



SMIRALDA MILFORT

**DESENVOLVIMENTO E AVALIAÇÃO DE UM SISTEMA
MULTIAGENTE APLICADO À ASSISTÊNCIA AO
CONDUTOR EM INTERSEÇÕES URBANAS**

**LAVRAS – MG
2025**

SMIRALDA MILFORT

**DESENVOLVIMENTO E AVALIAÇÃO DE UM SISTEMA
MULTIAGENTE APLICADO À ASSISTÊNCIA AO
CONDUTOR EM INTERSEÇÕES URBANAS**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do programa de Pós-Graduação em Ciência da Computação, área de concentração em inteligência artificial e otimização para a obtenção do título de Mestre.

Prof. DSc. Arthur de Miranda Neto
Orientador

**LAVRAS – MG
2025**

**Ficha Catalográfica elaborada pelo Sistema de Geração
de Ficha Catalográfica da Biblioteca Universitária da UFLA, com
dados informados pelo(a) próprio(a) autor(a).**

Milfort, Smiralda.

Desenvolvimento e avaliação de um sistema multiagente aplicado à assistência ao
condutor em interseções urbanas / Smiralda Milfort. - 2025.

81 p. : il.

Orientador: Arthur De Miranda Neto

Dissertação (Mestrado Acadêmico) - Universidade Federal de Lavras, 2025.
Bibliografia.

1. Veículos inteligentes. 2. Sistemas multiagentes. 3. ADAS. 4. JADE. 5. SUMO.
I. De Miranda Neto, Arthur. II. Universidade Federal de Lavras. III. Título.

SMIRALDA MILFORT

**DESENVOLVIMENTO E AVALIAÇÃO DE UM SISTEMA MULTIAGENTE
APLICADO À ASSISTÊNCIA AO CONDUTOR EM INTERSEÇÕES URBANAS**

**DEVELOPMENT AND EVALUATION OF A MULTI-AGENT SYSTEM APPLIED
TO DRIVER ASSISTANCE AT URBAN INTERSECTIONS**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do programa de Pós-Graduação em Ciência da Computação, área de concentração em inteligência artificial e otimização para a obtenção do título de Mestre.

APROVADA em 11 de julho de 2025.

Prof. DSc. Alessandro Corrêa Victorino

Prof. DSc. Mayron Cesar de Oliveira Moreira

UTC

DCC/UFLA

Prof. DSc. Arthur de Miranda Neto
Orientador

**LAVRAS – MG
2025**

À minha família, pelos inúmeros sacrifícios que fizeram desde que eu era criança, por sua paciência, amor e confiança. Que eles encontrem, por meio deste modesto trabalho, a expressão de minha imensa gratidão, meu profundo afeto e meu inabalável apego. Nenhuma dedicatória poderia fazer justiça a tudo o que lhes devo.

À minha única irmã Miouseline Milfort, que me apoiou sem reservas, me amou como se fosse sua filha e me orientou e aconselhou com inestimável sabedoria, possibilitando que eu alcançasse essa conquista.

Ao Hugues Ebert Mertilus, que sempre esteve presente para me apoiar, nunca me abandonando e me ajudando com coragem e amor a superar as provações da vida.

Aos meus pais biológicos Massien Milfort e Rithmanie Antoine (in memoriam), que infelizmente não tiveram a oportunidade de ver sua filha crescer, mas cujos valores ainda estão comigo no caminho que traçaram para mim.

Aos meus avós Richard Antoine e Luciana Dormelus (in memoriam), que assumiram o controle com amor e devoção exemplares após a perda precoce de meus pais e que me ofereceram todo o apoio de que precisei nos momentos mais difíceis.

Dedico este trabalho.

AGRADECIMENTOS

“Apesar de todas as limitações, um objetivo bem definido tem o poder de transformar todo esforço, dedicação e sacrifícios em sucesso.” Em primeiro lugar, gostaria de expressar minha gratidão ao supremo criador por suas bênçãos e fidelidade a mim, por guiar meus passos e fortalecer minha coragem e resiliência.

