseada em utilidade em uma arquitetura voltada ao paradigma Vehicle-as-a-Service. Essa lacuna motiva o desenvolvimento do framework SHADAI, apresentado nos capítulos seguintes.

Sintetizam-se na Tabela 1 as principais contribuições dos estudos analisados, destacando as dimensões teóricas e metodológicas que serviram de base conceitual para a formulação do framework SHADAI.

Tabela 1 – Revisão bibliográfica de trabalhos relacionados

Autores	**Arquitetura**	**Heterogeneidade**	**Incentivos**	**Prec. Din.**	**Mob.**	**Veículo**	**Método Principal**
Liu et al. (2023)	Descentralizada	X	✓	✓	X	N/A	Jogo de Stackelberg
Liu, Liu e Li (2026)	Descentralizada	X	✓	✓	✓	Tradicional	Strategyproof Cost-Sharing
Zhao et al. (2026)	Descentralizada	✓	✓	✓	✓	Estacionados	Stackelberg + Contratos + PSOPG
Liu et al. (2020)	Descentralizada	X	✓	✓	X	N/A	Jogo de Nash + IPA
Han, Chen e Fang (2019)	Centralizada	X	✓	✓	✓	Tradicional	Markov + Otimização
Wang, Guo e Yu (2023)	Descentralizada	✓	✓	✓	✓	Elétricos	Aprendizado Federado
Salem et al. (2025)	Hierárquica	✓	X	X	✓	Conectados	MCDM + ML + Teoria dos Jogos
Banerjee, Jain e Sethi (2021)	Centralizada	✓	X	✓	✓	Tradicional	Teoria das Filas + Otimização
Yu, Lam e Lu (2018)	Centralizada	X	✓	✓	X	Autônomos	Leilão Combinatório
Isaac et al. (2025)	Descentralizada	✓	X	X	✓	Híbrido	EHLO + MPA + MFCM
Wang et al. (2026)	Descentralizada	✓	✓	X	✓	Sensores	Reputação + Barganha + STPA
Cheng et al. (2023)	Descentralizada	✓	X	X	✓	Sensores	Gerenciamento de Reputação + Privacidade
SHADAI	**Semi-distribuída**	✓	✓	X	✓	**Híbrido**	**Stackelberg + Reputação + Utilidade + Seleção Adaptativa**

Fonte: Elaborado pelo autor, 2026.

4 FRAMEWORK SHADAI

Neste capítulo, é apresentado o framework SHADAI, uma proposta de alocação de recursos e gerenciamento de incentivos inspirada na estrutura hierárquica dos jogos de Stackelberg, voltada à seleção de veículos provedores de serviços em ambientes VaaS. A proposta parte da necessidade de estabelecer mecanismos de coordenação que considerem conjuntamente aspectos econômicos e operacionais, diante da mobilidade dos participantes e da disponibilidade variável de recursos.

A organização do SHADAI considera a plataforma central como líder do processo de alocação e os veículos como seguidores, cujas decisões de participação são orientadas por sua utilidade individual e pelas restrições operacionais. A plataforma estabelece as condições de participação e seleciona os provedores de serviços com base em critérios de reputação, disponibilidade energética e proximidade em relação às tarefas solicitadas.

Na implementação avaliada, a remuneração é definida previamente conforme o tipo de serviço, enquanto a adaptação às condições do ambiente ocorre por meio dos mecanismos de avaliação e seleção dos veículos. Dessa forma, o comportamento adaptativo do SHADAI está relacionado principalmente à alocação das tarefas, não contemplando o reajuste dinâmico de preços conforme as variações de oferta e demanda.

Como componente da arquitetura proposta, o framework contempla um módulo conceitual de *billing*, responsável por representar o gerenciamento das interações econômicas entre a plataforma e os veículos participantes. Esse módulo abstrai os mecanismos de registro e contabilização dos incentivos associados à execução das tarefas, fornecendo suporte à modelagem do processo de remuneração adotado pelo SHADAI. Ressalta-se, entretanto, que a implementação de funcionalidades específicas de faturamento, liquidação financeira ou processamento de pagamentos não faz parte do escopo desta dissertação.

Além disso, o SHADAI incorpora um mecanismo de reputação que considera o histórico de execução das tarefas pelos veículos participantes. A atualização desse indicador ocorre conforme os resultados registrados, permitindo que o desempenho anterior de cada veículo influencie sua prioridade nas seleções posteriores, sem contemplar um programa específico de fidelização ou bonificações financeiras.

O framework foi implementado e avaliado por meio de simulações realizadas no simulador SUMO, contemplando diferentes densidades veiculares, estratégias de seleção e cenários de comportamento malicioso. A arquitetura proposta foi integrada a um ambiente de computação distribuída capaz de representar a interação entre a plataforma líder e os veículos participantes, possibilitando a análise do comportamento do modelo em condições operacionais distintas.

Durante os experimentos, foram analisadas métricas relacionadas à reputação, ao *score*, à utilidade, ao consumo energético e à participação dos agentes ao longo da simulação. Além disso, foram conduzidas comparações entre diferentes estratégias de seleção e experimentos envolvendo ataques de ganância e inundação, permitindo avaliar a robustez do framework diante de comportamentos adversariais.

As análises apresentadas nos capítulos seguintes permitem discutir o comportamento do SHADAI sob diferentes condições de operação, identificar suas principais características e limitações e avaliar seu potencial como mecanismo de alocação adaptativa de recursos e gerenciamento de incentivos em ambientes VaaS.

4.1 ARQUITETURA E FUNCIONAMENTO DO FRAMEWORK SHADAI

Nesta seção é apresentado o framework SHADAI (***S**tackelberg-inspired **H**ybrid **A**lgorithm for **D**ynamic **A**llocation and **I**ncentives*), uma proposta que visa resolver o desafio da precificação dinâmica e da distribuição de incentivos em infraestruturas veiculares organizadas segundo o modelo VaaS. O SHADAI inspira-se na lógica de jogos hierárquicos de Stackelberg, nos quais a plataforma central de gerenciamento urbano atua como agente líder do sistema. Essa plataforma, concebida como a camada de orquestração hospedada na nuvem, é responsável por coordenar todas as decisões estratégicas do modelo. Compete a ela definir os preços dinâmicos, estabelecer os critérios de participação, aplicar mecanismos de incentivo e processar continuamente os dados contextuais do ambiente urbano, buscando conciliar eficiência operacional e

sustentabilidade econômica.

Os veículos, por sua vez, assumem o papel de agentes seguidores, ajustando suas estratégias de colaboração com base nas condições estabelecidas pela plataforma líder. Essa assimetria entre as decisões reforça a característica hierárquica do modelo, na qual o líder antecipa o comportamento racional dos seguidores ao definir suas ações iniciais.

O funcionamento do modelo é estruturado em etapas sequenciais e iterativas, que refletem a dinâmica operacional da prestação de serviços urbanos mediada por veículos conectados:

1. O modelo inicia seu funcionamento com o recebimento de solicitações urbanas provenientes de aplicações inteligentes ou nós da infraestrutura urbana. Essas solicitações podem abranger tarefas computacionais, logísticas ou de monitoramento, sendo caracterizadas por atributos como localização, tipo de serviço, prioridade e exigência de tempo de resposta.

2. A partir dessas informações, a plataforma central de gerenciamento analisa o estado atual do sistema e estabelece os parâmetros de remuneração e os critérios de execução associados a cada tarefa. Esse processo segue uma organização hierárquica inspirada nos jogos de Stackelberg, na qual a plataforma atua como agente líder, estabelecendo as condições consideradas pelos veículos em suas decisões individuais. Na implementação avaliada, os valores de remuneração são definidos conforme o tipo de serviço, enquanto a adaptação às condições dinâmicas do ambiente ocorre principalmente por meio dos mecanismos de avaliação e seleção dos veículos participantes.

3. Os veículos, por sua vez, avaliam estrategicamente sua participação. Cada agente veicular realiza uma análise individual baseada em uma função de utilidade que considera potenciais ganhos financeiros, custos operacionais (incluindo deslocamento e energia), tempo estimado de execução da tarefa e eventuais benefícios de fidelização acumulados ao longo do histórico de participação.

4. Com base nessas decisões, a plataforma realiza a alocação das tarefas, selecionando os veículos mais adequados para cada serviço de acordo com os critérios definidos pelo modelo. Esse processo pode adotar mecanismos baseados em

leilões, funções de utilidade agregada ou heurísticas adaptativas para favorecer uma distribuição eficiente e orientada pelo desempenho dos agentes.

5. Uma vez atribuída a tarefa, os veículos selecionados iniciam a execução do serviço. Durante esse processo, o sistema monitora continuamente o desempenho das operações, detectando falhas, desvios ou indisponibilidades. Caso seja necessário, a plataforma pode realocar a tarefa para outro agente disponível, assegurando a continuidade do serviço e a manutenção da qualidade.

6. Após a conclusão e validação da execução, a plataforma processa o pagamento conforme os parâmetros previamente acordados. Simultaneamente, são ativados os mecanismos de recompensa e reputação, nos quais os veículos com histórico positivo acumulam bonificações e melhorias em seu índice de confiabilidade, o que influencia futuras alocações.

7. Por fim, todos os dados extraídos durante as interações são utilizados em um processo contínuo de aprimoramento do modelo. As informações atualizadas sobre o estado dos veículos e seus históricos de participação são utilizadas nos ciclos subsequentes de decisão, permitindo que a plataforma adapte o processo de seleção às condições observadas no ambiente.

Essa lógica cíclica e sensível ao contexto permite ao SHADAI operar de forma eficiente em ambientes urbanos dinâmicos, promovendo uma utilização mais eficiente dos recursos veiculares heterogêneos como unidades de bordo, sensores e módulos de transporte, mas também a sustentabilidade econômica da infraestrutura. O modelo valoriza agentes recorrentes e confiáveis por meio de incentivos meritocráticos e escaláveis, promovendo a confiança e estabilidade da rede como um todo.

Demonstra-se na Figura 6 o fluxo operacional do framework SHADAI, estruturado em uma arquitetura hierárquica inspirada em jogos de Stackelberg. No topo, a camada de orquestração hospedada na nuvem atua como agente líder, responsável por receber as solicitações de serviços urbanos, definir os preços e condições de execução, e coordenar a alocação dos recursos. As demandas são enviadas por aplicações inteligentes ou entidades urbanas e processadas estrategicamente pela plataforma central. Em seguida, os veículos conectados, agentes seguidores, realizam uma análise individual baseada em suas funções de utilidade, decidindo se participarão da execução

dos serviços. Após a alocação e realização da tarefa, o sistema processa pagamentos, aplica mecanismos de recompensa e atualiza dados operacionais que são reutilizados em ciclos futuros de decisão. O modelo permite realimentação contínua com base no desempenho e no feedback das operações, garantindo adaptabilidade e sustentabilidade em contextos urbanos dinâmicos.

Figura 6 – Diagrama conceitual do framework SHADAI.

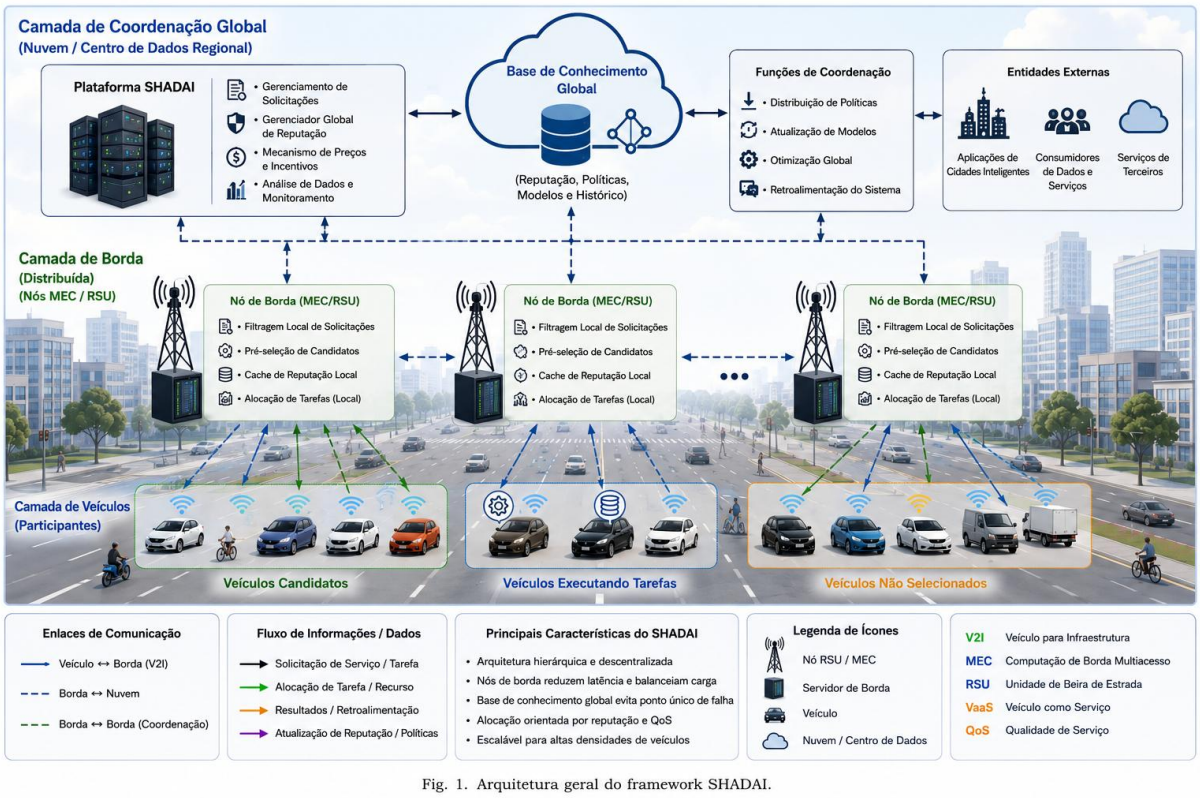
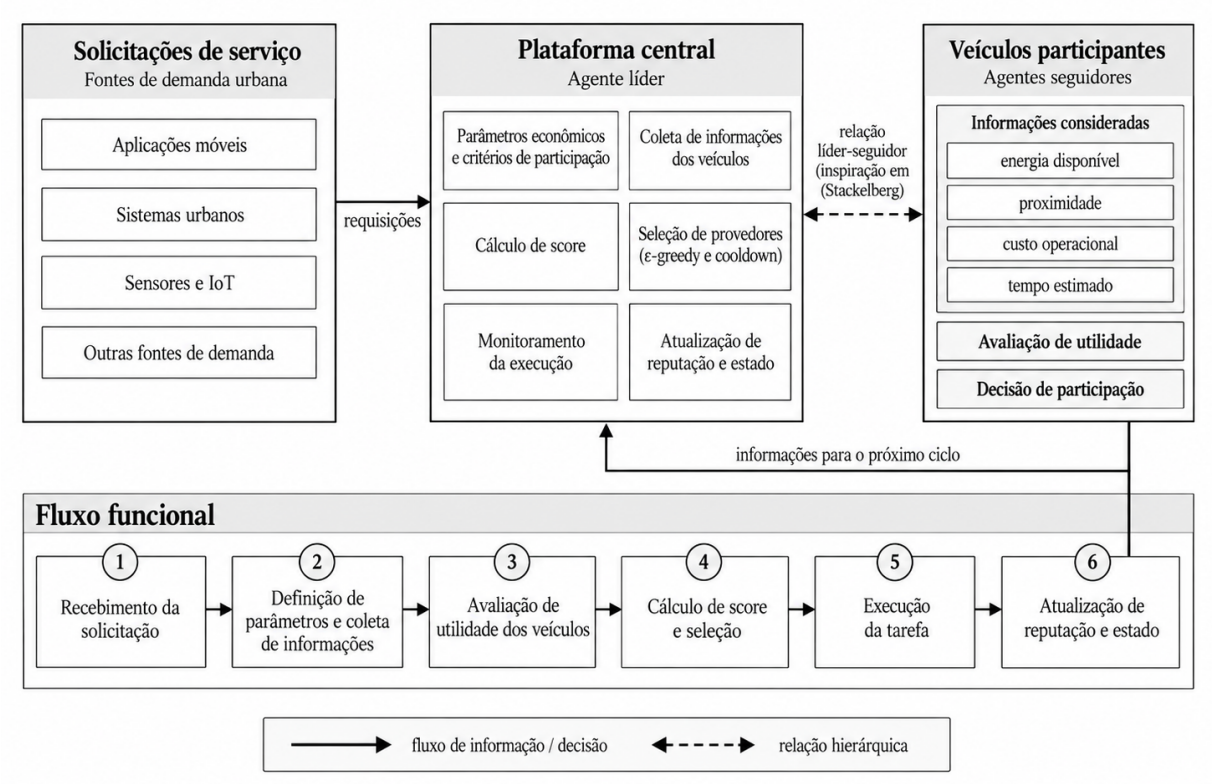


Fig. 1. Arquitetura geral do framework SHADAI.

Elaborado pelo autor, com auxílio de inteligência artificial generativa para a composição visual, 2026.

De forma complementar à representação conceitual apresentada anteriormente, na Figura 7, ilustra-se a organização funcional do framework SHADAI, destacando as responsabilidades da plataforma central de gerenciamento, a participação dos agentes veiculares e as principais etapas do processo de alocação de tarefas. Nessa representação, a plataforma é tratada como uma camada lógica de orquestração, sem implicar que seus componentes estejam concentrados em um único servidor físico.

Figura 7 – Arquitetura funcional e fluxo de decisão do framework SHADAI.



Elaborado pelo autor, com auxílio de inteligência artificial generativa para a composição visual, 2026.

4.2 JUSTIFICATIVA DO DESENVOLVIMENTO DO FRAMEWORK

A formulação do framework SHADAI surge da necessidade de lidar com lacunas observadas nas abordagens existentes para precificação e incentivos em infraestruturas veiculares sob demanda. Os trabalhos analisados na seção de Trabalhos Relacionados revelam que, embora existam mecanismos isolados de precificação, estratégias de leilão ou alocação de recursos, poucos modelos integram de forma coordenada aspectos fundamentais como incentivos dinâmicos, heterogeneidade dos agentes, mecanismos de recompensa e garantia de sustentabilidade econômica.

Diante disso, o framework SHADAI foi concebido como uma solução adaptável, inspirada na estrutura hierárquica dos jogos de Stackelberg, que permite representar a assimetria natural entre a plataforma central, no papel de agente líder, e os veículos participantes, como agentes seguidores. Essa escolha possibilita que a plataforma considere as respostas esperadas dos agentes ao ajustar suas políticas de precificação e busque conciliar objetivos sistêmicos, como ampliação da cobertura e redução

da latência, com os interesses individuais dos veículos, relacionados ao retorno econômico e à reputação.

Além disso, o framework responde diretamente aos desafios enfrentados em ambientes urbanos dinâmicos, onde variáveis como mobilidade, disponibilidade intermitente dos recursos, heterogeneidade de capacidades e variações de demanda são determinantes. O SHADAI incorpora elementos que endereçam essas complexidades, como a precificação dinâmica sensível ao estado do sistema, os mecanismos de fidelização e reputação, e o sistema de faturamento transparente e automatizado.

4.3 FUNÇÕES EMBARCADAS E DEPENDENTES DE CONECTIVIDADE NO FRAMEWORK SHADAI

A definição clara do que deve ser processado localmente nos veículos e do que deve ser delegado à infraestrutura em rede é essencial para a implementação prática do framework SHADAI. Essa separação evita tanto a sobrecarga dos recursos embarcados quanto a dependência excessiva da conectividade, garantindo que cada função seja executada no ambiente mais adequado. Para isso, torna-se necessário estabelecer critérios objetivos de decisão que permitam classificar as tarefas de forma consistente, mantendo equilíbrio entre desempenho, eficiência e segurança do sistema.

Na literatura sobre computação veicular, o critério mais frequentemente utilizado é a latência, já que aplicações críticas que demandam respostas em escala de milissegundos, como frenagem automática ou alertas de colisão, não podem depender de atrasos de transmissão. No entanto, a latência não é o único fator determinante. Outros aspectos também devem ser considerados, como a capacidade computacional necessária, pois tarefas que exigem processamento além do que o hardware veicular suporta precisam ser delegadas à infraestrutura; o volume de dados gerados, já que transmitir todo o fluxo bruto pela rede pode ser ineficiente e requer pré-processamento local; e os requisitos de privacidade e segurança, que impõem que informações sensíveis permaneçam no veículo. Dessa forma, a decisão entre funções embarcadas e distribuídas deixa de ser arbitrária e passa a seguir uma lógica multicritério, alinhada às necessidades técnicas e operacionais do VaaS.