Profunda gratidão ao Programa de Bolsas de Estudo OEA-GCUB Brasil, nascido de uma parceria entre o Grupo de Cooperação Internacional das Universidades Brasileiras (GCUB) e a Organização dos Estados Americanos (OEA), por seu compromisso com a educação internacional, e ao Programa de Bolsas de Estudo OEA-GCUB Brasil por essa grande iniciativa de contribuir para a educação superior de estudantes estrangeiros, da qual tive a oportunidade de fazer parte.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior no Brasil (CAPES), Código de Financiamento 001, por seu apoio financeiro durante meus dois anos de treinamento. Também gostaria de agradecer à Fondation Connaissance et Liberté d’Haïti (FOKAL) por sua contribuição financeira para o sucesso deste trabalho.

Gostaria de prestar uma homenagem especial a cada membro e professor do Programa de Pós-Graduação em Ciência da Computação (PPG-DCC) da Universidade Federal de Lavras (UFLA) pela qualidade excepcional do ensino que recebi durante meus estudos universitários.

Agradecimentos especiais ao meu orientador, Prof. Dr. Arthur Neto de Miranda, por sua incomparável orientação, sua infinita disponibilidade, seu apoio e a preciosidade de seus conselhos, que contribuíram consideravelmente para a conclusão bem-sucedida deste trabalho.

Gostaria de agradecer a cada um dos membros do júri pelo interesse em minha pesquisa ao concordar em examinar meu trabalho e enriquecê-lo com suas contribuições.

Um agradecimento sincero aos Prof. Dr. Eric de Mello Araújo e à Profa. Dra. Angélica de Mata por suas orientações, colaborações e aconselhamento desde o início de meu estudo.

Gostaria de agradecer a todos os membros de minha família, minha única irmã Miouseline Milfort, minha tia Rithna Antoine, meus primos Emeline Sainte-Croix, Manoucheca Antoine Lacouty, Frantz Milfort etc., pelo apoio que me deram, sem eles eu não teria conseguido fazer isso.

Um enorme agradecimento a Hugues Ebert Mertilus por sua confiança e que sempre me apoiou.

Gostaria de agradecer aos meus colegas haitianos, especialmente aqueles que estão no Brasil, Altène Jean-Louis, Ange-Bleurette Pascal Jean, Johnny Jean, Renan Previl, Luckencia

Jean, Monhel Maudony Pierre, Duterval Jesuka, e também aos meus colegas brasileiros e moçambicanos, e a todos aqueles que contribuíram de alguma forma para a conclusão deste trabalho.

E, por fim, agradeço a mim mesma por minha resiliência e coragem, por não ter desistido, mesmo quando o caminho parecia longo demais ou as forças eram poucas. Por ter seguido, apesar das dúvidas, e por ter acreditado que era possível chegar até aqui. Que este seja apenas mais um capítulo de uma trajetória marcada por aprendizados, coragem e muitos sonhos ainda por realizar.

Não tenha medo, pois eu estou com você; não se desanime, pois eu sou o seu Deus. Eu o fortalecerei e o ajudarei; eu o segurarei com a minha mão direita vitoriosa.
(Isaías 41:10)

Bom mesmo é ir à luta com determinação, abraçar a vida com paixão, perder com classe e vencer com ousadia, pois o triunfo pertence a quem se atreve. A vida é muita para ser insignificante.
(Charles Chaplin)

Todos nós temos sonhos. Mas para que os sonhos se tornem realidade, é preciso muita determinação, dedicação, autodisciplina e esforço.
(Jesse Owens)

RESUMO

As interseções urbanas são pontos críticos no trânsito devido à confluência de fluxos de veículos e elevado risco de acidentes. As ferramentas tecnológicas, como simulações de tráfego, ciência de dados e inteligência artificial, são essenciais para analisar padrões, prevenir acidentes e otimizar o fluxo veicular. O objetivo principal deste estudo é projetar e avaliar um sistema multiagente aplicado à assistência ao condutor, com foco na segurança em interseções urbanas, onde os riscos são mais acentuados. Para alcançar esse objetivo, o estudo utilizou o *Java Agent Development Framework* (JADE), que possibilita a modelagem de agentes autônomos que interagem em um ambiente simulado. O *Simulation of Urban MObility* (SUMO) é utilizado para oferecer uma simulação detalhada das interações de tráfego em cenários urbanos complexos. A integração entre JADE e SUMO é facilitada pelo *Traffic Simulation Manager Application Programming Interface* (TraSM API), uma interface que permite coordenar e sincronizar a comunicação entre as duas plataformas. Os resultados mostram o potencial de sistemas multiagente na prevenção de acidentes em interseções urbanas. O protocolo cooperativo de mensagens ACL (*Agent Communication Language*) elimina as colisões registradas no cenário puramente reativo do SUMO, ao passo que impõe um acréscimo médio de 7,3% no tempo de viagem e de apenas 0,18s de espera por veículo. Esses resultados sugerem que a coordenação multiagente pode promover decisões mais seguras sem comprometer significativamente a fluidez do tráfego. Embora as simulações ainda necessitem de validação em redes de maior densidade e comparação com dados empíricos, este trabalho contribui para o desenvolvimento de sistemas de assistência ao condutor mais resilientes com adoção de um protocolo automatizado de testes que varie sistematicamente, apontando caminhos para aplicações em cidades inteligentes e para futuras extensões envolvendo aprendizado de máquina distribuído e calibração em campo.

Palavras-chave: veículos inteligentes; sistemas multiagentes; ADAS; JADE; SUMO.

ABSTRACT

Urban intersections are critical points in traffic due to the confluence of vehicle flows and high risk of accidents. Technological tools, such as traffic simulations, data science, and artificial intelligence, are essential for analyzing patterns, preventing accidents, and optimizing vehicular flow. The main objective of this study is to design and evaluate a multi-agent system applied to driver assistance, focusing on safety at urban intersections, where the risks are more pronounced. To achieve this goal, the study used the Java Agent DEvelopment Framework (JADE), which enables the modeling of autonomous agents that interact in a simulated environment. The Simulation of Urban MObility (SUMO) is used to provide a detailed simulation of traffic interactions in complex urban scenarios. The integration between JADE and SUMO is facilitated by the Traffic Simulation Manager Application Programming Interface (TraSMAPI), an interface that allows you to coordinate and synchronize communication between the two platforms. The results showed the potential of multi-agent systems in the prevention of accidents at urban intersections. The cooperative messaging protocol ACL (Agent Communication Language) eliminates the collisions recorded in the purely reactive SUMO scenario, while imposing an average increase of 7.3% in travel time and only 0.18s of waiting time per vehicle. These results suggest that multi-agent coordination can promote safer decisions without significantly compromising traffic flow. Although simulations still need validation in higher density networks and comparison with empirical data, this work contributes to the development of more resilient driver assistance systems with the adoption of an automated test protocol that varies systematically, pointing the way for applications in smart cities and for future extensions involving distributed machine learning and field calibration.

Keywords: intelligent vehicles; multi-agent systems; ADAS; JADE; SUMO.

INDICADORES DE IMPACTO

A mobilidade está no centro da sociedade moderna, influenciando nossa vida cotidiana e moldando nossos ambientes urbanos. O desenvolvimento e a avaliação desse sistema podem ter um impacto significativo de várias maneiras. Socialmente, a melhoria da segurança viária por meio do gerenciamento eficaz de colisões pode salvar vidas e reduzir lesões, contribuindo para uma melhor qualidade de vida dos cidadãos. A redução de acidentes e congestionamentos também podem diminuir o estresse e a ansiedade associados ao deslocamento, melhorando o bem-estar geral das comunidades locais. Em termos econômicos, o gerenciamento de colisões pode gerar economias substanciais, principalmente nos custos associados a acidentes rodoviários, como despesas médicas, reparos de veículos e perda de produtividade devido a engarrafamentos, consumo de combustível e dentre outros igualmente importantes. Em termos de impacto cultural, a integração dessas tecnologias pode transformar o comportamento dos motoristas e incentivar uma maior aceitação de mudanças na comunidade. Em termos tecnológicos, o estudo da área de sistemas inteligentes pode permitir uma gestão mais eficiente de interseções.