Considerando esses critérios, diferentes aplicações veiculares apresentam neces-

sidades específicas quanto ao local de processamento. Aplicações críticas relacionadas à segurança, como sistemas de alerta de colisão e frenagem automática, apresentam requisitos rigorosos de tempo de resposta e confiabilidade, favorecendo sua execução local ou próxima ao veículo, de modo a reduzir a dependência de infraestruturas remotas (ABDEL-AZIZ et al., 2020; CHEN et al., 2025). Funções com requisitos de latência menos restritivos, como determinados serviços de coordenação de tráfego e comunicação V2X, podem recorrer ao processamento na borda, desde que a infraestrutura ofereça condições adequadas de comunicação e disponibilidade. Por sua vez, aplicações com menor sensibilidade temporal, como análise de dados históricos, precificação e planejamento urbano, apresentam maior compatibilidade com o processamento em infraestruturas remotas, como ambientes de nuvem. Essa diferenciação fornece ao SHADAI um referencial para classificar as funções de acordo com seus requisitos de processamento e comunicação, mantendo localmente aquelas mais sensíveis à latência e permitindo que atividades que demandem maior capacidade computacional ou integração global sejam delegadas à infraestrutura distribuída.

Embora o SHADAI não atue diretamente em aplicações críticas de segurança, essa categorização fornece um referencial para distinguir funções que apresentam maior adequação ao processamento embarcado daquelas que podem ser delegadas à computação em borda, à computação em névoa ou à computação em nuvem, considerando seus respectivos requisitos de latência, capacidade computacional e dependência de informações externas.

No framework SHADAI, algumas funções podem ser executadas diretamente no veículo, sem depender da conectividade. Exemplos incluem o processamento de imagens das câmeras internas, utilizado para monitoramento de segurança e que, por questões de privacidade, deve permanecer embarcado; o pré-processamento de dados de tráfego, como compressão de vídeo ou filtragem de informações, reduzindo o volume antes de enviar à rede. Além disso, o cálculo do consumo energético associado ao compartilhamento de recursos pode ser feito localmente, o que permite que o veículo reporte apenas métricas consolidadas à plataforma.

Outras funções, que exigem maior capacidade computacional ou integração global, devem ser tratadas em ambientes de computação em névoa ou em nuvem. Entre elas está o controle de tráfego em tempo real, que depende da agregação de dados

de múltiplos veículos para sugerir rotas; a definição de preços dinâmicos para os serviços veiculares, que requer a aplicação de modelos de Teoria dos Jogos envolvendo todos os agentes participantes; e a avaliação global da QoS, que integra o feedback dos usuários para ajustar incentivos e penalidades. Também se incluem funções de armazenamento e análise preditiva em larga escala, como identificar padrões de congestionamento ou projetar a disponibilidade futura de recursos computacionais, tarefas inviáveis para processamento isolado em cada veículo.

4.4 MODELAGEM MATEMÁTICA DO FRAMEWORK SHADAI

A modelagem matemática do framework SHADAI tem como propósito representar, de forma formal e sistemática, o comportamento estratégico dos agentes que compõem o ecossistema VaaS, em especial os veículos provedores e a plataforma líder. Essa formalização permite traduzir as interações entre os componentes do sistema em relações quantitativas, evidenciando como variáveis como custo operacional, energia disponível, reputação e distância influenciam as decisões de alocação e precificação. A formulação matemática constitui, portanto, a base conceitual que sustenta as análises de desempenho e os experimentos computacionais apresentados nesta dissertação, conferindo consistência, reprodutibilidade e rigor científico ao modelo proposto. Além disso, o uso dessa abordagem possibilita a derivação de métricas objetivas para avaliar a eficiência econômica e operacional do sistema.

4.4.1 Definições e variáveis do framework

Antes de proceder à formulação matemática propriamente dita, é fundamental apresentar os elementos que compõem o modelo e caracterizam o comportamento dos agentes envolvidos. Nesta etapa, são descritos os conjuntos, variáveis e parâmetros que representam as interações entre os veículos e os serviços disponíveis no ambiente VaaS. Na Tabela 2, sintetizam-se as principais variáveis e notações empregadas, servindo de referência para a formalização das equações apresentadas nas seções subsequentes.

A definição dessas variáveis fornece o alicerce conceitual para a modelagem do SHADAI que permite compreender de que forma aspectos como custo operacional, energia, reputação e distância influenciam o processo decisório de cada agente. Essa

etapa também estabelece a linguagem simbólica que será utilizada nas seções seguintes, contribuindo para a clareza e a consistência na descrição das relações formais do modelo.

Considera-se que o ambiente é composto por um conjunto de veículos disponíveis para execução de tarefas e um conjunto de serviços demandados pela infraestrutura urbana. Cada veículo possui características próprias, como custo operacional, energia disponível, reputação e localização relativa, que afetam diretamente sua decisão de participar ou não de determinada requisição de serviço. De forma análoga, cada serviço apresenta requisitos específicos de energia, tempo e remuneração associados à sua execução.

Tabela 2 – Variáveis e parâmetros do framework SHADAI

Símbolo	**Descrição**
$V = \{v_1, v_2, ..., v_n\}$	Conjunto de veículos disponíveis no sistema.
$S = \{s_1, s_2, ..., s_m\}$	Conjunto de serviços ou tarefas demandadas.
p_s	Preço ou remuneração associada ao serviço s.
E_s	Quantidade de energia necessária para a execução do serviço s.
T_s	Duração estimada ou tempo de execução do serviço s.
C_i	Custo operacional base atribuído ao veículo v_i (em unidades arbitrárias).
E_i	Energia atualmente disponível no veículo v_i.
R_i	Reputação acumulada do veículo v_i, resultante de seu histórico de desempenho.
d_i	Distância do veículo v_i até o local de execução da tarefa.

Fonte: Elaborado pelo autor, 2026.

Os parâmetros definidos permitem representar de forma abrangente o estado do modelo e o perfil de cada agente participante. Dessa maneira, a formulação contempla tanto os aspectos econômicos, expressos pelos termos p_s e C_i, quanto os aspectos operacionais e reputacionais, representados por E_s, R_i e d_i. Essa estrutura integra, de modo coerente, as dimensões de custo, desempenho e confiabilidade que influenciam

o processo decisório dos agentes, oferecendo uma base sólida para a construção das funções de decisão do framework SHADAI.

4.4.2 Função de utilidade dos veículos

No framework SHADAI, cada veículo é tratado como um agente racional e autônomo, cuja decisão de participação na execução de uma tarefa é orientada pela maximização de sua utilidade individual. Nesse contexto, a racionalidade refere-se à capacidade de avaliar o benefício econômico esperado em relação aos custos e às restrições operacionais associados à prestação do serviço. A autonomia, por sua vez, corresponde à possibilidade de cada veículo decidir individualmente sobre sua participação, considerando as condições estabelecidas pela plataforma líder. Dessa forma, um veículo somente se torna elegível para a execução de uma tarefa quando sua utilidade calculada é positiva e sua disponibilidade energética é suficiente para atender à demanda do serviço.

Considerando que as variáveis utilizadas no modelo representam grandezas distintas, como energia, distância e tempo, torna-se necessário compatibilizar suas escalas antes da composição da função de utilidade. Para isso, o framework adota um processo de normalização, no qual cada variável é convertida para uma faixa contínua entre 0 e 1 com base em valores máximos previamente definidos no sistema. Essa abordagem evita inconsistências decorrentes da combinação direta de unidades heterogêneas, o que permite que os fatores sejam comparáveis e ponderados adequadamente.

Assim, o comportamento de cada agente pode ser representado matematicamente pela Equação 2:

$$U_i = p_s - \left(C_i + \lambda_1 \hat{E}_s + \lambda_2 \hat{d}_i + \lambda_3 \hat{T}_s\right) \tag{2}$$

Na Equação 2, U_i representa a utilidade individual do veículo v_i, utilizada para avaliar a conveniência econômica de sua participação na execução de determinada tarefa. O parâmetro p_s corresponde à remuneração oferecida pela execução do serviço s, representando o benefício econômico associado à tarefa. Por sua vez, C_i representa o custo operacional base atribuído ao veículo v_i, considerado independentemente das penalizações adicionais associadas às características específicas do serviço.

Esse custo operacional base é utilizado para expressar diferenças individuais nos custos de participação dos agentes. No modelo, C_i é tratado de forma abstrata, sem corresponder diretamente à medição de despesas específicas, como combustível, manutenção ou desgaste dos componentes. Sua função é representar uma parcela básica do custo de participação, enquanto o termo $\hat{E}_s$ considera separadamente a demanda energética associada à execução de cada serviço. Dessa forma, C_i caracteriza uma condição individual do veículo, ao passo que $\hat{E}_s$ varia conforme os requisitos energéticos da tarefa solicitada.

O termo $\hat{E}_s$ representa o consumo energético normalizado necessário para executar o serviço s, de modo que tarefas com maior demanda energética contribuam para a redução da utilidade do veículo. De maneira semelhante, $\hat{d}_i$ corresponde à distância normalizada entre o veículo v_i e o local de execução da tarefa, representando a influência do deslocamento na decisão de participação. Já $\hat{T}_s$ indica o tempo estimado de execução do serviço, também normalizado, permitindo considerar a duração da tarefa como um fator que influencia negativamente a utilidade.

Os coeficientes λ_1, λ_2 e λ_3 representam os pesos atribuídos, respectivamente, ao consumo energético, à distância e ao tempo de execução. Esses parâmetros determinam a influência relativa de cada fator na função de utilidade, permitindo ajustar a importância das características operacionais na avaliação das tarefas. Assim, valores mais elevados de um determinado coeficiente aumentam o impacto da respectiva variável no cálculo, reduzindo a utilidade quando os demais parâmetros permanecem constantes.

Embora a normalização permita representar energia, distância e tempo em uma escala comum, esse procedimento não significa que essas grandezas possuam a mesma importância no processo de decisão. Por esse motivo, a função de utilidade utiliza coeficientes de ponderação que permitem considerar a influência de cada variável de maneira diferenciada. Dessa forma, a combinação desses fatores não pressupõe uma equivalência direta entre consumo energético, distância e tempo, mas representa uma avaliação conjunta das condições operacionais associadas à execução de cada tarefa, conforme os pesos estabelecidos no modelo.

O custo operacional base C_i, por sua vez, possui um coeficiente de ponderação unitário, implícito na formulação matemática. Assim, sua contribuição é considerada

diretamente no cálculo da utilidade, sem a aplicação de um peso adicional ajustável. Essa escolha constitui uma simplificação adotada na modelagem, mantendo a influência do custo-base dependente de sua escala de valores.

Na formulação considerada, o parâmetro p_s corresponde ao valor de remuneração associado ao serviço s, estabelecido previamente de acordo com as características da tarefa. Embora diferentes serviços possam apresentar remunerações distintas, a implementação avaliada não contempla um mecanismo explícito de reajuste do preço em função das variações de oferta e demanda. Nesse contexto, o valor de p_s é utilizado como parâmetro econômico na função de utilidade dos veículos, enquanto o comportamento adaptativo do framework está concentrado na seleção dos provedores de serviço, considerando as condições operacionais e os critérios estabelecidos pela plataforma. A incorporação de mecanismos de precificação dinâmica sensíveis à oferta e à demanda permanece como possibilidade de aprimoramento do modelo.

A normalização das variáveis é realizada conforme:

$$\hat{E}_s = \frac{E_s}{E_{\max}^{\text{serv}}} \tag{3}$$

$$\hat{d}_i = \frac{d_i}{d_{max}} \tag{4}$$

$$\hat{T}_s = \frac{T_s}{T_{max}} \tag{5}$$

em que $E_{\max}^{\text{serv}}$, $d_{\max}$ e $T_{\max}$ representam, respectivamente, os limites de referência para o consumo energético das tarefas, a distância e o tempo de execução. Esses parâmetros são definidos previamente na configuração do cenário experimental, considerando as escalas adotadas para representar as características dos serviços e as condições operacionais dos veículos. Dessa forma, os valores máximos não correspondem necessariamente aos maiores valores observados durante a simulação, mas a referências estabelecidas para permitir a normalização das diferentes grandezas e sua utilização na função de utilidade.

A interpretação da função de utilidade é direta: quanto maior o valor de U_i, mais vantajosa é a aceitação do serviço para o veículo. O agente apenas opta por participar da tarefa quando o valor de utilidade é positivo e quando dispõe de energia suficiente

para realizá-la, conforme as condições:

$$U_i > 0 \text{ e } E_i \geq E_s$$

Essas restrições impõem limites que mantêm o comportamento do agente compatível com os limites físicos e econômicos do sistema. Dessa forma, a função de utilidade constitui o núcleo do processo decisório local do framework SHADAI.

Na formulação avaliada, os parâmetros p_s e C_i são considerados diretamente na função de utilidade, enquanto os componentes associados ao consumo energético, à distância e ao tempo de execução são normalizados por seus respectivos valores de referência. Essa representação constitui uma simplificação da modelagem, na qual a remuneração e o custo operacional base são tratados como parâmetros econômicos, enquanto os demais fatores representam penalizações operacionais ponderadas. Embora essa abordagem permita considerar conjuntamente diferentes aspectos da decisão dos veículos, a ausência de normalização explícita de p_s e C_i limita a compatibilidade das escalas e torna a interpretação da utilidade dependente dos valores e coeficientes adotados no cenário experimental.

4.4.3 Estratégia de decisão e restrições

A decisão de aceitar ou rejeitar um serviço está diretamente associada à análise da utilidade U_i e às condições de viabilidade operacional de cada veículo. No contexto do framework SHADAI, essa escolha é regida por uma estratégia de decisão racional, na qual o agente considera tanto o retorno econômico esperado quanto as limitações de energia e distância envolvidas na execução da tarefa.

A primeira condição assegura que a aceitação do serviço resulta em ganho líquido positivo, ou seja, que o preço oferecido pelo serviço compensa os custos de operação, energia e deslocamento. A segunda condição estabelece que o veículo somente pode aceitar a tarefa caso disponha de energia suficiente para completá-la, evitando falhas ou interrupções na execução.

Essas restrições refletem o princípio de racionalidade do modelo, segundo o qual cada agente busca maximizar seu benefício individual respeitando seus próprios limites físicos e operacionais. Esse comportamento é compatível com os fundamentos da

Teoria dos Jogos, uma vez que cada veículo atua como um jogador independente que ajusta sua estratégia de maneira autônoma, respondendo às condições impostas pela plataforma líder e pelas características das tarefas disponíveis.

4.4.4 Função de score da plataforma

Enquanto os veículos tomam decisões individuais orientadas por sua utilidade, a plataforma líder atua de forma centralizada, avaliando globalmente os candidatos disponíveis para cada serviço. Seu objetivo é selecionar veículos que apresentem condições adequadas de confiabilidade, disponibilidade energética e proximidade da tarefa, considerando conjuntamente a eficiência operacional e a sustentabilidade do sistema.

Para isso, o framework SHADAI define uma função de score normalizada, responsável por combinar diferentes métricas em uma mesma escala de comparação. A normalização é necessária para evitar incompatibilidades entre grandezas heterogêneas, como distância, energia e reputação, uma vez que cada parâmetro possui unidades e amplitudes distintas. Dessa forma, todas as variáveis são convertidas para o intervalo $[0, 1]$, o que permite sua combinação de maneira coerente e proporcional.

A função de score é definida pela Equação 6:

$$\text{Score}_i = w_1 \hat{R}_i + w_2 \hat{E}_i + w_3 \hat{D}_i \tag{6}$$

em que:

- $\hat{R}_i$ representa a reputação normalizada do veículo v_i;
- $\hat{E}_i$ corresponde à energia disponível normalizada;
- $\hat{D}_i$ representa a proximidade normalizada em relação à tarefa;
- w_1, w_2 e w_3 são pesos ajustáveis associados a cada critério.

Os parâmetros normalizados são calculados da seguinte forma:

$$\hat{R}_i = \frac{R_i}{R_{\max}} \tag{7}$$

$$\hat{E}_i = \frac{E_i}{E_{\max}^{\text{veic}}} \tag{8}$$

$$\hat{D}_i = 1 - \frac{d_i}{D_{\max}} \tag{9}$$

em que $R_{\max}$ representa o valor máximo admissível de reputação, $E_{\max}^{\text{veic}}$ corresponde ao limite de referência para a energia disponível dos veículos e $D_{\max}$ representa a distância máxima considerada no cenário urbano simulado. Diferentemente de $E_{\max}^{\text{serv}}$, utilizado na função de utilidade para normalizar a demanda energética das tarefas, o parâmetro $E_{\max}^{\text{veic}}$ está associado à capacidade energética disponível dos agentes veiculares. Dessa forma, as duas normalizações representam grandezas distintas, utilizadas em diferentes etapas do processo decisório do framework.

A utilização do termo inverso na distância normalizada tem como objetivo favorecer veículos mais próximos da tarefa. Assim, quanto menor a distância d_i, maior será o valor de $\hat{D}_i$, aumentando a prioridade do veículo no processo de seleção.

Os pesos utilizados no modelo foram definidos empiricamente com base na importância relativa de cada atributo no contexto operacional do framework SHADAI. Neste trabalho, adotam-se os seguintes valores:

$$w_1 = 0.4, \quad w_2 = 0.3, \quad w_3 = 0.3 \tag{10}$$

Dessa forma, a reputação possui maior influência no processo decisório da plataforma, priorizando veículos historicamente confiáveis, enquanto energia disponível e proximidade atuam como fatores complementares de eficiência operacional.

A seleção final ocorre pela maximização da função de score, isto é, a plataforma escolhe o veículo que apresenta o maior valor de Score_i dentre os candidatos elegíveis. Essa abordagem permite combinar múltiplos critérios de maneira balanceada e adaptativa, tornando o processo de alocação mais robusto em cenários urbanos dinâmicos e heterogêneos.

Embora a Qualidade de Serviço (QoS) constitua um aspecto relevante para a alocação de recursos em ambientes VaaS, o framework SHADAI não incorpora diretamente métricas específicas de QoS, como latência, *jitter*, perda de pacotes, vazão de dados (*throughput*) ou cumprimento de prazos de execução, em sua função de *score*. Na modelagem implementada, a seleção dos provedores considera critérios operacionais relacionados à reputação, à disponibilidade energética e à proximidade em rela-

ção à tarefa solicitada. Esses fatores contribuem para a priorização de veículos com condições consideradas mais adequadas à execução dos serviços, mas não constituem uma medição direta da QoS. Dessa forma, a avaliação realizada concentra-se nos critérios de seleção e no comportamento operacional dos agentes, sem estabelecer garantias explícitas de desempenho dos serviços.

4.4.5 Atualização dinâmica da reputação

No framework SHADAI, a reputação é utilizada como um mecanismo para representar a confiabilidade e o histórico de desempenho dos veículos ao longo das interações realizadas no sistema. Esse parâmetro influencia diretamente o processo de seleção da plataforma, atuando como um fator de priorização para veículos que demonstram comportamento consistente e bom desempenho na execução das tarefas.

A evolução da reputação é descrita por uma regra de atualização incremental, formalizada na Equação 11:

$$R_i(t+1) = \begin{cases} R_i(t) + 1, & \text{se o serviço for concluído com sucesso;} \\ R_i(t) - 1, & \text{caso contrário.} \end{cases} \tag{11}$$

Na Equação 11, $R_i(t)$ representa o nível de reputação do veículo v_i antes da atualização, enquanto $R_i(t+1)$ corresponde ao valor obtido após o registro do resultado de uma execução. A atualização ocorre ao término de cada serviço atribuído ao veículo, não sendo realizada em intervalos fixos de tempo. Quando a tarefa é concluída com sucesso, a reputação do agente é incrementada em uma unidade. Em contrapartida, situações registradas como falha resultam na redução de uma unidade. Dessa forma, a frequência de atualização depende da quantidade de serviços finalizados por cada veículo ao longo da simulação, permitindo que seu histórico de desempenho seja considerado nas decisões posteriores da plataforma.

O mecanismo reputacional adotado no SHADAI utiliza uma avaliação baseada no resultado final da execução do serviço, sem considerar o percentual de conclusão da tarefa ou o esforço realizado pelo veículo antes de uma eventual falha. Assim, mesmo que uma parcela significativa do serviço tenha sido executada, o registro de falha resulta na redução da reputação, independentemente do progresso alcançado. Essa característica constitui uma simplificação da modelagem implementada, uma vez que

não são considerados níveis intermediários de conclusão das tarefas.

Esse mecanismo permite que o sistema incorpore informações históricas ao processo decisório da plataforma, favorecendo veículos que apresentem maior regularidade operacional ao longo do tempo. Como consequência, agentes com melhor reputação tendem a obter valores mais elevados na função de score, aumentando sua prioridade no processo de seleção de tarefas futuras.

Além de refletir o desempenho individual, a atualização reputacional contribui para tornar o processo de alocação mais consistente e previsível ao longo das interações. Esse mecanismo também auxilia na redução de comportamentos oportunistas, incentivando a participação cooperativa e a manutenção da qualidade dos serviços executados.

Após cada atualização, o valor de reputação R_i é utilizado para calcular sua representação normalizada $\hat{R}_i$, conforme a Equação 7. Esse valor normalizado é empregado diretamente na função de *score* da plataforma, juntamente com os indicadores normalizados de energia disponível e proximidade da tarefa. Dessa forma, a reputação atualizada influencia a avaliação dos veículos nos ciclos subsequentes de seleção, sem que seja necessária uma normalização adicional do *score*.

4.4.6 Heurística do framework SHADAI

O framework SHADAI incorpora uma heurística de decisão responsável por orientar tanto o comportamento individual dos veículos quanto o processo global de seleção realizado pela plataforma líder. Essa abordagem busca equilibrar eficiência operacional, adaptabilidade e diversidade na alocação de tarefas, o que permite que o sistema opere de maneira dinâmica em cenários urbanos heterogêneos.

No nível local, a estratégia racional adotada pelos veículos consiste em uma regra de decisão baseada na utilidade individual e nas restrições energéticas de cada agente. Ao avaliar uma solicitação de serviço, o veículo considera a utilidade esperada da tarefa e verifica se dispõe de energia suficiente para sua execução. Dessa forma, a participação somente é considerada quando a utilidade calculada é positiva ($U_i > 0$) e a energia disponível é suficiente para atender à demanda do serviço ($E_i \geq E_s$). Essa estratégia representa o comportamento racional dos agentes dentro das condições estabelecidas pelo modelo, enquanto a seleção final entre os veículos elegíveis

permanece sob responsabilidade da plataforma líder.

No nível global, a plataforma utiliza a função de score para classificar os candidatos elegíveis e selecionar o veículo mais adequado para cada serviço. Entretanto, a adoção de uma estratégia puramente determinística poderia concentrar sucessivas seleções em um mesmo conjunto reduzido de agentes, reduzindo a diversidade operacional do sistema.

A fim de mitigar esse efeito, o framework incorpora uma abordagem baseada no mecanismo ε-*greedy*. Nesse mecanismo, a plataforma prioriza a seleção do veículo com maior *score* na maior parte das decisões, mas mantém uma pequena probabilidade de realizar uma escolha aleatória entre os candidatos elegíveis, permitindo explorar diferentes alternativas de alocação.

Formalmente, o processo de seleção pode ser descrito pela Equação 12:

$$\text{Seleção} = \begin{cases} \arg\max(S_i), & \text{com probabilidade } (1-\epsilon) \\ \text{candidato aleatório}, & \text{com probabilidade } \epsilon \end{cases} \tag{12}$$

em que $\varepsilon \in [0, 1]$ representa o parâmetro de exploração do sistema. Valores reduzidos de ε favorecem decisões mais determinísticas e orientadas ao melhor *score* disponível, enquanto valores mais elevados aumentam a diversidade de seleção entre os agentes candidatos.

É importante reconhecer que a adoção do mecanismo ε-*greedy* afasta o SHADAI da formulação clássica dos jogos de Stackelberg, uma vez que introduz decisões exploratórias que não decorrem da determinação formal de um equilíbrio. Isso ocorre porque, em determinadas situações, a plataforma pode selecionar aleatoriamente um veículo elegível, em vez de priorizar exclusivamente aquele com maior *score*. Dessa forma, a exploração probabilística constitui uma estratégia heurística voltada à diversificação da alocação de tarefas, não sendo derivada de uma solução de equilíbrio de Stackelberg. Assim, embora o SHADAI preserve a estrutura hierárquica entre líder e seguidores, seu processo de seleção não corresponde à resolução formal desse modelo de jogo.

Além disso, o framework SHADAI incorpora um mecanismo de suavização temporária de seleção, denominado *cooldown*, aplicado aos veículos recentemente escolhidos pela plataforma. Dessa forma, após a seleção de um veículo, considera-se o

tempo transcorrido desde sua última escolha para reduzir temporariamente sua prioridade nas decisões subsequentes. Essa abordagem busca evitar a concentração de tarefas em um conjunto reduzido de agentes, favorecendo a participação de outros veículos elegíveis.

O mecanismo de *cooldown* foi adotado como uma estratégia heurística voltada à diversificação da seleção dos veículos. Entretanto, os parâmetros referentes à duração do período de prioridade reduzida e à intensidade dessa redução foram definidos empiricamente, sem uma derivação matemática formal ou uma análise sistemática de sensibilidade. Essa característica indica a possibilidade de aperfeiçoamento da parametrização do mecanismo.

A combinação entre racionalidade local, seleção baseada em score e exploração probabilística confere ao framework SHADAI um comportamento híbrido e adaptativo, que permite maior flexibilidade operacional diante das variações de demanda, disponibilidade de recursos e heterogeneidade dos veículos participantes.

4.4.7 Considerações finais da modelagem

A modelagem matemática apresentada nesta seção sintetiza a estrutura conceitual e operacional do framework SHADAI, formalizando o processo de tomada de decisão entre os veículos e a plataforma líder no contexto do modelo VaaS. O conjunto de equações, métricas normalizadas e heurísticas desenvolvido estabelece uma base consistente para compreender as interações entre os agentes, conciliando critérios econômicos, energéticos, espaciais e reputacionais sob uma perspectiva hierárquica e adaptativa.

A inspiração do SHADAI nos jogos de Stackelberg concentra-se na estrutura hierárquica de interação entre os agentes, caracterizada pela relação entre líder e seguidores. No contexto do framework, essa característica é representada pela plataforma central, que assume o papel de líder, e pelos veículos participantes, que desempenham o papel de seguidores. Dessa forma, a distinção entre esses papéis constitui o principal elemento conceitual dos jogos de Stackelberg incorporado à organização do modelo.

Entretanto, o SHADAI não constitui uma formulação completa de um jogo de Stackelberg, uma vez que não contempla a resolução formal de um problema de otimiza-

ção hierárquica nem a determinação de um equilíbrio entre líder e seguidores. Assim, essa estrutura hierárquica é empregada como referência conceitual para organizar as interações entre os agentes, enquanto a seleção dos veículos é realizada por meio dos mecanismos heurísticos adotados no framework SHADAI.

Além disso, a inclusão de mecanismos de reputação e de heurísticas probabilísticas, como a estratégia ϵ-*greedy*, contribui para tornar o modelo mais adaptativo e menos determinístico. Em conjunto com o mecanismo temporário de suavização de seleção (*cooldown*), essas estratégias auxiliam na redução da concentração excessiva de tarefas em poucos agentes, favorecendo uma distribuição mais equilibrada das execuções ao longo do tempo e promovendo maior diversidade operacional entre os veículos participantes.

A utilização de variáveis normalizadas também permite compatibilizar diferentes grandezas presentes no sistema, como energia, distância e tempo de execução, assegurando coerência matemática na composição das funções de utilidade e score utilizadas pela plataforma.

Uma limitação da modelagem proposta está relacionada à ausência de uma representação explícita do tamanho das tarefas, considerando aspectos como volume de dados ou carga computacional necessária para sua execução. Embora os serviços sejam caracterizados por parâmetros como demanda energética e tempo estimado de execução, essas variáveis não permitem analisar isoladamente a influência do tamanho das tarefas sobre o processo de alocação. Dessa forma, essa característica não foi contemplada diretamente na formulação desenvolvida, constituindo uma simplificação adotada em razão do escopo estabelecido para esta pesquisa.

Portanto, a modelagem matemática aqui delineada constitui o núcleo teórico do framework SHADAI, servindo como base para as etapas de simulação e experimentação apresentadas na sequência. A partir dessa formulação, foi possível analisar o comportamento do sistema em diferentes cenários operacionais, densidades veiculares e condições de execução, avaliando o impacto das variáveis de decisão e das estratégias propostas.

4.5 CENÁRIO DE EXECUÇÃO DO FRAMEWORK

O modelo é projetado para operar em ambientes urbanos inteligentes que adotam o modelo VaaS. Nesse contexto, veículos conectados atuam como unidades móveis e distribuídas que oferecem, sob demanda, serviços computacionais, logísticos ou de monitoramento. A gestão desses recursos é feita por uma plataforma centralizada responsável por aplicar políticas de precificação e incentivos, de forma dinâmica e adaptativa.

A arquitetura de funcionamento do sistema baseia-se em três níveis principais. A camada superior é ocupada pela plataforma de orquestração central, hospedada na nuvem, que atua como o agente líder no modelo de Stackelberg. Essa camada concentra as decisões estratégicas do sistema, como a definição dinâmica de preços, critérios de participação, políticas de incentivo e gestão de reputação. Além disso, processa dados contextuais em tempo real, armazena informações históricas e aplica algoritmos adaptativos com base em aprendizado de máquina, garantindo a escalabilidade e a evolução contínua do modelo.

A camada intermediária representa os agentes solicitantes de serviço, como aplicações urbanas, empresas, sensores ambientais ou plataformas logísticas. São esses componentes que enviam as solicitações computacionais, logísticas ou de monitoramento à plataforma de orquestração, especificando parâmetros como prioridade, localização e tipo de serviço.

Por fim, a camada inferior é composta pelos veículos conectados, que atuam como agentes seguidores. Equipados com conectividade e capacidade computacional, esses veículos reagem às políticas definidas pelo agente líder, avaliando individualmente sua participação por meio de funções de utilidade que consideram esforço, tempo de serviço, custo energético e recompensa esperada.

Todo esse ecossistema depende de uma infraestrutura de comunicação eficiente e de baixa latência, essencial para garantir a sincronia entre as camadas. Essa conectividade é o que possibilita o recebimento contínuo de demandas, a precificação dinâmica, a alocação eficaz dos recursos e a aplicação em tempo real das estratégias de incentivo e fidelização.

4.6 FERRAMENTAS E TECNOLOGIAS UTILIZADAS

Nesta seção, são descritas as ferramentas e tecnologias empregadas para o desenvolvimento, simulação e análise do framework SHADAI. A seleção desses recursos buscou proporcionar viabilidade prática, flexibilidade analítica e compatibilidade com os objetivos desta pesquisa. Ressalta-se que, embora o conjunto tecnológico tenha sido consolidado durante o processo experimental, sua estrutura modular permite futuras expansões e adaptações conforme a evolução do trabalho.

Para a simulação do ambiente urbano e da dinâmica veicular, foi utilizado o SUMO (***S**imulation of **U**rban **MO**bility*), um simulador de tráfego de código aberto. O SUMO permite a modelagem detalhada de cenários urbanos, incluindo a definição de rotas e fluxos de tráfego (DLR, 2025).

A comunicação entre o framework SHADAI e o simulador SUMO foi realizada por meio da interface TraCI (*Traffic Control Interface*), que permite acessar informações sobre o estado e a movimentação dos veículos durante a simulação. Esses dados são utilizados pelos módulos do SHADAI, implementados em Python, para apoiar o processo de atribuição de tarefas e o acompanhamento das condições operacionais dos agentes. O gerenciamento da disponibilidade energética e a atualização da reputação são realizados pelas rotinas do próprio framework, conforme as regras estabelecidas na modelagem proposta.

O ambiente de desenvolvimento adotado foi o *Visual Studio Code*, em razão de sua integração com o ecossistema Python, suporte a controle de versões e compatibilidade com bibliotecas voltadas à simulação e análise de dados. Essa escolha proporcionou maior flexibilidade e organização durante o desenvolvimento iterativo do framework e dos experimentos realizados.

A implementação do modelo foi realizada em Python, linguagem escolhida devido à sua simplicidade de integração com o SUMO, ampla disponibilidade de bibliotecas científicas e flexibilidade para prototipação de algoritmos adaptativos e sistemas multiagente. O framework incorpora mecanismos heurísticos de decisão, atualização dinâmica de reputação e estratégias probabilísticas de seleção, o que permite representar o comportamento dos agentes de forma modular e extensível.

Complementarmente, as análises exploratórias e a avaliação dos resultados experimentais foram conduzidas com o auxílio de ferramentas de visualização e mani-

pulação de dados baseadas em Python, possibilitando a geração de gráficos, séries temporais e análises comparativas entre diferentes cenários de execução.

O conjunto de tecnologias adotado fornece uma infraestrutura computacional integrada para simulação de tráfego, modelagem matemática e análise de desempenho em um fluxo experimental unificado. Essa abordagem favorece a reprodutibilidade dos experimentos e possibilita futuras extensões do framework SHADAI em cenários mais complexos e heterogêneos.

4.7 MÉTRICAS E INDICADORES DE AVALIAÇÃO

Após a definição conceitual e matemática do framework SHADAI, torna-se necessário estabelecer métricas capazes de avaliar o comportamento operacional do sistema em diferentes cenários de execução. Essas métricas permitem analisar a efetividade das estratégias de seleção, reputação e balanceamento implementadas no modelo, fornecendo indicadores quantitativos para comparação entre diferentes configurações experimentais.

As avaliações realizadas neste trabalho consideram tanto métricas individuais dos veículos quanto indicadores globais do sistema, permitindo observar aspectos relacionados à eficiência operacional, distribuição de tarefas, robustez e estabilidade do ambiente VaaS. A definição desse conjunto de métricas foi orientada pela análise exploratória dos trabalhos relacionados, que abrangem diferentes áreas associadas à computação veicular, aos mecanismos de incentivo e à alocação de recursos em ambientes distribuídos. Considerando a diversidade de abordagens e objetivos desses estudos, foram reunidos indicadores que permitem avaliar, de maneira complementar, diferentes aspectos do funcionamento do SHADAI, como utilidade dos participantes, disponibilidade energética, reputação e comportamento das estratégias de seleção. Dessa forma, buscou-se estabelecer um conjunto de métricas compatível com as características e os mecanismos implementados no framework.

Dentre as principais métricas analisadas, destacam-se:

- **Score médio dos veículos selecionados**: utilizado para avaliar a qualidade geral das decisões tomadas pela plataforma ao longo das execuções;
- **Utilidade média**: representa o retorno líquido obtido pelos veículos participan-

tes, considerando custos operacionais, energia, distância e tempo de execução;

- **Distribuição de tarefas**: analisa o equilíbrio na alocação de serviços entre os veículos, verificando possíveis concentrações excessivas de execução em determinados agentes;
- **Energia residual média**: utilizada para observar o impacto das tarefas sobre os recursos energéticos disponíveis dos veículos ao longo da simulação;
- **Evolução reputacional**: avalia o comportamento adaptativo dos agentes e o impacto do mecanismo de reputação na priorização dos veículos;
- **Taxa de participação**: mede a quantidade de veículos aptos e efetivamente selecionados durante os ciclos de execução;
- **Robustez sob comportamento malicioso**: utilizada para avaliar o impacto de veículos maliciosos em cenários de ataque, incluindo estratégias de ganância e flood de candidaturas;
- **Comparação entre estratégias de seleção**: considera diferentes modos de operação do sistema, incluindo seleção aleatória, estratégia gulosa (*greedy*), modelo sem reputação e o framework SHADAI completo.

Além das métricas individuais, os experimentos também consideram diferentes densidades veiculares e configurações de cenário, o que permite analisar o comportamento do framework em ambientes mais densos ou mais esparsos. Essa abordagem possibilita investigar aspectos relacionados à adaptabilidade, estabilidade operacional e potencial de escalabilidade do sistema.

Os indicadores definidos nesta seção constituem a base para as análises experimentais apresentadas no capítulo seguinte, o que permite avaliar a coerência prática do framework SHADAI, bem como identificar suas limitações e possibilidades de aprimoramento futuro.

5 RESULTADOS E DISCUSSÕES

Neste capítulo, são apresentados os resultados experimentais da pesquisa, iniciando-se pela descrição das condições de execução das simulações e dos cenários considerados, seguida da análise e discussão dos resultados obtidos. Ao final, são sintetizadas as principais implicações desses resultados e apresentadas as contribuições científicas e as publicações decorrentes do trabalho, relacionadas aos campos da mobilidade inteligente e do modelo *Vehicle-as-a-Service* (VaaS).

Em seguida, são apresentados os resultados obtidos a partir da implementação e da simulação do framework SHADAI, considerando os parâmetros, cenários e critérios de avaliação definidos no capítulo anterior. Essa etapa tem como objetivo analisar o comportamento do modelo quanto à alocação de tarefas, à evolução da reputação, à utilidade dos veículos, à qualidade das decisões e à eficiência operacional no contexto VaaS.

As análises abrangem aspectos quantitativos, relacionados às métricas de desempenho, score, utilidade, reputação e energia residual, bem como aspectos qualitativos associados à dinâmica de seleção e ao comportamento do sistema ao longo das execuções simuladas. Busca-se, assim, compreender de que forma os parâmetros de ponderação, as estratégias de seleção e os mecanismos de reputação influenciam o funcionamento do framework em diferentes condições operacionais.

Os resultados e discussões estão organizados nas seguintes subseções:

(5.1) **Configuração do ambiente experimental**, na qual são descritas as condições de execução das simulações, o ambiente utilizado e os parâmetros adotados;

(5.2) **Definição dos cenários experimentais**, na qual são apresentados os cenários considerados para a avaliação do framework SHADAI;

(5.3) **Análise dos resultados**, na qual são apresentados e interpretados os dados obtidos nas simulações;

(5.4) **Discussão dos Resultados à Luz do Estado da Arte**, na qual são estabelecidas relações entre os resultados obtidos e as propostas existentes na literatura;

(5.5) **Síntese e Implicações dos Resultados**, na qual são destacadas as principais conclusões e implicações decorrentes da avaliação experimental;

(5.6) **Contribuições**, na qual são apresentadas as contribuições científicas e as publicações decorrentes da pesquisa.

5.1 CONFIGURAÇÃO DO AMBIENTE EXPERIMENTAL

Os experimentos realizados para avaliação do framework SHADAI foram conduzidos em um ambiente de simulação projetado para reproduzir, de forma controlada, as interações entre veículos e a plataforma de coordenação de serviços. A implementação foi desenvolvida sobre o simulador SUMO, amplamente utilizado em estudos de mobilidade inteligente, e integrado ao modelo por meio da interface TraCI, que possibilita o controle dinâmico dos agentes e a coleta contínua de dados durante a simulação.

O cenário urbano adotado corresponde a uma malha viária de média complexidade, composta por múltiplas interseções e controladores semafóricos automatizados, de modo a representar um contexto operacional realista. O limite temporal das simulações foi estabelecido em 3600 segundos, correspondendo a uma hora de tempo simulado. A adoção desse intervalo encontra precedente na literatura, em estudo que utiliza o simulador SUMO para a avaliação de mecanismos de controle de tráfego e emprega a mesma duração como horizonte experimental (TANG et al., 2026). No contexto do SHADAI, esse limite foi utilizado para acompanhar sucessivos ciclos de solicitação, seleção e execução de tarefas, permitindo observar a evolução temporal dos indicadores de reputação, utilidade e *score* dos veículos. Além disso, a utilização de um horizonte temporal comum favorece a comparação entre os diferentes cenários experimentais. Ressalta-se que essa duração delimita o período de observação considerado, não implicando necessariamente a convergência dos indicadores ou a representação do comportamento do sistema em intervalos mais prolongados.

Durante o processo experimental, o framework SHADAI foi responsável pela geração periódica de solicitações de serviço, representando tarefas típicas de um ecossistema veicular cooperativo em ambiente urbano. Essas solicitações foram formuladas

com diferentes níveis de complexidade computacional, definidos a partir de variações nas demandas energéticas, na duração de execução e no valor de recompensa associado a cada tarefa. Entre os serviços simulados incluem-se atividades como Processamento de Imagem Urbana, Agregação de Dados de Sensores, Reencaminhamento de Dados (Edge Relay), Atualização de Modelos Locais (ML Retraining) e Diagnóstico e Sincronização Veicular, refletindo cenários realistas de aplicações em redes veiculares de computação em borda.

A decisão de cada veículo quanto à aceitação ou rejeição de um serviço foi conduzida de maneira autônoma, com base nos critérios de racionalidade individual definidos na modelagem matemática. Cada agente avaliou o retorno esperado, o custo energético estimado e as restrições operacionais para determinar se a execução da tarefa resultaria em utilidade positiva sob as condições vigentes. A plataforma líder, por sua vez, atuou como agente central de coordenação, responsável pela seleção do veículo mais adequado a cada tarefa. Essa escolha foi realizada por meio de uma função de score ponderada, que integra fatores relacionados à reputação acumulada, à disponibilidade energética e à proximidade em relação à tarefa solicitada, considerando simultaneamente aspectos de eficiência operacional e distribuição das tarefas entre os agentes participantes.