IMPACT INDICATORS

Mobility is at the heart of modern society, influencing our daily lives and shaping our urban environments. The development and evaluation of this system can have a significant impact in a few ways. Socially, improving road safety through effective collision management can save lives and reduce injuries, contributing to a better quality of life for citizens. Reducing accidents and congestion can also reduce the stress and anxiety associated with commuting, improving the general well-being of local communities. In economic terms, collision management can generate substantial savings, particularly in the costs associated with road accidents, such as medical expenses, vehicle repairs and lost productivity due to traffic jams, fuel consumption and the creation of jobs in the maintenance and operation of the system. In terms of cultural impact, the integration of these technologies can transform driver behavior and encourage greater acceptance of change in the community. In technological terms, thanks to the multi-agent system, system performance will improve intersection management accuracy and traffic efficiency.

LISTA DE FIGURA

Figura 2.1- Os níveis de automação definidos pela norma SAE J301.	21
Figura 2.2 - Esquema do processo de raciocínio de um agente.....	23
Figura 2.3 - Ambiente SUMO.....	32
Figura 2.4 - Estrutura de diretórios JADE.....	35
Figura 2.5 - Comunicação entre JADE e SUMO.	36
Figura 4.1 - Pseudocódigo do algoritmo de decisão do Agente-Veículo.	43
Figura 4.2 - Interseção não regulamentada.	44
Figura 4.3 - InterliJ IDEA.	50
Figura 4.4 - Interface gráfica do sistema.	51
Figura 4.5 - Arquivo Net.xml.....	52
Figura 4.6 - Arquivo rou.xml.	53
Figura 4.7 - Arquivo configuração.	54
Figura 4.8 - Fluxograma da classe <i>DriverManager</i>	55
Figura 4.9 - Troca de mensagens (recebido).	56
Figura 4.10 - Troca de mensagens (enviado).	57
Figura 4.11 - Troca de mensagens entre os agentes.	58
Figura 5.1 - Relatório de SUMO com uma colisão.	61
Figura 5.2 - Relatório de SUMO com uma colisão.	62
Figura 5.3 - Encontro de veículos durante a colisão.	63
Figura 5.4 - Relatório de SUMO sem colisão.	64
Figura 5.5 - Tempo de espera por veículos.	65
Figura 5.6 - Comparação métrica.	67
Figura 5.7 - Comparação pareada de métricas	69

LISTA DE QUADRO

Quadro 2. 1 - Quadro das aplicações SUMO.	32
Quadro 2. 2 - Quadro das aplicações e middleware associados.	33
Quadro 2. 3 - Arquivos entrada no sumo.	33
Quadro 2. 4 - Distribuição dos arquivos JADE.....	34
Quadro 2. 5 - Pacotes JADE.....	34
Quadro 3. 1 - Quadro dos trabalhos relacionados.....	40

LISTA DE TABELA

Tabela 5. 1 - Indicadores de desempenho (SUMO)	60
Tabela 5. 2 - Comparação métricas	68