Ao longo da simulação, todas as interações entre a plataforma e os veículos foram registradas em arquivos de histórico, o que viabilizou o acompanhamento detalhado da evolução de variáveis-chave como energia residual, reputação, número de serviços concluídos e ganhos acumulados. Esses registros serviram de base para análises quantitativas e comparativas, a partir das quais foi possível avaliar o comportamento do sistema sob diferentes condições operacionais e observar padrões relacionados ao desempenho e à adaptabilidade do framework.

A configuração experimental foi concebida de forma a privilegiar a reprodutibilidade e a coerência metodológica. A execução controlada de múltiplos ciclos de oferta, seleção e conclusão de serviços possibilitou a observação de comportamentos estáveis ao longo do tempo, de modo que as análises subsequentes, em especial as relacionadas ao desempenho, distribuição de tarefas e adaptabilidade do sistema, se fundamentem em uma base empírica consistente e verificável.

Ao final, a simulação foi conduzida de forma iterativa até o atendimento dos critérios

de parada definidos.

A execução era interrompida quando uma das seguintes condições era satisfeita:

$$t \geq T_{\text{max}} \quad \text{ou} \quad N_{\text{req}} \geq N_{\text{max}}$$

em que t representa o tempo total de execução, T_{max} o limite temporal estabelecido (3600 s), N_{req} o número de requisições processadas e N_{max} o número máximo de tarefas simuladas.

Esses limites favorecem a estabilidade computacional e consistência experimental, mantendo a abrangência temporal da simulação compatível com sua viabilidade de execução.

5.2 DEFINIÇÃO DOS CENÁRIOS EXPERIMENTAIS

Com o objetivo de avaliar o comportamento do framework SHADAI sob diferentes condições operacionais, foram definidos múltiplos cenários experimentais organizados de maneira incremental. Essa abordagem possibilita analisar não apenas o desempenho do modelo em condições regulares de operação, mas também sua capacidade de adaptação frente a diferentes densidades veiculares e estratégias de seleção.

Cenário base

O primeiro cenário experimental corresponde à configuração padrão do framework SHADAI, utilizada como referência para as demais avaliações conduzidas neste trabalho. Nesse cenário, a plataforma emprega integralmente os mecanismos propostos pelo modelo, incluindo a função de utilidade normalizada, o score multiobjetivo, a atualização dinâmica de reputação, a estratégia ϵ-*greedy* e o mecanismo de suavização temporária de seleção (*cooldown*).

A execução desse cenário teve como finalidade observar o comportamento geral do sistema em condições convencionais de operação, o que permite analisar aspectos relacionados à distribuição de tarefas, utilização energética, evolução reputacional e estabilidade operacional ao longo do tempo.

Cenários com diferentes densidades veiculares

Com o intuito de investigar o comportamento do framework em ambientes caracterizados por diferentes níveis de demanda e competição entre agentes, foram realizados experimentos utilizando três configurações distintas de densidade veicular: 100, 400 e 800 veículos simultaneamente presentes no ambiente de simulação.

A variação da quantidade de veículos permitiu avaliar a capacidade de adaptação, estabilidade e escalabilidade do framework diante do aumento progressivo do número de agentes participantes no ambiente de simulação. Para isso, as configurações com 100, 400 e 800 veículos foram definidas de forma a representar, respectivamente, cenários de baixa, média e alta densidade operacional no contexto VaaS. A configuração de menor densidade possibilita observar o comportamento do sistema em condições reduzidas de concorrência por tarefas e menor complexidade de coordenação entre os agentes. O cenário intermediário permite analisar o funcionamento do framework em condições mais próximas de um ambiente urbano moderadamente movimentado, enquanto o cenário de alta densidade foi concebido para investigar o desempenho do modelo sob maior volume de veículos concorrentes e maior complexidade de gerenciamento das decisões de alocação.

A definição dos quantitativos também considerou a capacidade computacional disponível para a realização dos experimentos, uma vez que o aumento do número de veículos amplia a demanda de processamento do ambiente de simulação. Assim, a escolha das configurações com 100, 400 e 800 veículos buscou conciliar a avaliação de diferentes níveis de participação com a viabilidade computacional das execuções. Ressalta-se que o cenário com 800 veículos corresponde ao maior quantitativo avaliado nesta pesquisa, não representando necessariamente o limite máximo de capacidade ou de escalabilidade do framework SHADAI.

Todos os cenários mantiveram a mesma configuração estrutural do ambiente urbano e os mesmos parâmetros gerais de execução, alterando-se exclusivamente a quantidade máxima de veículos disponíveis durante a simulação.

Cenários comparativos entre estratégias

Além da execução padrão do framework SHADAI, foram conduzidos experimentos comparativos utilizando diferentes estratégias de seleção de veículos, empregadas

como baselines para análise de desempenho do modelo proposto.

A primeira estratégia corresponde ao modo *random*, no qual os veículos candidatos são selecionados aleatoriamente, sem considerar métricas relacionadas à reputação, disponibilidade energética ou proximidade da tarefa. Esse cenário foi utilizado como referência básica para avaliar a efetividade das heurísticas implementadas no framework SHADAI.

O segundo cenário comparativo utiliza uma abordagem gulosa (*greedy*), em que a seleção prioriza os veículos com menor custo associado à execução da tarefa. Essa configuração permite avaliar os impactos de decisões orientadas predominantemente por eficiência local sobre o comportamento global do sistema.

Por fim, foi considerado um cenário denominado *no reputation*, no qual o mecanismo reputacional é removido da função de score da plataforma. O objetivo dessa configuração consiste em analisar a influência da reputação sobre a estabilidade das seleções, a distribuição das tarefas e a priorização de agentes historicamente mais confiáveis.

A utilização desses cenários comparativos possibilita avaliar de maneira mais abrangente a contribuição individual dos mecanismos propostos pelo framework SHADAI, o que permite observar seus impactos sobre eficiência operacional, adaptabilidade e balanceamento da alocação de serviços.

Os cenários descritos anteriormente permitem avaliar o comportamento do framework SHADAI sob diferentes políticas de seleção e distintas densidades veiculares. Entretanto, além da análise de desempenho em condições regulares de operação, torna-se igualmente relevante investigar a robustez do modelo diante de comportamentos adversariais e agentes potencialmente maliciosos. Dessa forma, foram conduzidos experimentos adicionais considerando cenários de ataque e manipulação do processo de seleção, apresentados na subseção seguinte.

Cenários com veículos maliciosos

Além dos cenários convencionais de operação, foram conduzidos experimentos adicionais com o objetivo de avaliar a robustez do framework SHADAI diante da presença de agentes com comportamento malicioso. Esses cenários adversariais foram concebidos para analisar a capacidade do modelo de manter estabilidade operacional,

coerência na seleção dos veículos e distribuição equilibrada das tarefas mesmo sob tentativas de manipulação do processo decisório.

Nos experimentos realizados, aproximadamente 20% dos veículos presentes no ambiente de simulação foram configurados com comportamento malicioso. Esses agentes passaram a adotar estratégias destinadas a interferir no processo de seleção, seja pela tentativa de participação sem atender aos requisitos operacionais, seja pela multiplicação artificial de candidaturas.

O percentual de 20% foi adotado como uma configuração experimental exploratória, com o objetivo de observar os efeitos de comportamentos maliciosos sobre o processo de alocação de tarefas. A utilização dessa mesma proporção nos cenários de ataque por ganância e inundação permitiu comparar seus efeitos sob uma condição comum de participação de veículos maliciosos. Entretanto, reconhece-se como limitação desta pesquisa a ausência de uma análise de sensibilidade desse parâmetro, uma vez que não foram avaliadas diferentes proporções de agentes maliciosos. Dessa forma, os resultados obtidos estão restritos à configuração considerada e não permitem determinar como o framework SHADAI se comportaria diante de percentuais maiores ou menores, nem estabelecer um limite de tolerância à presença desses agentes.

O primeiro cenário adversarial corresponde ao ataque de ganância. Nesse tipo de comportamento, veículos maliciosos tentam participar do processo de seleção mesmo quando não atendem integralmente aos requisitos operacionais estabelecidos, como condições mínimas de utilidade ou adequação à tarefa solicitada. O objetivo desse ataque consiste em simular agentes oportunistas que buscam maximizar ganhos individuais independentemente da viabilidade real de execução do serviço.

O segundo cenário corresponde ao ataque do tipo *flood*. Nessa configuração, veículos maliciosos realizam múltiplas tentativas artificiais de candidatura para uma mesma tarefa, multiplicando sua presença no conjunto de candidatos analisados pela plataforma. Esse comportamento busca aumentar a probabilidade de seleção por meio da sobrecarga do mecanismo de decisão, simulando tentativas de manipulação do processo de alocação de serviços.

A inclusão desses cenários permite investigar o comportamento do framework SHADAI diante de estratégias oportunistas e tentativas de manipulação do processo

de seleção. Além disso, tais experimentos contribuem para avaliar a efetividade dos mecanismos de reputação, seleção probabilística e balanceamento de tarefas empregados pela plataforma, observando sua capacidade de mitigar concentrações indevidas de serviços e reduzir impactos causados por agentes adversariais.

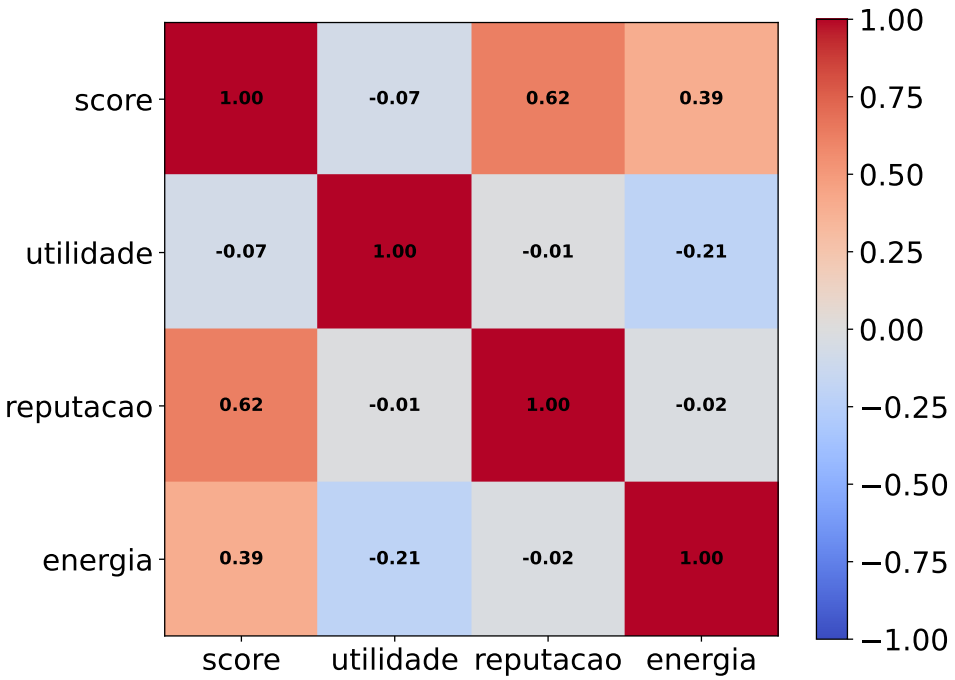
Esses cenários também fornecem subsídios importantes para a análise das limitações e da resiliência do modelo proposto, o que possibilita identificar as condições nas quais o framework mantém seu desempenho e aquelas em que mecanismos adicionais de proteção e validação podem ser necessários.

5.3 ANÁLISE DOS RESULTADOS

Ilustra-se nesta subseção a análise quantitativa dos resultados obtidos a partir da execução do framework SHADAI, considerando as métricas relacionadas à reputação, energia, ganho e desempenho operacional dos veículos simulados. As representações gráficas discutidas a seguir permitem compreender como as variáveis do modelo se inter-relacionam e de que forma os mecanismos de decisão e reputação influenciam o equilíbrio global do sistema.

Apresenta-se na Figura 8 a matriz de correlação entre as principais métricas observadas no framework SHADAI, possibilitando a análise das relações estatísticas entre score, utilidade, reputação e energia residual dos veículos ao final da simulação. De modo geral, os resultados indicam que os mecanismos de decisão implementados pelo modelo produzem interações coerentes entre desempenho operacional, disponibilidade energética e priorização dos agentes.

Figura 8 – Matriz de correlação entre métricas finais do framework SHADAI.



Fonte: Elaborado pelo autor, 2026.

Observa-se uma correlação positiva moderada entre score e reputação ($r = 0{,}62$), indicando que veículos com maior reputação tendem a alcançar valores mais elevados de score durante o processo de seleção. Esse comportamento confirma a influência direta do mecanismo reputacional na estratégia de priorização adotada pela plataforma, favorecendo agentes com histórico consistente de participação e desempenho.

Além disso, verifica-se uma correlação positiva entre score e energia residual ($r = 0{,}39$). Esse resultado sugere que a disponibilidade energética também exerce papel relevante na seleção dos veículos, contribuindo para que agentes com melhores condições operacionais mantenham maior capacidade de participação ao longo da simulação. Em conjunto, essas relações indicam que o framework busca equilibrar critérios de confiabilidade e viabilidade operacional no processo de alocação de tarefas.

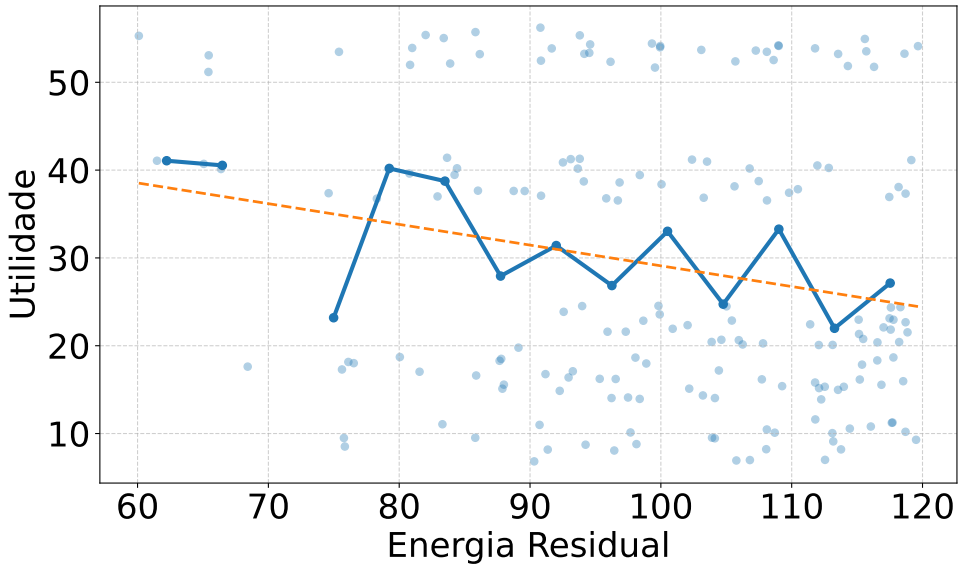
Por outro lado, a utilidade apresentou correlações de baixa intensidade com as demais variáveis analisadas. A relação entre utilidade e score foi praticamente nula ($r = -0{,}07$), enquanto as correlações com reputação ($r = -0{,}01$) e energia ($r = -0{,}21$) também permaneceram reduzidas. Esse comportamento indica que a utilidade atua predominantemente como um mecanismo local e individual de decisão dos agentes, sem exercer influência direta significativa sobre os critérios globais de priorização em-

pregados pela plataforma.

De maneira geral, os resultados evidenciam que o framework SHADAI mantém uma dinâmica relativamente equilibrada entre os fatores considerados no processo de coordenação dos veículos. A predominância das correlações associadas ao score reforça a coerência da modelagem proposta, o que sugere que os mecanismos de reputação e disponibilidade energética contribuem conjuntamente para a organização adaptativa do sistema.

Na Figura 9, apresenta-se a relação entre a energia residual dos veículos ao final da simulação e os valores de utilidade observados durante a execução do framework SHADAI. O gráfico evidencia uma tendência linear moderadamente negativa entre as variáveis, indicando que veículos com menores níveis de energia residual tendem, em média, a apresentar maiores valores de utilidade acumulada ao longo das interações realizadas no ambiente simulado.

Figura 9 – Relação entre energia residual e utilidade dos veículos.



Fonte: Elaborado pelo autor, 2026.

Esse comportamento sugere que agentes com maior participação operacional, ao aceitarem e executarem uma quantidade mais elevada de tarefas, consomem parcela mais significativa de seus recursos energéticos, ao mesmo tempo em que obtêm maiores retornos utilitários em função das recompensas associadas à execução dos serviços. A inclinação negativa observada na linha de tendência reforça a coerência da função de utilidade proposta pelo modelo, o que indica que o consumo energético

está diretamente relacionado ao grau de engajamento dos veículos nas atividades do ecossistema VaaS.

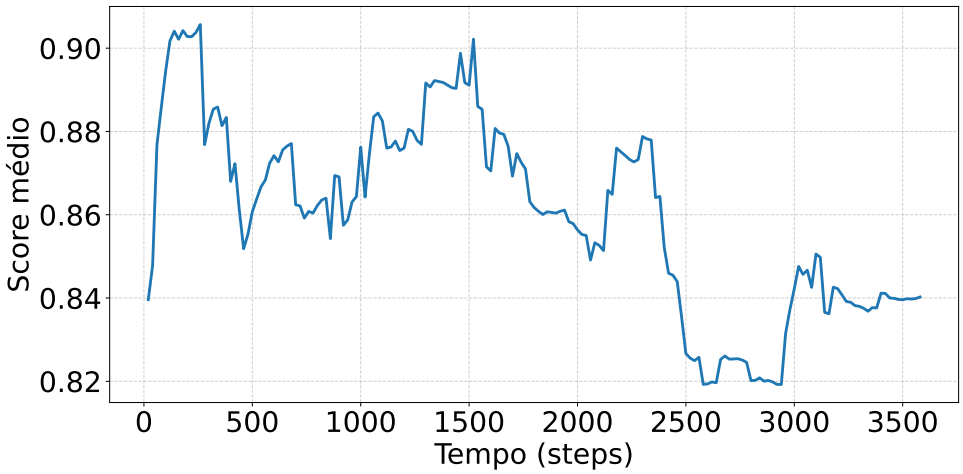
Observa-se, entretanto, uma dispersão considerável dos pontos ao longo do gráfico, indicando que a relação entre energia residual e utilidade não ocorre de maneira estritamente determinística. Veículos com níveis energéticos semelhantes podem apresentar valores distintos de utilidade, o que sugere a influência simultânea de outros fatores relevantes no processo decisório, tais como reputação acumulada, distância em relação às tarefas e dinâmica probabilística de seleção empregada pelo framework.

A linha de média por faixa de energia apresenta ainda oscilações ao longo das diferentes regiões do gráfico, sugerindo a presença de perfis operacionais heterogêneos entre os agentes simulados. Enquanto parte dos veículos adota um comportamento mais conservador, preservando energia e reduzindo sua participação nas tarefas, outros agentes demonstram atuação mais intensiva, aceitando maior consumo energético em troca de maiores níveis de utilidade operacional.

De maneira geral, os resultados indicam que o framework SHADAI mantém uma relação relativamente equilibrada entre utilização energética e retorno operacional, evitando tanto a subutilização excessiva dos recursos disponíveis quanto a concentração absoluta das tarefas em um grupo restrito de veículos.

Exibe-se na Figura 10 a evolução temporal do *score* médio dos veículos ao longo da execução do framework SHADAI. O *score* corresponde à métrica composta utilizada pela plataforma para priorização dos agentes candidatos às tarefas, integrando fatores como reputação acumulada, energia residual, utilidade esperada e critérios operacionais associados ao processo de alocação.

Figura 10 – Evolução temporal do score médio dos veículos.



Fonte: Elaborado pelo autor, 2026.

A curva apresentada corresponde à aplicação de uma média móvel sobre os valores médios de *score*, com o objetivo de suavizar oscilações instantâneas e evidenciar o comportamento global do sistema ao longo da simulação.

Observa-se que o *score* médio permanece relativamente estável durante todo o período de execução, apresentando oscilações moderadas dentro de uma faixa limitada de valores. Esse comportamento sugere que o framework preserva equilíbrio operacional mesmo diante das variações dinâmicas inerentes ao ambiente VaaS, como alterações na disponibilidade energética dos veículos, atualizações reputacionais e redistribuição contínua das tarefas.

As variações observadas ao longo da curva indicam que o sistema mantém capacidade adaptativa sem convergir para estados rígidos ou excessivamente determinísticos. Em determinados intervalos da simulação, percebe-se uma leve redução do *score* médio, possivelmente associada ao desgaste energético acumulado dos agentes mais ativos ou ao aumento da concorrência entre veículos disponíveis. Ainda assim, o framework apresenta capacidade de estabilização progressiva, mantendo níveis consistentes de desempenho ao longo do tempo.

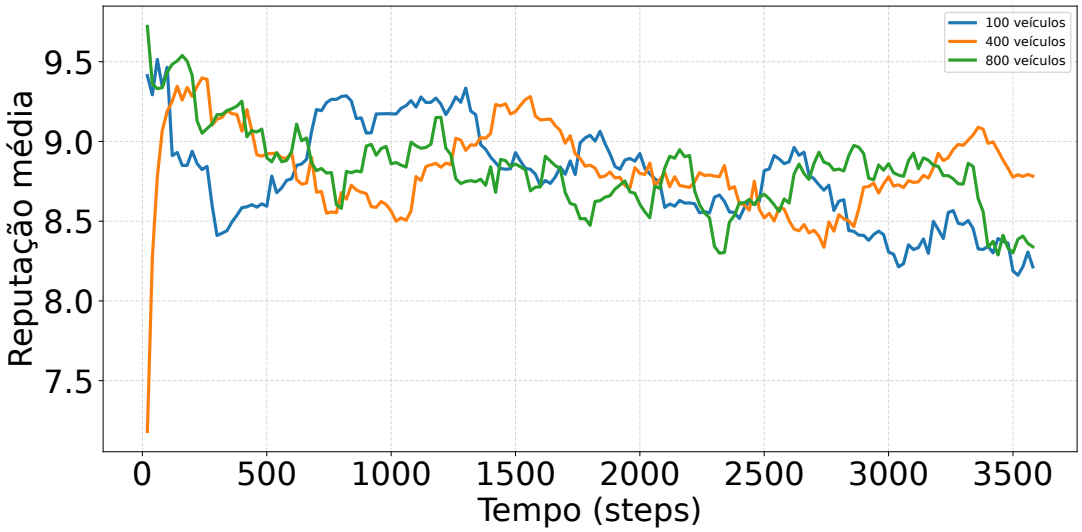
De maneira geral, os resultados sugerem que os mecanismos de decisão e balanceamento empregados pelo SHADAI contribuem para a manutenção de um comportamento operacional estável e adaptativo, favorecendo a distribuição contínua das oportunidades de participação entre os agentes do ambiente simulado.

Análise dos cenários com diferentes densidades veiculares

Esta subseção apresenta a análise dos resultados obtidos a partir da execução do framework SHADAI em cenários caracterizados por diferentes densidades veiculares. O objetivo desses experimentos consiste em investigar o comportamento do modelo diante do aumento progressivo do número de agentes participantes no ambiente VaaS, observando aspectos relacionados à estabilidade operacional, adaptação dinâmica e distribuição das interações entre os veículos ao longo da simulação. Para isso, foram considerados três cenários distintos, compostos por 100, 400 e 800 veículos simultaneamente presentes no ambiente de execução, representando diferentes níveis de densidade operacional.

Na Figura 11, apresenta-se a evolução da reputação média dos veículos ao longo da simulação, nos cenários com 100, 400 e 800 veículos. De modo geral, observa-se que os valores médios de reputação permanecem dentro de uma faixa relativamente estável ao longo da execução, mesmo diante do aumento progressivo da densidade veicular no ambiente simulado.

Figura 11 – Evolução temporal da reputação média em diferentes densidades veiculares.



Fonte: Elaborado pelo autor, 2026.

As oscilações observadas nas curvas refletem a natureza dinâmica do processo de seleção e atualização reputacional empregado pelo framework SHADAI. Como a reputação dos agentes é continuamente ajustada em função das interações realizadas e das tarefas executadas, são esperadas oscilações nos valores médios de reputação

ao longo da simulação, especialmente em cenários caracterizados por maior concorrência entre veículos.

Verifica-se ainda que, no cenário com 800 veículos, os valores médios de reputação apresentam maiores variações ao longo da simulação em comparação aos demais cenários analisados. Esse comportamento está associado ao aumento significativo da quantidade de agentes simultaneamente aptos a participar do processo de seleção, ampliando a dinâmica competitiva do ambiente e tornando mais frequentes as alterações nas oportunidades de participação dos veículos ao longo da execução. Em contextos de alta densidade veicular, pequenas variações nos parâmetros considerados pelo framework como reputação, energia residual e utilidade estimada passam a influenciar de forma mais intensa a priorização dos agentes, contribuindo para oscilações mais perceptíveis nas métricas reputacionais médias observadas durante a simulação.

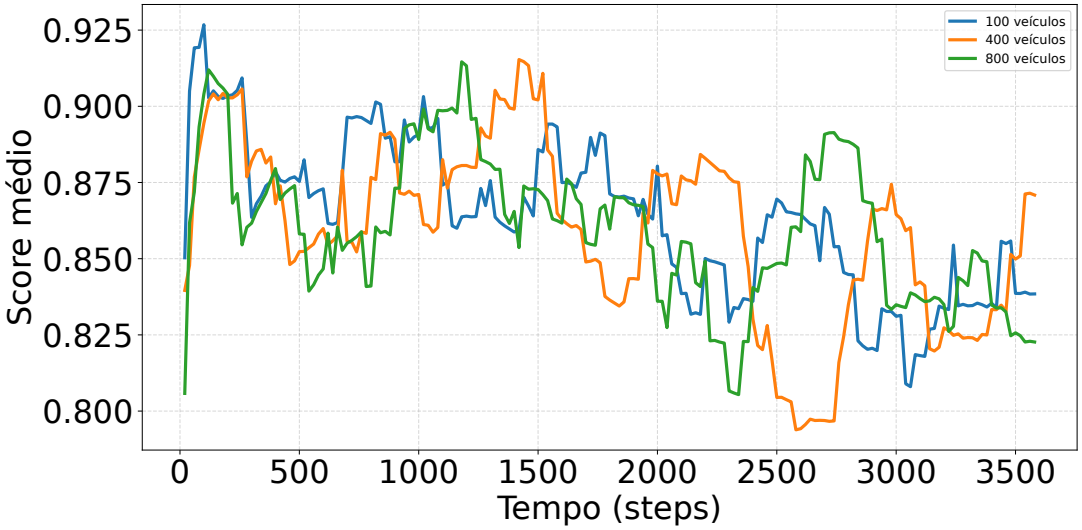
O cenário intermediário, composto por 400 veículos, apresenta comportamento relativamente mais uniforme durante grande parte da execução, com oscilações moderadas e menor incidência de variações abruptas entre os intervalos temporais analisados. Esse comportamento sugere que, nessa configuração, o ambiente mantém uma dinâmica operacional suficientemente diversificada sem produzir níveis excessivos de concorrência entre os agentes participantes. Em contrapartida, o cenário com 100 veículos evidencia oscilações mais perceptíveis em determinados momentos da simulação, possivelmente em função da menor quantidade de agentes disponíveis para redistribuição das tarefas. Nessas condições, a participação recorrente de determinados veículos tende a exercer impacto mais direto sobre os valores médios de reputação observados ao longo do tempo.

De forma geral, os resultados obtidos indicam que o framework SHADAI mantém comportamento operacional consistente mesmo diante de diferentes níveis de densidade veicular. As curvas observadas indicam que o mecanismo reputacional preserva estabilidade ao longo da execução, sem ocorrência de degradações abruptas ou comportamentos altamente discrepantes entre os cenários analisados.

Na Figura 12, observa-se a evolução temporal do *score* médio dos veículos ao longo da simulação. Como o score constitui a principal métrica utilizada pelo framework SHADAI no processo de priorização dos agentes candidatos às tarefas, sua

análise permite observar o comportamento global do mecanismo de decisão sob diferentes níveis de concorrência operacional.

Figura 12 – Evolução temporal do score médio em diferentes densidades veiculares.



Fonte: Elaborado pelo autor, 2026.

De maneira geral, as curvas permanecem dentro de uma faixa relativamente próxima durante toda a execução, indicando que o processo de cálculo e atualização do score mantém comportamento consistente ao longo do tempo. Mesmo diante das oscilações naturais produzidas pelas dinâmicas de seleção, atualização reputacional e consumo energético dos agentes, não são observados comportamentos divergentes ou degradações abruptas nas métricas analisadas.

Observa-se que os cenários de maior densidade apresentam variações mais frequentes ao longo da simulação, refletindo a intensificação da concorrência entre os veículos disponíveis para execução das tarefas. À medida que o número de agentes aumenta, pequenas diferenças entre os parâmetros considerados pelo framework passam a exercer influência mais significativa no processo de seleção, tornando a dinâmica de priorização mais sensível às alterações contextuais do ambiente.

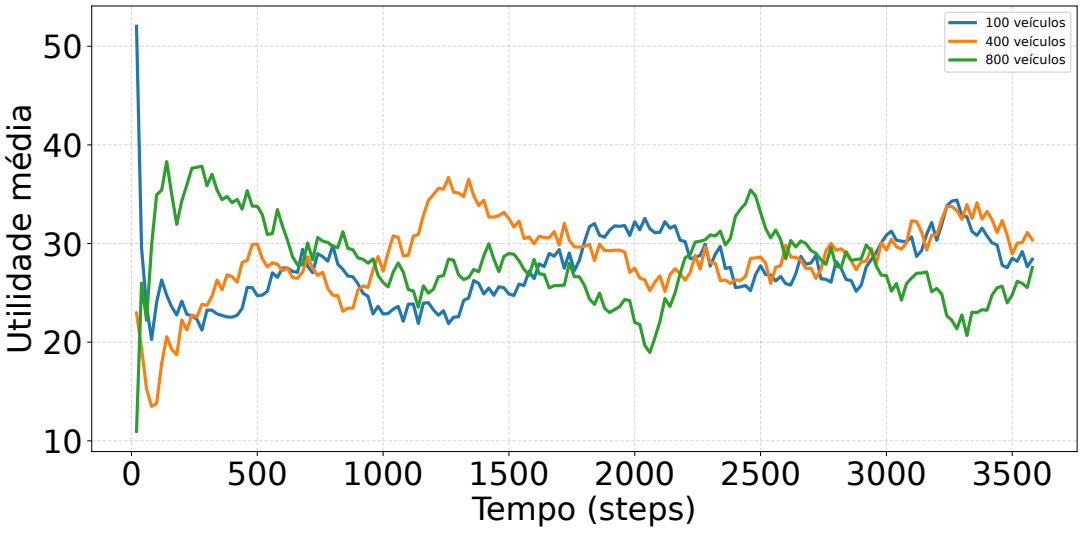
Em determinados intervalos temporais, nota-se também a ocorrência de reduções temporárias no score médio, especialmente nos cenários caracterizados por maior volume de agentes concorrentes. Esse comportamento pode estar associado à redistribuição contínua das oportunidades de participação, bem como às atualizações acumuladas de reputação e energia residual dos veículos mais ativos durante a execução.

Além disso, embora os cenários apresentem padrões distintos de oscilação, as curvas demonstram comportamento operacional compatível ao longo de toda a simulação, preservando níveis relativamente próximos de score médio independentemente da densidade veicular empregada. Esse resultado sugere que o mecanismo de priorização adotado pelo SHADAI permanece funcional mesmo sob diferentes condições de escala operacional, mantendo capacidade adaptativa frente às variações dinâmicas do ambiente VaaS.

De forma geral, os resultados obtidos indicam que o framework mantém estabilidade no processo de seleção dos agentes ao longo do tempo, evidenciando consistência operacional do mecanismo de score mesmo diante do aumento progressivo da quantidade de veículos participantes no ambiente simulado.

Observa-se na Figura 13 a evolução temporal da utilidade média dos veículos ao longo da simulação em diferentes níveis de densidade veicular. A utilidade corresponde à métrica associada ao retorno operacional obtido pelos agentes durante a execução das tarefas, considerando fatores relacionados às recompensas recebidas e aos custos envolvidos na participação do ambiente VaaS.

Figura 13 – Evolução temporal da utilidade média em diferentes densidades veiculares.



Fonte: Elaborado pelo autor, 2026.

Observa-se que os valores médios de utilidade permanecem ativos ao longo de toda a execução em todos os cenários analisados, indicando que o framework mantém funcionamento operacional contínuo mesmo diante do aumento progressivo da quantidade de veículos participantes. Apesar das oscilações naturais presentes nas

curvas, não são identificados comportamentos de degradação abrupta ou perda significativa de desempenho ao longo da simulação.

No cenário com 800 veículos, os valores médios de utilidade apresentam maiores oscilações ao longo da simulação em comparação aos demais cenários analisados. Em ambientes caracterizados por elevada densidade de agentes, o aumento da concorrência pelas tarefas disponíveis tende a tornar mais dinâmica a distribuição das oportunidades de participação. Como consequência, os valores médios de utilidade passam a sofrer oscilações mais frequentes em função das mudanças contínuas no conjunto de veículos selecionados ao longo da execução.

No cenário com menor densidade veicular, observa-se a ocorrência de um pico inicial mais acentuado nos valores médios de utilidade. Esse comportamento pode estar relacionado ao impacto proporcionalmente maior que a participação individual dos agentes exerce sobre a média global em ambientes com quantidade reduzida de veículos disponíveis. À medida que a simulação evolui e ocorre maior redistribuição das tarefas entre os agentes participantes, os valores tendem a apresentar comportamento mais uniforme ao longo do tempo.

O cenário intermediário apresenta oscilações moderadas durante grande parte da execução, mantendo comportamento relativamente contínuo quando comparado aos demais cenários analisados. Tal resultado sugere que diferentes níveis de densidade veicular influenciam diretamente a dinâmica de participação dos agentes e a distribuição das recompensas operacionais no ambiente simulado.

Em síntese, os resultados indicam que o framework SHADAI preserva capacidade operacional consistente mesmo sob diferentes níveis de concorrência entre veículos, mantendo a geração contínua de utilidade para os agentes ao longo da execução e evidenciando a adaptabilidade do processo de alocação adotado pelo sistema.

A análise conjunta dos cenários de densidade veicular permite observar que o framework mantém comportamento operacional consistente mesmo diante do aumento progressivo da quantidade de agentes presentes no ambiente. As métricas de reputação, score e utilidade permanecem funcionalmente estáveis ao longo da execução, ainda que submetidas às oscilações naturais decorrentes da dinâmica de seleção e redistribuição das tarefas. Além disso, os resultados sugerem que o mecanismo de priorização adotado pelo framework preserva capacidade adaptativa frente às variações

de concorrência operacional observadas nos diferentes cenários simulados.

Considerando essas observações, torna-se relevante investigar de que maneira diferentes estratégias de seleção influenciam o comportamento do sistema e a distribuição das tarefas entre os agentes. Nesse contexto, a subseção seguinte apresenta uma análise comparativa entre as estratégias implementadas no ambiente experimental, o que permite avaliar como diferentes critérios de priorização impactam as métricas operacionais do framework SHADAI.

Análise comparativa entre estratégias de seleção

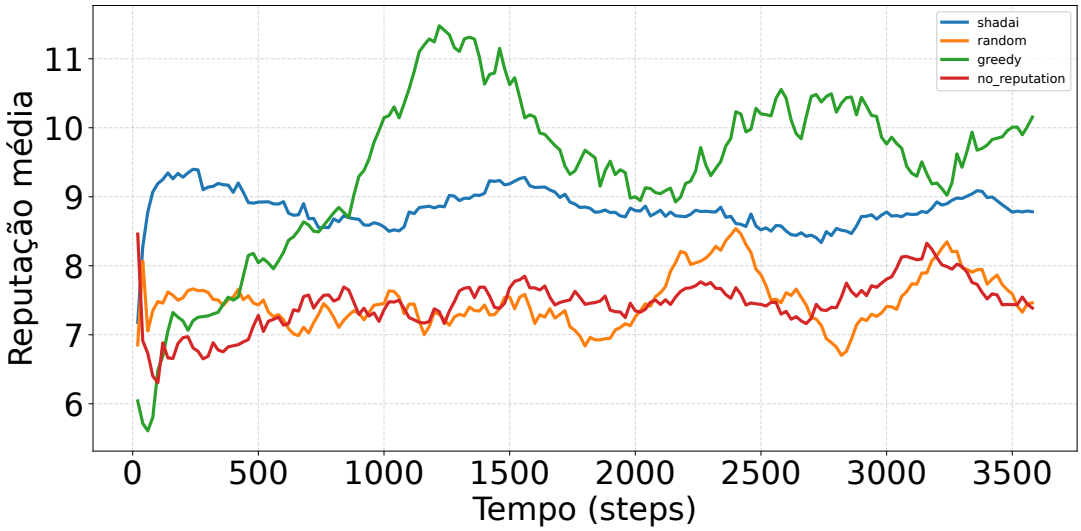
Com o objetivo de analisar o impacto dos diferentes mecanismos de decisão no desempenho operacional do ambiente VaaS simulado, foram realizados experimentos comparando o framework SHADAI com outras estratégias de seleção. Para isso, foram considerados quatro modos distintos de operação: SHADAI, *greedy*, *random* e *no reputation*.

As estratégias avaliadas diferem principalmente nos critérios utilizados para priorização dos veículos durante o processo de alocação das tarefas. Enquanto o SHADAI utiliza uma métrica composta baseada em reputação, energia residual, utilidade e fatores operacionais, as demais abordagens adotam mecanismos simplificados ou parcialmente restritivos de seleção. A estratégia *greedy* prioriza veículos com maior retorno imediato, o modo *random* realiza seleções aleatórias e o cenário *no reputation* desconsidera o componente reputacional durante a tomada de decisão.

Os resultados apresentados a seguir permitem observar como essas diferentes abordagens influenciam a evolução temporal das métricas operacionais do sistema, evidenciando padrões distintos de comportamento reputacional, distribuição de utilidade e dinâmica de participação dos agentes ao longo da simulação.

Na Figura 14, compara-se a evolução temporal da reputação média dos veículos considerando diferentes estratégias de seleção adotadas. durante a execução do ambiente VaaS simulado. Os resultados permitem observar como os distintos mecanismos de decisão influenciam a evolução das métricas reputacionais ao longo do tempo, evidenciando diferenças relevantes no comportamento operacional dos agentes em cada abordagem analisada.

Figura 14 – Comparação temporal da reputação média entre estratégias de seleção.



Fonte: Elaborado pelo autor, 2026.

Observa-se que o framework SHADAI mantém a reputação média em uma faixa relativamente estável durante praticamente toda a simulação, apresentando oscilações moderadas e comportamento menos abrupto em comparação às demais estratégias. Após um crescimento inicial associado ao processo de adaptação dos agentes ao ambiente, os valores reputacionais tendem a permanecer distribuídos dentro de um intervalo consistente, sugerindo que o mecanismo de seleção adotado pelo framework evita variações excessivamente acentuadas na priorização dos veículos.

Em contraste, a estratégia *greedy* apresenta crescimento reputacional significativamente mais elevado ao longo da execução, alcançando os maiores valores médios observados entre todos os cenários analisados. Além disso, observam-se oscilações mais amplas nos valores médios de reputação ao longo da simulação, o que pode estar associado à concentração de seleções em determinados veículos. Esse comportamento sugere maior intensificação do acúmulo reputacional em agentes frequentemente priorizados, característica associada a estratégias orientadas predominantemente pela maximização imediata de retorno.