SUMÁRIO

1	INTRODUÇÃO	15
1.1	Hipótese	16
1.2	Objetivo	16
2	REFERÊNCIAL TEÓRICO	18
2.1	Sistemas de transporte inteligentes	18
2.2	Veículos inteligentes.....	20
2.3	Agentes inteligentes.....	22
2.4	Sistemas multiagentes.....	24
2.4.1	Sistemas multiagentes reativos	26
2.4.2	Sistemas multiagentes cognitivos	26
2.5 C	omunicação entre agentes	27
2.6 S	imulação de tráfego e gerenciamento de interseções urbanas	27
2.7 S	imulação baseada em agentes	28
2.8	Ferramentas utilizadas na simulação inteligente de tráfego	30
2.8.1	SUMO – <i>Simulation of Urban Mobility</i>	31
2.8.2	JADE – <i>Java Agent DEvelopment Framework</i>	33
2.8.3	TraSMAPI – <i>Traffic Simulation Manager API</i>	35
2.9	Modelagem de veículos no sumo	36
3	TRABALHOS RELACIONADOS	37
4	MATERIAL E MÉTODOS	41
4.1	Fundamentação teórica e arquitetura do sistema	41
4.2	Modelagem dos agentes.....	41
4.3	Variáveis de estado e parâmetros do sistema.....	42
4.4	Algoritmo de tomada de decisão	42
4.5	Cenários de simulação	43
4.6	Métricas de avaliação	45
4.6.1	Número de Veículos Concluintes (Throughput).....	45
4.6.2	Contagem de Colisões (Collision Count)	46
4.6.3	Tempo Médio de Viagem (Average Travel Time)	46
4.6.4	Velocidade Média (Average Speed).....	47
4.6.5	Tempo Médio de Espera (Average Waiting Time).....	47
4.6.6	Carga Comunicacional ACL (ACL Communication Load).....	48
4.7	Troca de informações via JADE	49
4.8	Ambiente de trabalho.....	49
4.8.1	Descrição da interface gráfica do sistema.....	50
4.8.2	Criação de cenários com o SUMO	51
4.9	Descrição da classe <i>DriverManager</i>	54
4.10	Análise do funcionamento do <i>framework</i> JADE-SUMO	56
5	RESULTADOS E DISCUSSÃO.....	59
5.1	Análise comparativa: ocorrência de acidentes e eficiência operacional	59
5.1.1	SUMO.....	59
5.1.2	Análise do mapa de calor da densidade de colisão	61
5.1.3	Análise da aproximação de veículos durante a colisão.....	62
5.2	JADE	63
5.3	Comparação	65
5	CONSIDERAÇÕES FINAIS	70
6	CONCLUSÃO.....	71
	REFERÊNCIAS	72

1 INTRODUÇÃO

Os acidentes de trânsito constituem um grande desafio de saúde pública em escala global e uma causa preponderante de mortalidade. Anualmente, as estimativas apontam para cerca de 1,3 milhão de mortes e 50 milhões de feridos no trânsito (WHO, 2013; Lozano *et al.*, 2012; Andrade *et al.*, 2014). Neste contexto, a mobilidade urbana contemporânea apresenta um paradoxo: apesar dos rápidos avanços tecnológicos em conectividade veicular, inteligência artificial e automação, as interseções permanecem como zonas críticas e gargalos para a segurança viária.

De forma preocupante, as interseções são o local de mais de 40% das colisões fatais registradas nas vias urbanas brasileiras (DENIT, 2024). Essa estatística é alarmante e encontra um paralelo na América do Norte, onde, segundo um relatório da *National Highway Traffic Safety Administration* (NHTSA), cerca de 36% de todos os acidentes de trânsito também ocorrem em interseções (Karbasi; Yang; Razavi, 2024; NHTSA, 2019). Essa concentração de acidentes se deve à confluência de múltiplos fatores: geometrias complexas, interações entre modais (veículos, pedestres, ciclistas), decisões humanas imprevisíveis e falhas de coordenação em tempo real (Spatharis e Blekas, 2022).

A literatura recente aponta que estratégias cooperativas baseadas em comunicação V2V (*vehicle-to-vehicle*) e V2I (*vehicle-to-infrastructure*), associadas a sistemas de transporte inteligentes (STI), podem reduzir em até 25% os atrasos e incidentes em interseções, especialmente quando aplicadas de forma descentralizada (Mozaffari *et al.*, 2024; Zhang e Wang, 2024). No entanto, grande parte dos estudos ainda assume cenários ideais com veículos 100% autônomos ou sem presença do condutor humano, desconsiderando o contexto “*driver-in-the-loop*”, no qual Sistemas Avançados de Assistência ao Condutor (ADAS) atuam em parceria com motoristas humanos parcialmente engajados. Este é, justamente, o cenário dominante nas próximas décadas, segundo projeções da SAE International (2023).