A estratégia aleatória (*random*), por sua vez, apresenta comportamento mais irregular, com oscilações frequentes e ausência de tendência de crescimento sustentado da reputação média. Como a seleção dos veículos ocorre sem critérios consistentes de priorização, a evolução reputacional tende a permanecer mais dispersa ao longo da execução, reduzindo a consolidação progressiva de desempenho entre os agentes

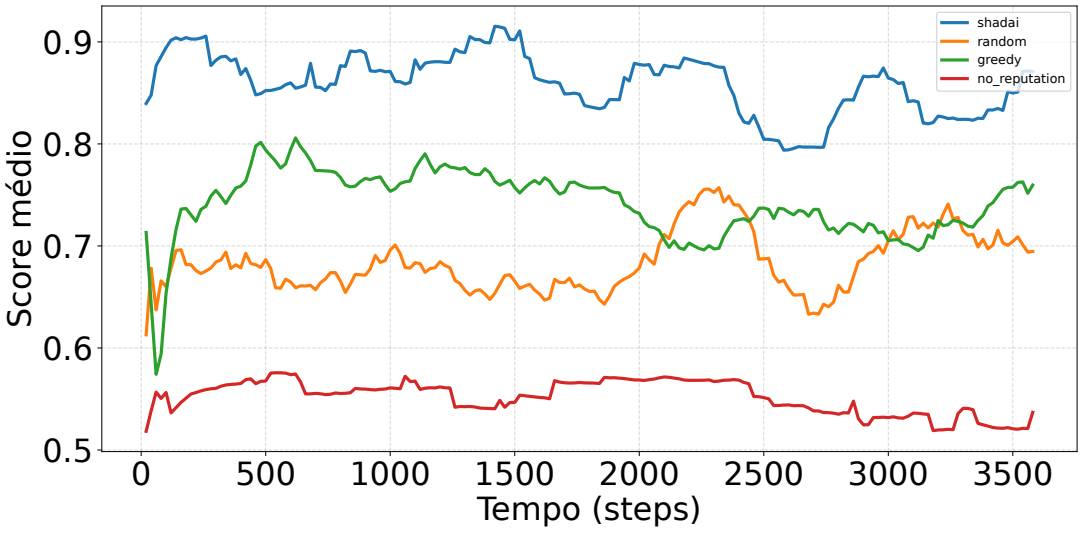
participantes.

Já o cenário *no reputation*, no qual a reputação não participa diretamente do processo de decisão, apresenta valores médios inferiores e menor diferenciação reputacional entre os veículos ao longo do tempo. Esse comportamento sugere que a ausência do componente reputacional na seleção reduz o impacto acumulativo do histórico de desempenho dos agentes, limitando a progressão das métricas reputacionais durante a execução.

De maneira geral, os resultados indicam que o framework SHADAI apresenta comportamento intermediário entre estabilidade operacional e diferenciação reputacional, evitando tanto oscilações excessivamente aleatórias quanto mecanismos de concentração acentuada observados em estratégias mais agressivas de seleção.

Ilustra-se na Figura 15 a comparação da evolução temporal do *score* médio dos veículos entre as diferentes estratégias de seleção avaliadas no ambiente simulado. O score corresponde à métrica composta utilizada para priorização dos veículos candidatos às tarefas, incorporando fatores relacionados à reputação, energia residual, utilidade esperada e condições operacionais associadas ao processo de alocação.

Figura 15 – Evolução temporal do score médio em diferentes estratégias de seleção.



Fonte: Elaborado pelo autor, 2026.

Observa-se que o framework SHADAI mantém, durante praticamente toda a execução da simulação, os maiores valores médios de score em comparação às demais abordagens analisadas. Além disso, a curva apresenta oscilações moderadas dentro de uma faixa relativamente estável, indicando consistência no processo de sele-

ção adotado pelo framework ao longo do tempo. Esse comportamento sugere que a integração simultânea de múltiplos critérios de decisão contribui para preservar a qualidade média dos veículos selecionados durante a execução das tarefas.

A partir dos valores representados no gráfico, estimam-se valores médios de *score* próximos de $0{,}86$ para o SHADAI e de $0{,}69$ para a estratégia de seleção aleatória (*random*) ao longo da simulação. Essa diferença corresponde a uma melhoria relativa da ordem de 25% em favor do SHADAI, considerando a estimativa das curvas e as condições experimentais avaliadas.

A estratégia *greedy* também apresenta valores relativamente elevados em determinados intervalos da simulação, sobretudo nas etapas intermediárias, porém com oscilações mais acentuadas nos valores médios de *score* ao longo da execução.Esse comportamento indica que abordagens excessivamente orientadas à maximização imediata de ganhos podem produzir períodos de desempenho elevado, mas com menor regularidade operacional ao longo da execução contínua do sistema.

Por sua vez, a estratégia random mantém valores intermediários de score durante grande parte da simulação, apresentando oscilações mais acentuadas e menor consistência temporal. Tal resultado evidencia que a ausência de critérios estruturados de priorização reduz a capacidade de manutenção de padrões estáveis de seleção, tornando o desempenho mais dependente das condições momentâneas do ambiente.

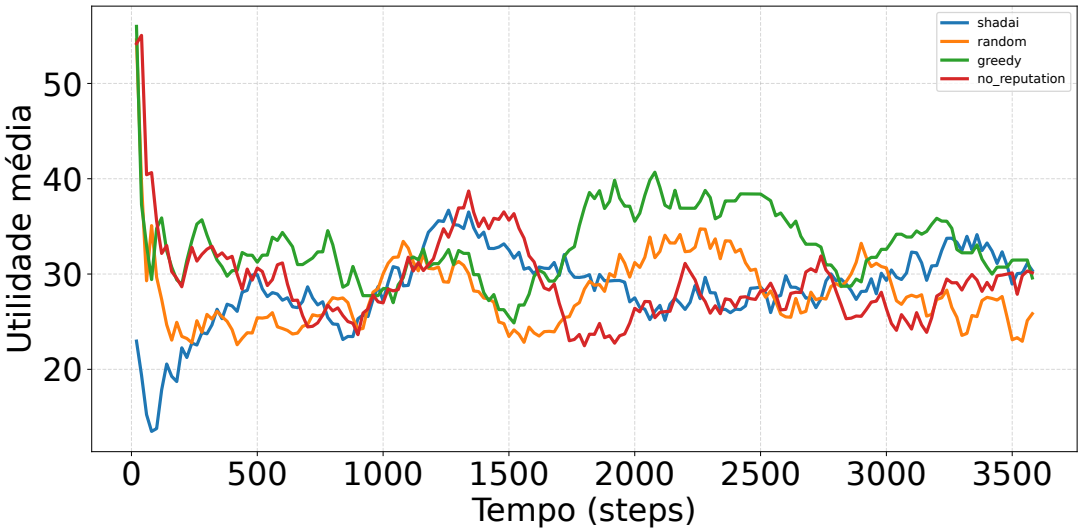
O cenário no reputation apresenta os menores valores médios de score entre todas as estratégias analisadas, permanecendo em níveis inferiores durante praticamente toda a execução. Esse comportamento sugere que a remoção do componente reputacional compromete a capacidade do mecanismo de seleção em diferenciar adequadamente os veículos com melhor desempenho operacional, reduzindo a eficiência global do processo de priorização.

De maneira geral, os resultados indicam que o mecanismo de seleção proposto pelo SHADAI apresenta comportamento mais consistente em comparação às demais estratégias avaliadas, preservando níveis elevados de score médio ao longo da simulação e reforçando a relevância da integração entre reputação, energia e utilidade no processo de tomada de decisão do framework.

Apresenta-se na Figura 16 a comparação da utilidade média dos veículos ao longo da execução da simulação considerando diferentes estratégias de seleção de tare-

fas. Os resultados obtidos evidenciam comportamentos distintos entre os mecanismos analisados, o que indica que a estratégia de alocação adotada influencia diretamente a dinâmica de participação dos agentes e os níveis de utilidade acumulada ao longo do tempo.

Figura 16 – Evolução temporal da utilidade média em diferentes estratégias de seleção.



Fonte: Elaborado pelo autor, 2026.

Observa-se que a estratégia *greedy* apresenta, em diversos intervalos da simulação, os maiores valores médios de utilidade entre os modos avaliados. Esse comportamento indica que abordagens orientadas predominantemente à maximização imediata de retorno tendem a favorecer ganhos utilitários mais elevados em determinados períodos da execução. Entretanto, a curva também apresenta oscilações mais acentuadas ao longo do tempo, sugerindo maior sensibilidade às variações operacionais do ambiente e à dinâmica de redistribuição das tarefas.

O framework SHADAI, por sua vez, mantém comportamento mais uniforme ao longo da simulação, apresentando níveis de utilidade relativamente consistentes mesmo diante das flutuações naturais do ambiente VaaS. Embora não alcance os maiores valores absolutos em todos os instantes da execução, o modelo apresenta capacidade de manter desempenho operacional contínuo sem depender exclusivamente de decisões oportunistas de curto prazo.

A estratégia *random* apresenta desempenho intermediário, com oscilações moderadas e ausência de padrões persistentes de crescimento ou estabilidade prolongada. Já o modo *no reputation* evidencia maior variabilidade especialmente nos instantes

iniciais da simulação, indicando que a ausência de mecanismos reputacionais tende a produzir decisões menos consistentes ao longo da execução.

Os resultados apresentados nesta subseção evidenciam que as diferentes estratégias de seleção produzem impactos distintos sobre as métricas operacionais analisadas, influenciando diretamente a evolução da reputação, do score e da utilidade dos veículos ao longo da simulação. De maneira geral, observa-se que abordagens orientadas exclusivamente à maximização imediata de retorno tendem a apresentar maior variabilidade operacional, enquanto o framework SHADAI demonstra comportamento mais consistente ao integrar múltiplos critérios no processo de priorização dos agentes.

A partir dessas análises comparativas, torna-se relevante investigar também o comportamento do framework em cenários adversos, nos quais parte dos veículos adota condutas potencialmente maliciosas ou inconsistentes. Nesse contexto, a próxima subseção avalia a capacidade do SHADAI de responder a comportamentos não cooperativos no ambiente VaaS, analisando os impactos desses agentes sobre as métricas operacionais e sobre a dinâmica geral do sistema.

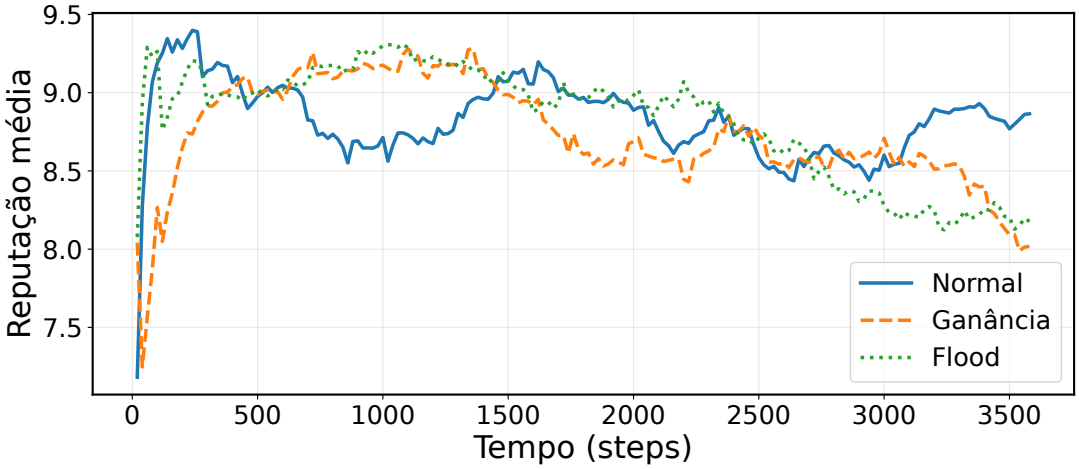
Análise do SHADAI frente a cenários maliciosos

Esta subseção avalia o comportamento do framework SHADAI sob diferentes padrões de comportamento malicioso, com o objetivo de analisar os impactos dessas ações sobre os mecanismos de reputação e seleção de veículos. Para essa finalidade, foram considerados dois cenários de ataque. No ataque de ganância (greedy attack), os veículos buscam maximizar seus benefícios individuais por meio da aceitação oportunista de tarefas, priorizando ganhos imediatos em detrimento da cooperação sistêmica. Já no ataque de inundação (flood attack), agentes maliciosos realizam um volume excessivo de solicitações ou participações, aumentando artificialmente a competição por recursos e elevando a carga operacional do ambiente. Os resultados obtidos são comparados ao cenário normal de execução, possibilitando a análise dos impactos de diferentes comportamentos adversos sobre a dinâmica do framework.

Na Figura 17, apresenta-se a evolução temporal da reputação média dos veículos ao longo da simulação para os diferentes cenários analisados. De maneira geral, observa-se que os três cenários seguem uma trajetória semelhante durante os instan-

tes iniciais de execução, indicando que a presença de agentes maliciosos não produz alterações imediatas sobre a dinâmica reputacional do sistema. Entretanto, à medida que as interações se acumulam, tornam-se perceptíveis diferenças progressivas entre os comportamentos observados.

Figura 17 – Evolução temporal da reputação média sob diferentes cenários de ataque.



Fonte: Elaborado pelo autor, 2026.

O cenário de operação normal mantém os maiores níveis de reputação média durante a maior parte da execução, apresentando oscilações moderadas e comportamento relativamente consistente ao longo do tempo. Esse resultado sugere que, na ausência de comportamentos adversariais, o mecanismo reputacional preserva uma dinâmica estável de atualização, refletindo de forma mais homogênea o histórico de participação dos agentes no ambiente.

Nos cenários sob ataque, observa-se uma tendência gradual de redução da reputação média quando comparados ao cenário normal. No caso do ataque de ganância, essa diferença torna-se mais evidente na segunda metade da simulação, período em que a curva passa a permanecer sistematicamente abaixo dos valores observados na operação regular. Esse comportamento sugere que a participação de agentes que buscam maximizar suas oportunidades de seleção sem necessariamente atender às condições ideais de elegibilidade tende a introduzir distorções no processo reputacional, afetando progressivamente os valores médios observados pelo sistema.

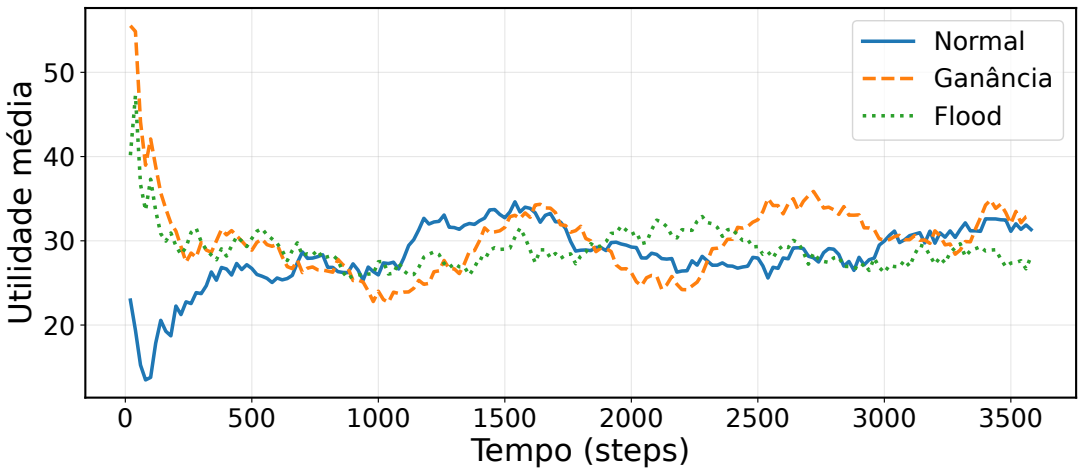
O ataque de inundação apresenta um comportamento distinto. Durante parte significativa da execução, a reputação média permanece próxima dos níveis observados nos demais cenários, porém passa a apresentar uma redução mais acentuada nos

instantes finais da simulação. Esse resultado sugere que o aumento artificial da competição provocado pelas múltiplas candidaturas dos agentes maliciosos pode alterar a dinâmica de distribuição das tarefas, produzindo efeitos acumulativos sobre a evolução das métricas reputacionais.

Os resultados obtidos indicam que ambos os ataques influenciam negativamente a evolução da reputação média dos veículos, embora com intensidades e padrões distintos. Enquanto o ataque de ganância produz um efeito mais persistente ao longo da execução, o ataque de inundação tende a concentrar seus impactos nos estágios finais da simulação. Ainda assim, as diferenças observadas permanecem relativamente limitadas quando comparadas ao cenário de referência, sugerindo que os mecanismos reputacionais empregados pelo SHADAI continuam exercendo influência sobre o processo de seleção mesmo na presença de comportamentos maliciosos

Na Figura 18, acompanha-se a evolução temporal da utilidade média dos veículos nos diferentes cenários analisados. De maneira geral, observa-se que os três cenários mantêm valores de utilidade dentro de uma mesma faixa ao longo da simulação, embora apresentem diferenças pontuais em determinados intervalos de execução. Esse comportamento indica que a presença de agentes maliciosos influencia a dinâmica de distribuição dos ganhos no sistema, mas não resulta em reduções abruptas ou permanentes da utilidade média observada.

Figura 18 – Evolução temporal da utilidade média sob diferentes cenários de ataque.



Fonte: Elaborado pelo autor, 2026.

O cenário submetido ao ataque de ganância apresenta as maiores oscilações ao longo da execução, alternando períodos de crescimento e redução da utilidade mé-

dia. Em diversos intervalos da simulação, os valores observados superam aqueles registrados no cenário normal, sugerindo que a maior frequência de participação dos agentes maliciosos pode resultar em ganhos operacionais mais elevados para parte dos veículos envolvidos. Esse comportamento sugere que estratégias orientadas à maximização de oportunidades de seleção podem produzir benefícios individuais de curto prazo, ainda que introduzam distorções na dinâmica de alocação das tarefas.

No cenário de inundação, a utilidade média apresenta comportamento mais próximo ao observado na operação normal durante grande parte da execução. Apesar disso, verifica-se uma tendência de redução nos instantes finais da simulação, indicando que o aumento artificial da concorrência entre candidatos pode influenciar a eficiência do processo de distribuição das tarefas ao longo do tempo. Ainda que esse efeito não seja expressivo, sua ocorrência sugere que a presença contínua de múltiplas candidaturas indevidas tende a impactar gradualmente os retornos operacionais obtidos pelos agentes.

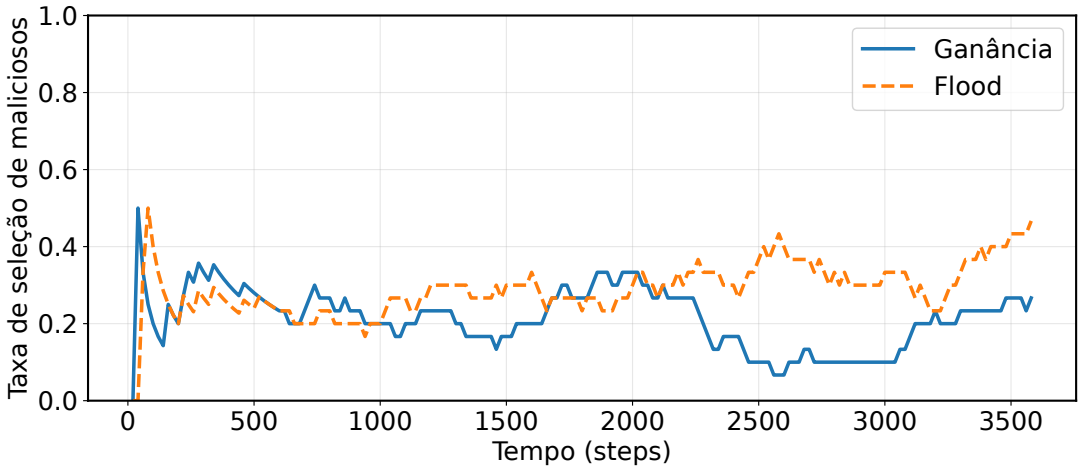
Quando comparado aos cenários sob ataque, o ambiente de operação normal apresenta uma evolução mais regular da utilidade média, mantendo níveis consistentes ao longo de toda a execução. Embora as diferenças entre as curvas não sejam suficientemente expressivas para caracterizar degradações severas do sistema, os resultados indicam que os comportamentos maliciosos exercem influência mensurável sobre a dinâmica de geração de utilidade, alterando a forma como os ganhos são distribuídos entre os participantes do ambiente.

Os resultados obtidos sugerem que os mecanismos empregados pelo SHADAI preservam a capacidade de geração de utilidade mesmo na presença de comportamentos adversariais. Em conjunto com a análise reputacional apresentada anteriormente, observa-se que os impactos dos ataques tendem a se manifestar inicialmente nas métricas de reputação e priorização dos agentes, enquanto seus efeitos sobre a utilidade média mostram-se mais graduais. Esse comportamento indica que o framework mantém sua operacionalidade sob condições adversas, embora apresente alterações mensuráveis na dinâmica de participação e distribuição dos benefícios entre os veículos.

Observa-se na Figura 19 a evolução da taxa de seleção de veículos maliciosos ao longo da simulação para os cenários de ataque por ganância e inundação. Em

ambos os casos, 20% dos veículos presentes no ambiente foram configurados como agentes maliciosos, o que permite avaliar em que medida esses agentes conseguem influenciar o processo de alocação de tarefas conduzido pelo framework SHADAI.

Figura 19 – Evolução temporal da taxa de seleção de veículos maliciosos sob diferentes cenários de ataque.



Fonte: Elaborado pelo autor, 2026.

Observa-se que a taxa de seleção dos veículos maliciosos permanece limitada durante toda a execução, não apresentando crescimento contínuo nem predominância sobre os demais participantes do sistema. Embora ambos os ataques consigam inserir agentes maliciosos entre os veículos selecionados, os resultados indicam que tais agentes não passam a concentrar a maior parte das oportunidades de execução de tarefas ao longo da simulação.

Entre os cenários avaliados, o ataque de inundação apresenta os maiores valores de taxa de seleção durante grande parte da execução. Em diversos intervalos temporais, a proporção de agentes maliciosos selecionados supera significativamente os 20% originalmente presentes na população, alcançando valores próximos de 40% em determinados momentos da simulação. Esse comportamento sugere que o aumento artificial do número de candidaturas amplia a visibilidade desses agentes no processo de seleção, elevando suas chances de participação nas tarefas disponibilizadas pelo sistema.

Por outro lado, o ataque de ganância apresenta impacto mais moderado sobre a taxa de seleção. Embora os veículos maliciosos também obtenham participação superior à sua representatividade inicial em alguns períodos da execução, os valores

observados permanecem inferiores aos registrados no cenário de inundação durante a maior parte da simulação. Esse resultado indica que estratégias voltadas exclusivamente à maximização individual dos ganhos produzem influência mais limitada sobre o mecanismo de priorização adotado pelo framework.

Outro aspecto relevante é que nenhuma das curvas apresenta tendência de crescimento irrestrito ao longo do tempo. Mesmo nos períodos em que os agentes maliciosos alcançam maiores taxas de seleção, observa-se posteriormente uma redução ou estabilização desses valores, sugerindo que os mecanismos de avaliação utilizados pelo SHADAI dificultam a concentração permanente das tarefas em um mesmo grupo de veículos.

Os resultados obtidos indicam que os ataques analisados exercem influência mensurável sobre o processo de seleção, especialmente no cenário de inundação. Entretanto, mesmo diante dessas tentativas de manipulação, os agentes maliciosos não passam a dominar o mecanismo de alocação de tarefas, permanecendo como uma parcela limitada dos veículos efetivamente selecionados ao longo da execução. Esse comportamento reforça a capacidade do framework em mitigar parcialmente os efeitos de estratégias adversariais, reduzindo o potencial de concentração indevida das oportunidades de participação no ambiente VaaS.

Em conjunto, os resultados obtidos evidenciam que os ataques avaliados afetam diferentes componentes do processo de seleção, produzindo impactos observáveis sobre as métricas de reputação, utilidade e participação dos agentes maliciosos. O ataque de inundação apresentou influência mais expressiva, elevando a frequência de seleção desses veículos e provocando maior degradação das métricas analisadas ao longo da execução. Ainda assim, os resultados indicam que os mecanismos de avaliação empregados pelo SHADAI limitam a concentração contínua de oportunidades em agentes adversariais, contribuindo para a manutenção do funcionamento do sistema mesmo na presença de comportamentos maliciosos. Esses achados reforçam a importância da utilização de múltiplos critérios de avaliação no processo de seleção e reforçam a relevância da reputação como mecanismo complementar para mitigação de tentativas de manipulação no ambiente VaaS.

5.4 DISCUSSÃO DOS RESULTADOS À LUZ DO ESTADO DA ARTE

Os resultados obtidos pelo framework SHADAI devem ser analisados não apenas de forma isolada, mas também em relação às principais soluções encontradas na literatura. Entretanto, os trabalhos correlatos empregam cenários experimentais, métricas de avaliação, arquiteturas e objetivos distintos, o que inviabiliza uma comparação quantitativa direta entre os resultados apresentados. Além disso, a reprodução dos modelos propostos por Liu et al. (2023) e Wang et al. (2026) em um mesmo ambiente de simulação demandaria adaptações arquiteturais significativas, uma vez que ambos foram concebidos para contextos e pressupostos distintos daqueles considerados nesta dissertação. Essas adaptações poderiam introduzir vieses de implementação ou descaracterizar o comportamento originalmente proposto pelos autores, comprometendo a validade de uma comparação quantitativa direta. Dessa forma, esta seção realiza uma análise comparativa qualitativa...

Entre os trabalhos analisados, o modelo proposto por Liu et al. (2023) é o que apresenta maior similaridade com o SHADAI ao utilizar a Teoria dos Jogos de Stackelberg como mecanismo para definir estratégias de precificação e alocação de recursos. Na proposta de Liu et al., provedores e usuários estabelecem uma relação líder-seguidor, buscando alcançar um equilíbrio econômico capaz de maximizar simultaneamente o lucro dos provedores e a utilidade dos consumidores. O foco principal do modelo está na obtenção do equilíbrio de Stackelberg e na eficiência da utilização dos recursos computacionais.

O SHADAI compartilha a ideia de utilizar uma relação hierárquica inspirada em Stackelberg para orientar a tomada de decisão. Entretanto, sua principal contribuição não está em ampliar a quantidade de critérios considerados, mas em tornar o processo de decisão continuamente adaptativo ao contexto operacional do ambiente VaaS. Enquanto o modelo de Liu et al. determina a estratégia dos participantes a partir da interação econômica entre oferta e demanda, o SHADAI permite que cada decisão de alocação seja influenciada simultaneamente pelas condições atuais do provedor, por sua reputação acumulada, pela disponibilidade energética e pela utilidade esperada da prestação do serviço. Dessa forma, busca-se manter a consistência das decisões mesmo em cenários caracterizados por elevada mobilidade, alterações frequentes na disponibilidade dos veículos e heterogeneidade entre os participantes.

Outro trabalho particularmente relevante é a abordagem RHIA proposta por Wang et al. (2026), desenvolvida para ambientes de *Vehicular Crowdsensing*. Diferentemente de Liu et al., Wang et al. concentram seus esforços na utilização de mecanismos de reputação para incentivar a participação dos veículos na coleta colaborativa de dados. O modelo utiliza negociação baseada em jogos de barganha, reputação dinâmica e planejamento de trajetórias para selecionar veículos confiáveis e maximizar a qualidade dos dados coletados.

Embora ambos utilizem reputação como componente da tomada de decisão, os objetivos das duas propostas diferem significativamente. No RHIA, a reputação constitui o principal mecanismo para incentivar a qualidade da coleta de dados durante a negociação entre a plataforma e os veículos participantes. No SHADAI, por outro lado, a reputação atua como um regulador contínuo do processo de seleção dos provedores de serviço, sendo utilizada em conjunto com critérios de disponibilidade energética, utilidade e qualidade do serviço. Dessa forma, a reputação deixa de representar apenas um incentivo econômico e passa a influenciar diretamente a confiabilidade da alocação dos recursos computacionais ao longo das sucessivas interações do sistema.

Essa diferença evidencia uma característica específica do SHADAI em relação às abordagens analisadas. Enquanto Liu et al. priorizam predominantemente a eficiência econômica do processo de precificação e Wang et al. concentram-se na confiabilidade da coleta de dados em aplicações de *Vehicular Crowdsensing*, o SHADAI foi concebido especificamente para ambientes Vehicle-as-a-Service, nos quais a decisão de alocação precisa conciliar simultaneamente eficiência econômica, qualidade do serviço e confiabilidade operacional. Em vez de propor apenas um novo mecanismo de precificação ou um novo modelo de reputação, o framework busca tornar a decisão de seleção dos provedores altamente adaptativa às condições observadas durante a execução do sistema.

Sob essa perspectiva, os resultados experimentais apresentados no capítulo anterior reforçam essa proposta. As simulações indicam que o mecanismo de decisão do SHADAI adapta continuamente a seleção dos provedores de acordo com as condições do ambiente, preservando a utilidade dos participantes, favorecendo veículos mais confiáveis e mantendo o desempenho do sistema mesmo diante de cenários adversos. Embora o framework não tenha sido desenvolvido para fornecer garantias

analíticas de equilíbrio, como ocorre em modelos estritamente fundamentados em Teoria dos Jogos, sua estratégia heurística mostrou-se adequada para ambientes VaaS caracterizados por elevada dinamicidade e heterogeneidade.

Embora o SHADAI introduza uma maior complexidade heurística no processo de tomada de decisão quando comparado a abordagens fundamentadas em um único mecanismo de seleção, os resultados obtidos indicam que esse custo adicional é compensado pela maior capacidade de adaptação do framework às condições dinâmicas do ambiente. Dessa forma, a proposta estabelece um compromisso entre a abrangência do processo de decisão e a capacidade de adaptação do sistema, permitindo que fatores econômicos, operacionais e históricos sejam considerados conjuntamente durante a seleção dos provedores de serviço.

Em síntese, a análise comparativa evidencia que a principal contribuição do SHADAI não consiste apenas na combinação de diferentes mecanismos já existentes na literatura. Seu diferencial está na proposição de um processo de decisão adaptativo, sensível ao histórico de reputação dos participantes (*reputation-aware*), permitindo que fatores econômicos, operacionais e históricos sejam considerados conjuntamente durante a seleção dos provedores. Essa característica aproxima o framework das demandas observadas em ambientes VaaS reais, nos quais disponibilidade, mobilidade e confiabilidade variam continuamente ao longo da operação do sistema.

Tabela 3 – Comparação entre o SHADAI e os trabalhos mais relacionados

Característica	**Liu et al. (2023)**	**Wang et al. (2026)**	**SHADAI**
Contexto de aplicação	Edge Computing	Vehicular Crowdsensing	Vehicle-as-a-Service
Objetivo principal	Precificação e alocação de recursos	Incentivo à coleta de dados	Alocação de recursos e gerenciamento de incentivos
Mecanismo principal de decisão	Jogo de Stackelberg	Reputação + Barganha	Stackelberg + Utilidade
Precificação dinâmica	✓	X	X
Reputação como critério de decisão	X	✓	✓
Energia influencia a decisão	X	X	✓
QoS influencia a seleção dos provedores	Eficiência da alocação	Qualidade dos dados	Não diretamente
Seleção dinâmica de provedores	Baseada na demanda	Baseada na reputação	Baseada em reputação, energia, proximidade e utilidade
Histórico dos participantes considerado	X	✓	✓
Contexto específico para VaaS	X	X	✓

Fonte: Elaborado pelo autor (2026).

5.5 SÍNTESE E IMPLICAÇÕES DOS RESULTADOS

A análise integrada dos resultados permite identificar padrões relevantes sobre o comportamento do framework SHADAI nos diferentes cenários experimentais. Inicialmente, a matriz de correlação apresentada na Figura 8 indica que o processo de

priorização está associado principalmente à reputação e à disponibilidade energética dos veículos. A correlação positiva moderada entre *score* e reputação ($r = 0{,}62$), bem como a correlação positiva entre *score* e energia residual ($r = 0{,}39$), mostram que ambos os critérios exercem influência sobre a classificação dos candidatos. Por outro lado, as correlações reduzidas da utilidade com o *score*, a reputação e a energia sugerem que essa métrica atua predominantemente no nível local, orientando a decisão individual de aceitação ou rejeição dos serviços, enquanto o *score* apoia a priorização global conduzida pela plataforma.

A relação entre energia residual e utilidade também evidencia que veículos com maior participação tendem a acumular maiores retornos utilitários e, simultaneamente, consumir parcela mais significativa de seus recursos energéticos. Contudo, a dispersão observada entre essas variáveis demonstra que esse comportamento não depende exclusivamente da energia, sendo também influenciado pela reputação, pela distância em relação às tarefas e pela dinâmica de seleção do framework. Assim, os resultados indicam que o SHADAI considera conjuntamente fatores econômicos, operacionais e históricos sem estabelecer uma relação determinística entre eles.

Nos experimentos com diferentes densidades veiculares, as métricas de reputação, *score* e utilidade permaneceram dentro de faixas operacionais compatíveis nos cenários com 100, 400 e 800 veículos. Os cenários de maior densidade apresentaram oscilações mais frequentes, especialmente em razão do aumento da concorrência entre os agentes, enquanto os cenários de menor densidade mostraram maior influência das participações individuais sobre as médias globais. Ainda assim, não foram observadas degradações abruptas ou comportamentos divergentes entre as configurações avaliadas, o que indica que o mecanismo de seleção preservou funcionamento consistente diante do aumento do número de participantes.

A comparação entre estratégias de seleção mostrou que cada abordagem produz efeitos distintos sobre as métricas do sistema. A estratégia *greedy* alcançou valores elevados de reputação e utilidade em determinados intervalos, porém apresentou maior variabilidade e concentração das seleções em agentes frequentemente priorizados. A estratégia *random* produziu comportamento mais irregular, enquanto a remoção do componente reputacional resultou nos menores valores médios de *score*. O SHADAI, por sua vez, manteve valores elevados de *score* e comportamento mais

uniforme ao longo da execução, indicando que a combinação entre reputação, energia, utilidade e critérios operacionais contribui para uma seleção mais consistente dos provedores.

Os cenários adversariais demonstraram que os ataques de ganância e inundação influenciam a reputação, a utilidade e a frequência de seleção dos veículos maliciosos. O ataque de inundação apresentou o maior impacto, elevando a taxa de seleção desses agentes acima dos 20% inicialmente presentes na população e alcançando valores próximos de 40% em determinados períodos. Apesar disso, não foi observada predominância contínua dos agentes maliciosos ao longo da execução, uma vez que as taxas posteriormente se reduziram ou se estabilizaram. Esses resultados indicam que os mecanismos de avaliação do SHADAI limitam parcialmente a concentração permanente das oportunidades em agentes adversariais, embora não impeçam que comportamentos maliciosos produzam efeitos mensuráveis sobre o processo de alocação.

Em síntese, os resultados obtidos sugerem que o framework SHADAI apresenta três características principais:

- **Seleção adaptativa:** o processo de priorização responde às variações de reputação, energia, utilidade e condições operacionais dos veículos ao longo da execução;
- **Orientação à qualidade e à confiabilidade:** a reputação e a disponibilidade energética influenciam diretamente o *score*, favorecendo candidatos com histórico mais consistente e melhores condições operacionais;
- **Resiliência parcial a comportamentos adversariais:** embora os ataques alterem as métricas analisadas e aumentem temporariamente a participação de agentes maliciosos, não ocorre concentração permanente das tarefas nesses veículos.

Em conjunto, as evidências experimentais indicam que o SHADAI atende aos objetivos definidos para esta dissertação ao apoiar a alocação adaptativa de recursos em ambientes *Vehicle-as-a-Service*, considerando simultaneamente critérios econômicos, operacionais e reputacionais. Os resultados também mostram que o framework permanece sujeito aos efeitos da concorrência elevada e de comportamentos maliciosos,

especialmente em ataques de inundação, o que sugere a necessidade de mecanismos adicionais de detecção e mitigação em futuras extensões da proposta.

5.6 CONTRIBUIÇÕES

Durante o desenvolvimento desta dissertação foram produzidas contribuições científicas relacionadas ao tema central da pesquisa, contemplando diferentes aspectos do ecossistema *Vehicle-as-a-Service* (VaaS). As publicações resultantes abordam desde a análise da mobilidade urbana e da integração entre veículos autônomos e transporte público até o desenvolvimento de um framework para alocação de recursos e gerenciamento de incentivos em ambientes VaaS.

O primeiro trabalho, intitulado *"Analyzing the Role of Autonomous Vehicles and Vehicle-as-a-Service in Enhancing Public Transport Efficiency in São Paulo"*, foi publicado nos anais do *9th International Workshop on Applications of Big Data Methods and Technology in the Transport Industry* (ANTONIO et al., 2025a). O estudo investiga os desafios da mobilidade urbana na cidade de São Paulo e analisa, por meio de técnicas de análise de dados e visualização espacial, o potencial da integração entre veículos autônomos e o modelo VaaS para aprimorar a eficiência e a acessibilidade do transporte público. Os resultados destacam a relevância da utilização de abordagens orientadas por dados para apoiar o planejamento da mobilidade urbana e evidenciam o potencial do conceito VaaS na reorganização inteligente da oferta de transporte em grandes centros urbanos.

O segundo artigo, intitulado *"Assessing São Paulo's Public Transport Efficiency and Coverage through Data-Driven Modeling of Autonomous Vehicle and Vehicle-as-a-Service Integration"*, foi publicado no periódico *Scientific Reports* (ANTONIO et al., 2025b). Esse trabalho amplia a análise apresentada anteriormente por meio de uma modelagem orientada a dados capaz de avaliar simultaneamente a eficiência operacional e a cobertura espacial do sistema de transporte público paulistano. Os resultados reforçam o papel estratégico dos veículos autônomos e do modelo VaaS na expansão da cobertura dos serviços e na melhoria da conectividade entre regiões centrais e periféricas, evidenciando seu potencial para apoiar políticas públicas voltadas à mobilidade inteligente e sustentável.

Como principal resultado científico desta dissertação, foi desenvolvido o framework

SHADAI (*Stackelberg-Inspired Resource Allocation and Incentive Framework for Vehicle-as-a-Service Environments*), apresentado no artigo *“SHADAI: A Stackelberg-Inspired Resource Allocation and Incentive Framework for Vehicle-as-a-Service Environments”*, atualmente em processo de revisão no periódico *IEEE Transactions on Network and Service Management (IEEE TNSM)* (ANTONIO et al., 2026). A proposta integra mecanismos inspirados na Teoria dos Jogos de Stackelberg, reputação, disponibilidade energética e utilidade dos provedores para apoiar a seleção dinâmica dos veículos participantes em ambientes VaaS. Os resultados experimentais sugerem o potencial da abordagem para aumentar a eficiência da alocação de recursos e a robustez do sistema diante de cenários dinâmicos e da presença de agentes maliciosos.

6 CONCLUSÃO

O desenvolvimento deste trabalho surgiu da identificação de uma lacuna significativa na literatura quanto à integração entre precificação dinâmica e mecanismos de incentivo em infraestruturas veiculares do tipo VaaS. A revisão teórica demonstrou que, embora existam avanços notáveis em computação veicular, sistemas distribuídos e modelos de coordenação baseados na Teoria dos Jogos, ainda são escassas as propostas capazes de conciliar eficiência econômica, adaptabilidade operacional e qualidade de serviço em um mesmo arcabouço conceitual.

Em resposta a esse desafio, foi proposto o framework SHADAI (*Stackelberg-inspired Hybrid Algorithm for Dynamic Allocation and Incentives*), concebido como uma abordagem híbrida que combina a estrutura hierárquica dos jogos de Stackelberg com heurísticas adaptativas voltadas à alocação dinâmica de recursos. O framework SHADAI representa a interação entre plataformas de gestão urbana (líderes) e veículos provedores de serviços (seguidores racionais), incorporando critérios de utilidade, reputação e disponibilidade energética ao processo de seleção dos veículos.

A fundamentação teórica forneceu o suporte conceitual necessário para o desenvolvimento da proposta, consolidando princípios de precificação, coordenação e incentivo aplicados ao contexto VaaS. A partir dessa base, foram estruturadas a modelagem matemática do framework SHADAI, suas funções de decisão e suas métricas de avaliação. Os resultados obtidos demonstraram consistência com os objetivos definidos para o framework SHADAI e evidenciaram sua capacidade de considerar conjuntamente consumo energético, desempenho econômico e reputação no processo de seleção dos provedores, reforçando sua aplicabilidade em cenários de mobilidade inteligente.

Cabe reconhecer algumas limitações que delimitam o alcance dos resultados apresentados nesta pesquisa. Embora o framework SHADAI tenha sido implementado e avaliado por meio de simulações no SUMO, os experimentos foram conduzidos sob

condições controladas, considerando configurações específicas de mobilidade, densidade veicular e demanda por serviços. A avaliação de diferentes cenários, dentro de um horizonte temporal previamente definido, permitiu analisar o comportamento do framework nas condições estabelecidas, mas não contempla toda a diversidade de situações encontradas em ambientes urbanos reais. Além disso, aspectos como interrupções de conectividade, atrasos de comunicação e custos computacionais da plataforma não foram avaliados de forma abrangente.

Nesse sentido, uma das principais perspectivas de continuidade consiste na realização de experimentos em ambientes mais próximos das condições reais de operação. Para isso, poderão ser utilizados cenários baseados em dados reais de tráfego, com diferentes padrões de mobilidade, variações na demanda por serviços e maior heterogeneidade de recursos entre os veículos. Também se mostra relevante ampliar as densidades veiculares e os períodos de observação, além de incorporar condições de conectividade variável e métricas de desempenho relacionadas à comunicação e à qualidade de serviço. Essas avaliações permitirão investigar o comportamento do SHADAI diante de situações menos controladas e identificar possíveis restrições à sua aplicação em infraestruturas VaaS.