Neste contexto, os sistemas multiagentes (SMA) representam uma abordagem importante para modelar ambientes dinâmicos e heterogêneos, como as interseções urbanas. SMA permitem representar cada veículo, semáforo ou infraestrutura como um agente autônomo capaz de perceber, deliberar e agir em cooperação com os demais. Ferramentas como o JADE (*Java Agent Development Framework*), acopladas ao simulador de tráfego SUMO (*Simulation of Urban MObility*) via *TraSMaPI*, permitem simular e testar arquiteturas distribuídas com alto grau de fidelidade (Azevedo *et al.*, 2016; Soares *et al.*, 2014). Além disso, abordagens recentes

utilizando aprendizado por reforço multiagente (MARL) têm demonstrado resultados expressivos e eficácia na negociação de prioridade em interseções não sinalizadas, sem regras fixas, inclusive com incorporação de parâmetros cognitivos e comportamentais dos condutores (Gronauer; Diepold, 2022; Spatharis; Blekas, 2022; Chala; Kóczy, 2024). Ainda assim, persistem lacunas importantes, poucas abordagens avaliam a robustez desses modelos frente às normas da SAE J3014 (níveis 2 e 3 de automação), ou consideram explicitamente os limites cognitivos, perceptivos e comportamentais de motoristas humanos em cenários de simulação.

Este trabalho investiga o potencial da cooperação veicular mediada por agentes inteligentes em interseções urbanas não sinalizadas, adotando um modelo híbrido (condutor + automação) com foco na prevenção de colisões e fluidez do tráfego. Diferentemente de abordagens que focam apenas em veículos totalmente autônomos, este trabalho se concentra em um sistema de assistência ao condutor (ADAS) que opera em um modelo híbrido, onde a coordenação via agentes inteligentes é projetada para mitigar os riscos associados à imprevisibilidade do condutor humano em cruzamentos complexos, preenchendo uma lacuna crítica na transição para a automação completa.

1.1 Hipótese

A hipótese central deste trabalho é a implementação de um sistema multiagente cooperativo em interseções urbanas, utilizando JADE e SUMO, resultará em uma redução significativa no número de colisões e/ou no tempo de espera dos veículos, em comparação com cenários reativos, mesmo em condições de tráfego denso.

1.2 Objetivo

Este trabalho propõe e valida um framework integrado baseado na plataforma JADE para SMA, no simulador de tráfego SUMO, e na interface TraSMAPI para comunicação via protocolo TraCI. Para alcançar esse objetivo, o estudo se propõe aos seguintes objetivos específicos:

- a) definir e implementar agentes com papéis e comportamentos específicos, utilizando o framework JADE de modo a estruturar a lógica de cada agente e garantir que eles executem corretamente suas tarefas dentro do framework integrado;

- b) desenvolver uma réplica digital de interseções urbanas, por meio do *framework* SUMO, integrando o TraSMAPI para análise de dados e coleta de métricas de desempenho, visando criar um ambiente de teste representativo sobre o qual os agentes possam atuar e ser avaliados;
- c) elaborar uma arquitetura de simulação e controle que permita a comunicação efetiva entre agentes, assegurando conformidade com a norma SAE J3016™, para que todas as mensagens trocadas sigam um padrão interoperável e reflitam fielmente os cenários de condução autônoma;
- d) validar e testar o sistema proposto, analisando métricas de redução de colisões com o objetivo de demonstrar quantitativamente a eficácia do *framework* na melhoria da segurança viária.

Este texto está organizado da seguinte forma: o capítulo 2 apresenta o referencial teórico; o capítulo 3 apresenta os trabalhos correlatos; o capítulo 4 descreve os materiais, ferramentas e metodologia de simulação; o capítulo 5 discute os resultados obtidos e o capítulo 6 conclui com as limitações e perspectivas futuras da pesquisa.

2 REFERÊNCIAL TEÓRICO

Este capítulo apresenta a base teórica deste trabalho, no qual são apresentados os conceitos fundamentais relacionados aos sistemas multiagentes, veículos inteligentes e ferramentas de simulação.

2.1 Sistemas de transporte inteligentes

Os sistemas de transportes inteligentes (STI) são o resultado de desenvolvimentos tecnológicos e organizacionais, com o objetivo de melhorar a eficiência, a segurança e a sustentabilidade dos sistemas de transporte (Azad *et al.*, 2024). O trabalho com STI começou em Londres em 1868, usando um sistema movido a gás de luzes vermelhas e verdes, em que o vermelho significava "pare" e o verde significava "siga em frente", comumente conhecido como semáforo. Quando o sistema a gás causou uma explosão após um vazamento, seu uso foi interrompido. Ele foi substituído pelo semáforo elétrico. No entanto, a invenção dos carros, o crescimento populacional e o desenvolvimento da industrialização resultaram em um crescimento drástico do tráfego. Assim, para atender a essas demandas e estabelecer um sistema de transporte mais seguro, um projeto global após o outro foi desenvolvido (Azad *et al.*, 2024).

Daí a participação de países como o Japão com um Sistema de Veículos Inteligentes (SVI) em 1980. No mesmo ano, na Alemanha, a Siemens realizou o primeiro trabalho em sistemas de orientação rodoviária em Berlim, conhecidos como sistemas inteligentes de veículos em autoestradas (Avci; Koca, 2024). Vários termos foram sugeridos por europeus e americanos, mas o termo STI foi mantido. Desde então, o STI tornou-se parte integrante do gerenciamento de sistemas de transporte em todo o mundo, inclusive no Brasil. Os STI são ferramentas tecnológicas avançadas que combinam inteligência artificial, comunicações digitais e automação (Azad *et al.*, 2024).

Eles abrangem uma série de sistemas, sendo os principais: Redes *Ad-Hoc* Veiculares (VANETs); semáforos inteligentes; semáforos virtuais; e previsão de mobilidade. A VANET é alimentada pelo ecossistema da internet dos veículos, cuja função é coletar e compartilhar informações sobre carros, estradas, infraestrutura, edifícios e muito mais. Há várias subcategorias, a primeira das quais é a comunicação veículo a veículo (V2V), durante a qual os dois trocam informações para descobrir a localização, a velocidade e a direção um do outro. Isso gera dados importantes para o desenvolvimento de aplicativos de segurança cooperativa para evitar acidentes e reduzir engarrafamentos e tempos de viagem (Satyanarayana;

Selvakumar, 2022). A segunda é a comunicação dos veículos com a infraestrutura (V2I), como semáforos, câmeras, sensores e assim por diante. Os dados coletados podem ser usados para criar aplicativos de comunicação para fornecer aos motoristas informações em tempo real sobre as condições da viagem e a existência de engarrafamentos ou acidentes, o que, por sua vez, melhora a segurança e o fluxo do tráfego (HE *et al.*, 2019).

O V2I também inclui a comunicação veículo-servidor (V2S), que facilita o contato entre um veículo e um servidor remoto. Esse sistema possibilita o monitoramento do tráfego em tempo real e a otimização das rotas. Há outros sistemas, como a comunicação veículo para casa (V2H), que facilita a conexão do carro a equipamentos domésticos, incluindo pontos de recarga e aparelhos inteligentes (Yang *et al.*, 2024). A comunicação veículo-nuvem, que é usada para estabelecer uma conexão entre o veículo e os serviços baseados em nuvem. A comunicação V2N permite que o veículo se conecte à rede externa, como uma rede celular, com o objetivo de acessar as funcionalidades dos serviços baseados em nuvem para se conectar a semáforos inteligentes e sistemas de gerenciamento de tráfego (Elassy *et al.*, 2024).