Outra possibilidade de aprimoramento está relacionada à modelagem matemática e aos mecanismos de decisão. Entre as limitações identificadas, destaca-se a ausência de uma representação explícita do tamanho das tarefas, bem como a adoção de simplificações na composição da função de utilidade e na definição dos parâmetros de ponderação. Trabalhos futuros poderão incorporar características adicionais das tarefas, como volume de dados e demanda computacional, além de investigar procedimentos de normalização e calibração dos componentes econômicos e operacionais. Também poderão ser desenvolvidos mecanismos de precificação capazes de ajustar a remuneração conforme as condições de oferta e demanda. Adicionalmente, considera-se relevante avaliar diferentes configurações dos mecanismos ε-*greedy* e de *cooldown*, investigar formas de atualização reputacional que considerem diferentes níveis de conclusão das tarefas e aprofundar a relação entre as decisões heurísticas adotadas e a formulação teórica dos jogos de Stackelberg.

Quanto à avaliação de cenários adversariais, os experimentos contemplaram os ataques de ganância e inundação, utilizando uma proporção fixa de veículos malicio-

sos. Como não foi realizada uma análise de sensibilidade desse percentual, os resultados permanecem restritos à configuração avaliada. Dessa forma, trabalhos futuros poderão considerar diferentes proporções de participantes maliciosos, ampliar os tipos de comportamento adversarial e investigar mecanismos adicionais de detecção e mitigação de ataques. Essas extensões poderão contribuir para uma compreensão mais abrangente da capacidade do framework SHADAI de lidar com comportamentos maliciosos em diferentes condições experimentais.

Assim, o framework SHADAI constitui uma contribuição para o estudo da alocação de recursos e do gerenciamento de incentivos em ambientes VaaS, ao integrar mecanismos inspirados na Teoria dos Jogos de Stackelberg, reputação e disponibilidade energética em um processo adaptativo de seleção de veículos, considerando também a utilidade individual dos participantes e sua proximidade em relação às tarefas solicitadas.

REFERÊNCIAS

3GPP. *Digital Cellular Telecommunications System (Phase2+) (GSM); Universal Mobile Telecommunications System (UMTS); LTE; 5G; The Release 14 Specification Status*. Valbonne, France, 2018. Release 14.

3GPP. *Study on New Radio (NR) Access Technology*. Valbonne, France, 2018. Release 15.

3GPP. *Architecture Enhancements for 5G System (5GS) to Support Vehicle-To-Everything (V2X) Services*. Valbonne, France, 2020. Release 16.

ABDEL-AZIZ, M. K. et al. Optimized age of information tail for ultra-reliable low-latency communications in vehicular networks. *IEEE Transactions on Communications*, v. 68, n. 3, p. 1911–1924, mar. 2020.

AGEED, Z. et al. Cloud computing resources impacts on heavy-load parallel processing approaches. *IOSR Journal of Computer Engineering (IOSR-JCE)*, v. 22, n. 3, p. 30–41, 2020.

AKPAKWU, G. A. et al. A survey on 5g networks for the internet of things: Communication technologies and challenges. *IEEE Access*, v. 6, p. 3619–3647, 2018.

ANTONIO, L. H. d. L. et al. SHADAI: A stackelberg-inspired resource allocation and incentive framework for vehicle-as-a-service environments. Manuscript submitted to IEEE Transactions on Network and Service Management, under review. 2026.

ANTONIO, L. H. d. L. et al. Analyzing the role of autonomous vehicles and vehicle-as-a-service in enhancing public transport efficiency in são paulo. In: *2025 IEEE International Conference on Big Data (BigData)*. [S.l.: s.n.], 2025. p. 5277–5286.

ANTONIO, L. H. d. L. et al. Assessing são paulo's public transport efficiency and coverage through data-driven modeling of autonomous vehicle and vehicle-as-a-service integration. *Scientific Reports*, v. 16, n. 1, p. 2969, dez. 2025. Disponível em: https://www.nature.com/articles/s41598-025-32807-z_reference.pdf.

BANERJEE, S.; JAIN, G.; SETHI, S. P. Dynamic pricing for one-way ride-sharing networks with price-dependent demand and abandonment. *Transportation Research Part C: Emerging Technologies*, v. 133, p. 103445, 2021.

BASAR, T.; OLSDER, G. J. *Dynamic noncooperative game theory*. 2. ed. Philadelphia: Society for Industrial and Applied Mathematics, 1999.

BONOMI, F. et al. Fog computing and its role in the internet of things. In: *Proceedings of the first edition of the MCC workshop on Mobile cloud computing - MCC '12*. [S.l.: s.n.], 2012.

BOUKERCHE, A.; GRANDE, R. E. D. Vehicular cloud computing: Architectures, applications, and mobility. *Computer Networks*, v. 135, p. 171–189, abr. 2018.

BRANZEI, R.; FRAGNELLI, V.; TIJS, S. *Models in Cooperative Game Theory*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2008.

CAMPBELL, A. et al. Integrated quality of service for multimedia communications. In: *IEEE INFOCOM '93 – The Conference on Computer Communications, Proceedings*. San Francisco, CA, USA: [s.n.], 1993. v. 2, p. 732–739.

CAMPOS, J. R. de et al. Serviço compartilhado e criação de valor: Airbnb e o sistema de review. *Organicom*, v. 19, n. 38, p. 187–201, jun. 2022.

CHEN, X. et al. Vehicle as a service (VaaS): Leverage vehicles to build service networks and capabilities for smart cities. *IEEE Communications Surveys & Tutorials*, p. 1–34, jan. 2024.

CHEN, Z. et al. Age analysis of critical information in internet of vehicle networks with service confluence. *IEEE Open Journal of the Communications Society*, p. 1, jan. 2025.

CHENG, Y. et al. A lightweight privacy preservation scheme with efficient reputation management for mobile crowdsensing in vehicular networks. *IEEE Transactions on Dependable and Secure Computing*, v. 20, n. 3, p. 1771–1788, 2023.

CHRISTIDIS, K.; DEVETSIKIOTIS, M. Blockchains and smart contracts for the internet of things. *IEEE Access*, v. 4, n. 4, p. 2292–2303, 2016.

DING, N. et al. Incentive mechanism design for distributed coded machine learning. In: *IEEE INFOCOM 2021 – IEEE Conference on Computer Communications*. [S.l.: s.n.], 2021.

DING, Y. et al. Resource allocation in V2X communications based on multi-agent reinforcement learning with attention mechanism. *Mathematics*, v. 10, n. 19, p. 3415, set. 2022.

DINH, H. T. et al. A survey of mobile cloud computing: architecture, applications, and approaches. *Wireless Communications and Mobile Computing*, v. 13, n. 18, p. 1587–1611, 2013. Disponível em: https://onlinelibrary.wiley.com/doi/abs/10.1002/wcm.1203.

DLR. *SUMO – Simulation of Urban MObility. Eclipse SUMO Documentation*. 2025. Disponível em: https://sumo.dlr.de/docs/index.html. Acessado em: 13 de maio de 2025.

FATIMA, N. S.; BEGAM, S. J.; MUNEERA, N. S. Reverse auction to trade unused cloud computing resources. *Indian Journal of Science and Technology*, v. 9, n. 30, ago. 2016.

GARCíA, M. H. C. et al. A tutorial on 5g nr v2x communications. *IEEE Communications Surveys & Tutorials*, v. 23, n. 3, p. 1972–2026, 2021.

GYAWALI, S. et al. Challenges and solutions for cellular based v2x communications. *IEEE Communications Surveys & Tutorials*, v. 23, n. 1, p. 222–255, 2021.

HAN, D.; CHEN, W.; FANG, Y. A dynamic pricing strategy for vehicle assisted mobile edge computing systems. *IEEE Wireless Communications Letters*, v. 8, n. 2, p. 420–423, 2019.

HASAN, M. et al. Securing vehicle-to-everything (v2x) communication platforms. *IEEE Transactions on Intelligent Vehicles*, v. 5, n. 4, p. 693–713, 2020.

HIGASHIYAMA, K. et al. Safety and efficiency of intersections with mix of connected and non-connected vehicles. *IEEE Open Journal of Intelligent Transportation Systems*, v. 1, p. 29–34, 2020.

HOU, X. et al. Vehicular fog computing: A viewpoint of vehicles as the infrastructures. *IEEE Transactions on Vehicular Technology*, v. 65, n. 6, p. 3860–3873, jun. 2016.

IHLE, C. et al. Incentive mechanisms in peer-to-peer networks — a systematic literature review. *ACM Comput. Surv.*, Association for Computing Machinery, New York, NY, USA, v. 55, n. 14s, jul. 2023. ISSN 0360-0300.

ISAAC, R. A. et al. Enhanced novelty approaches for resource allocation model for multi-cloud environment in vehicular ad-hoc networks. *Scientific Reports*, v. 15, n. 1, mar. 2025.

JIANG, D. et al. Design of 5.9 ghz dsrc-based vehicular safety communication. *IEEE Wireless Communications*, v. 13, n. 5, p. 36–43, out. 2006.

KEY, P. B.; MCAULEY, D. R. Differential qos and pricing in networks: Where flow control meets game theory. *IEE Proceedings - Software*, v. 146, n. 1, p. 39, 1999.

KLEIN, T. et al. A threat model for vehicular fog computing. *IEEE Access*, v. 10, p. 133256–133278, 2022.

KREPS, D. M. Nash equilibrium. In: ____. *Game Theory*. [S.l.: s.n.], 1989. p. 167–177.

KUHN, H. W.; TUCKER, A. W. *Contributions to the theory of games*. Princeton, NJ: Princeton University Press, 1969. v. 4.

KUMAR, D. et al. A truthful combinatorial double auction-based marketplace mechanism for cloud computing. *Journal of Systems and Software*, v. 140, p. 91–108, mar. 2018.

LAM, A. Y. S. A VCG-based mechanism for combinatorial auction in autonomous vehicle public transportation system. In: *2015 IEEE 18th International Conference on Intelligent Transportation Systems (ITSC)*. [S.l.: s.n.], 2015. p. 1306–1311.

LEMAIRE, J. Cooperative game theory and its insurance applications. *Insurance: Mathematics and Economics*, v. 12, n. 1, p. 72, fev. 1993.

LI, T.; SETHI, S. P. A review of dynamic stackelberg game models. *Discrete & Continuous Dynamical Systems - B*, v. 22, n. 1, p. 125–159, 2017.

LIAO, S. et al. Fog-enabled vehicle as a service for computing geographical migration in smart cities. *IEEE Access*, v. 7, p. 8726–8736, 2019.

LIN, F. et al. Optimization-oriented resource allocation management for vehicular fog computing. *IEEE Access*, v. 6, p. 69294–69303, 2018.

LIU, B. et al. Dynamic pricing in edge computing resource allocation based on stackelberg dynamic game. Preprint. 2023.

LIU, G. et al. Game theory-based optimization of distributed idle computing resources in cloud environments. *Theoretical Computer Science*, v. 806, p. 468–488, fev. 2020.

LIU, X.; LIU, J.; LI, W. Strategyproof mechanism for resource allocation and cost-sharing in edge-assisted vehicle computing. *IEEE Transactions on Vehicular Technology*, 2026. Disponível em: https://ieeexplore.ieee.org/abstract/document/11359969.

MANTAS, N. et al. Towards an incentive-compatible, reputation-based framework for stimulating cooperation in opportunistic networks: a survey. *IET Networks*, v. 6, n. 6, p. 169–178, 2017. Disponível em: https://ietresearch.onlinelibrary.wiley.com/doi/abs/10.1049/iet-net.2017.0079.

MISIK, S.; CELA, A.; BRADAC, Z. Distributed systems – a brief review of theory and practice. *IFAC-PapersOnLine*, v. 49, n. 25, p. 318–323, 2016.

MOREIRA, D. C. et al. Qos predictability in v2x communication with machine learning. In: *2020 IEEE 91st Vehicular Technology Conference (VTC2020-Spring)*. [S.l.: s.n.], 2020. p. 1–5.

MYERSON, R. B. *Game Theory: Analysis of Conflict*. Cambridge, Mass.: Harvard University Press, 1997. ISBN 978-0-674-34116-6.

NAIR, A.; TANWAR, S. Resource allocation in v2x communication: State-of-the-art and research challenges. *Physical Communication*, v. 64, p. 102351, jun. 2024.

NAZIH, O. et al. Towards secure and trustworthy vehicular fog computing: A survey. *IEEE Access*, p. 1–27, jan. 2024.

NEUMANN, J. von; MORGENSTERN, O. *Theory of Games and Economic Behavior*. Princeton, N.J.: Princeton University Press, 1944.

NOROZPOUR, S.; SAFAEI, M. An overview on game theory and its application. In: *IOP Conference Series: Materials Science and Engineering*. [S.l.: s.n.], 2020. v. 993, p. 012114.

QADIR, G. A.; ZEEBAREE, S. R. M. Evaluation of qos in distributed systems: A review. *International Journal of Science and Business*, v. 5, n. 2, p. 89–101, 2021.

QIAO, W. et al. Distributed dynamic pricing of multiple perishable products using multi-agent reinforcement learning. *Expert Systems with Applications*, v. 237, p. 121252, mar. 2024.

ROMP, G. *Game theory: introduction and applications*. Oxford: Oxford University Press, 2005. ISBN 978-0199276927.

ROTHE, J. *Economics and Computation: An Introduction to Algorithmic Game Theory, Computational Social Choice, and Fair Division*. Berlin, Heidelberg: Springer, 2016.

SALEM, A. H. et al. Qoe-aware computational resource allocation for connected vehicles in smart urban environments. *IEEE Access*, v. 13, p. 142998–143019, 2025.

SANTOS, F. A. N. dos; ZANON, M. L. B.; MORES, G. M. S. D. M. Dynamic pricing and price fairness perceptions: a study of the use of the uber app in travels. *Turismo: Visão e Ação*, v. 21, n. 3, p. 239–264, dez. 2019.

SCHäR, F.; BERENTSEN, A. *Bitcoin, Blockchain, and Cryptoassets: A Comprehensive Introduction*. Cambridge, Mass.: MIT Press, 2020. ISBN 978-0262538189.

SHABAN, M.; NOORY, R.; YASEEN, D. Billing system design based on internet environment. *International Journal of Advanced Computer Science and Applications*, v. 3, n. 9, 2012.

SILVA, B. N.; KHAN, M.; HAN, K. Towards sustainable smart cities: A review of trends, architectures, components, and open challenges in smart cities. *Sustainable Cities and Society*, v. 38, n. 1, p. 697–713, abr. 2018.

STACKELBERG, H. von. *The Theory of the Market Economy*. Oxford: Oxford University Press, 1952.

STANKOVA, K. *On Stackelberg and inverse Stackelberg games and their applications in the optimal toll design problem, the energy markets liberalization problem*. Tese (Doutorado) — Delft Institute of Applied Mathematics, Delft University of Technology, Delft, 2009. Disponível em: http://resolver.tudelft.nl/uuid:8a7342eb-cf40-459b-8adc-fa4806f4e024.

STILLER, B. et al. Pricing and QoS. In: *Quality of Future Internet Services*. Berlin, Heidelberg: Springer, 2003, (Lecture Notes in Computer Science, v. 2816). p. 263–291.

SUN, Y. et al. Internet of things and big data analytics for smart and connected communities. *IEEE Access*, v. 4, p. 766–773, 2016.

SWATHI, B. et al. Implementation of improved billing system. *International Journal of Scientific Research in Computer Science, Engineering and Information Technology*, p. 37–41, maio 2020.

SZABO, N. *Smart Contracts*. 1996. Disponível em: https://www.fon.hum.uva.nl/rob/Courses/InformationInSpeech/CDROM/Literature/LOTwinterschool2006/szabo.best.vwh.net/smart.contracts.html. Acessado em: 5 de março de 2025.

SZABO, N. *The Idea of Smart Contracts*. 1997. Disponível em: https://www.fon.hum.uva.nl/rob/Courses/InformationInSpeech/CDROM/Literature/LOTwinterschool2006/szabo.best.vwh.net/idea.html. Acessado em: 5 de março de 2025.

TANG, D. et al. Research on adaptive traffic signal optimization control based on an improved dqn. In: *Harmonious Human-Machine Environment*. Springer, 2026. (Communications in Computer and Information Science, v. 2879), p. 451–466. Disponível em: https://doi.org/10.1007/978-981-92-3994-8_28.

TENG, R.; SATO, K. A fundamental study of reliable vehicle-to-cloud communication using multiple paths with redundancy mitigation. *Applied Sciences*, v. 14, n. 7, p. 2841, mar. 2024.

WANG, H.; TIANFIELD, H.; MAIR, Q. Auction based resource allocation in cloud computing. *Multiagent and Grid Systems*, v. 10, n. 1, p. 51–66, maio 2014.

WANG, Y.; GUO, Q.; YU, Y. Cooperative pricing for vehicle-traffic-power nexus to support city decarbonization: A federated deep reinforcement learning framework. *IEEE Transactions on Industrial Cyber-Physical Systems*, v. 1, p. 182–191, 2023.

WANG, Z. et al. Reputation-based sensing data collection in vehicular crowdsensing: A hybrid incentive approach. *IEEE Transactions on Mobile Computing*, v. 25, n. 6, p. 8977–8995, 2026.

XU, Y. et al. Informer-based QoS prediction for V2X communication: A method with verification using reality field test data. *Computer Networks*, v. 235, p. 109958, nov. 2023.

YU, J. J. Q.; LAM, A. Y. S.; LU, Z. Double auction-based pricing mechanism for autonomous vehicle public transportation system. *IEEE Transactions on Intelligent Vehicles*, v. 3, n. 2, p. 151–162, jun. 2018.

ZANELLA, A. et al. Internet of things for smart cities. *IEEE Internet of Things Journal*, v. 1, n. 1, p. 22–32, fev. 2014.

ZHANG, H.; LIU, X. Reverse auction-based services optimization in cloud computing environments. *Security and Communication Networks*, v. 2021, p. 1–10, mar. 2021.

ZHAO, L. et al. Dependency-aware task offloading and resource pricing in parked vehicle-assisted edge computing: A stackelberg-contract approach. *IEEE Transactions on Green Communications and Networking*, v. 10, p. 2320–2332, 2026.

ZHOU, H. et al. Evolutionary v2x technologies toward the internet of vehicles: Challenges and opportunities. *Proceedings of the IEEE*, v. 108, n. 2, p. 308–323, fev. 2020.

DADOS CURRICULARES

IDENTIFICAÇÃO	
	Lucas Henrique de Lima Antonio data de nascimento: 10/04/2002
Nacionalidade	Brasileiro
Nome em citações bibliográficas:	Antonio, Lucas Henrique de Lima Antonio, Lucas Henrique L.
Currículo Lattes	http://lattes.cnpq.br/1221400360730902
ORCID	https://orcid.org/0009-0004-2194-0664
FORMAÇÃO ACADÊMICA	
2024/2026	Mestre em Ciência da Computação Universidade Estadual Paulista “Júlio de Mesquita Filho
2020/2023	Bacharel em Ciência da Computação Faculdades Integradas de Bauru - FIB
PRODUÇÃO BIBLIOGRÁFICA	
ANTONIO, L. H. L.; TERENCIANI, S. J. C.; ELER, D. M.; FILHO, G. P. R.; JUNIOR, L. A. P.; DE GRANDE, R. E.; MENEGUETTE, R. I. Assessing São Paulo's public transport efficiency and coverage through data-driven modeling of autonomous vehicle and vehicle-as-a-service integration. *Scientific Reports*, v. 16, artigo 2969, 2026. DE LIMA ANTONIO, L. H.; TERENCIANI, S. J. C.; ELER, D. M.; JÚNIOR, L. A. P.; DE GRANDE, R. E.; FILHO, G. P. R.; MENEGUETTE, R. I. Analyzing the Role of Autonomous Vehicles and Vehicle-as-a-Service in Enhancing Public Transport Efficiency in São Paulo. In: IEEE INTERNATIONAL CONFERENCE ON BIG DATA (BIGDATA), 2025, Macau. *Anais* [...]. IEEE, 2025. p. 5277–5286.	
PARTICIPAÇÃO EM EVENTOS CIENTÍFICOS	
INTERNATIONAL WORKSHOP ON APPLICATIONS OF BIG DATA METHODS AND TECHNOLOGY IN THE TRANSPORT INDUSTRY, 9., 2025, Macau. Analyzing the Role of Autonomous Vehicles and Vehicle-as-a-Service in Enhancing Public Transport Efficiency in São Paulo. 2025. (Workshop).	