Os semáforos inteligentes, também conhecidos como semáforos tricolores inteligentes, assumem uma função essencial no monitoramento do tráfego e na melhoria da segurança nas estradas. Para isso, eles coletam dados em tempo real de equipamentos como câmeras, radares e sensores para ajustar seu tempo de acordo com o volume de tráfego, congestionamento e movimentos de pedestres (Zhu *et al.*, 2022). Além disso, ajudam a detectar veículos de emergência e modificam seu status para permitir que passem rapidamente, reduzindo, assim, o risco de colisões causadas pela ultrapassagem de sinais vermelhos. Portanto, graças a algoritmos avançados e tecnologias de ponta, eles facilitam o fluxo de tráfego, melhoram a segurança viária e reduzem as emissões (Fernando; Gupta, 2024).

Em resumo, os STI ajudam a otimizar a mobilidade, reduzindo o congestionamento, o tempo de viagem e os custos de transporte. Eles melhoram a atratividade do transporte público, a segurança viária e a competitividade e o desempenho do setor. Além disso, promovem um transporte acessível, seguro e econômico para todos. Seu desenvolvimento também permite uma gestão mais eficiente da energia e uma redução do impacto ambiental graças à troca de dados entre usuários, veículos, infraestrutura e meio ambiente (Elassy *et al.*, 2024). O desenvolvimento do STI demonstra eficácia significativa na redução de acidentes rodoviários, perdas econômicas e poluição do ar (Wang *et al.*, 2025). Esses sistemas também melhoram o conforto do usuário e aumentam a segurança das viagens. Além disso, as tecnologias de vigilância que incorporam algoritmos de aprendizagem profunda permitem que os incidentes sejam detectados rapidamente, melhorando assim a capacidade de resposta dos serviços de

emergência e o gerenciamento de situações críticas (Porwal *et al.*, 2024). Para entender melhor a eficácia do STI na melhoria da segurança e da conveniência do transporte, é muito importante ter conhecimento sobre veículos inteligentes. Isso se deve ao fato de que a incorporação de STI e veículos inteligentes é importante para a transformação das infraestruturas de mobilidade e do gerenciamento de transporte contemporâneo. Essa sinergia tecnológica e conceitual exige uma análise aprofundada dentro dessa estrutura de referência.

Em particular, a gestão de interseções urbanas representa um desafio onde a aplicação de STI se torna importante. A complexidade gerada pela confluência de múltiplos fluxos de veículos, pedestres e diferentes modais exige soluções que superem os semáforos tradicionais, justificando a exploração de abordagens distribuídas e inteligentes.


2.2 Veículos inteligentes

De acordo com a Administração Nacional de Segurança de Tráfego Rodoviário (*NHTSA - National Highway Traffic Safety Administration*), os veículos autônomos são definidos como sistemas capazes de operar sem intervenção humana direta. Esses sistemas utilizam tecnologias avançadas, como sensores, comunicação, inteligência artificial e automação, para realizar tarefas como navegação, direção, frenagem e aceleração (Hollowell, 2024). Esses veículos podem ser categorizados em dois principais níveis de automação: totalmente autônomo, que dispensam a presença de um motorista humano, e parcialmente automatizados, nos quais o condutor humano mantém algum grau de controle, assistido por tecnologias inteligentes (SAE, 2021). O desenvolvimento de veículos autônomos tem sido liderado por montadoras, empresas de tecnologia e instituições acadêmicas, com objetivos variados, como aprimorar a segurança no trânsito, reduzir congestionamentos, otimizar o tempo e promover eficiência energética (Anderson *et al.*, 2014). Além dos benefícios já mencionados, destaca-se que a implementação desses sistemas enfrenta desafios substanciais, incluindo barreiras regulatórias, dilemas éticos, preocupações com privacidade e a necessidade de reconfiguração da infraestrutura urbana para atender às novas demandas tecnológicas.

A padronização é importante no desenvolvimento de sistemas de automação veicular, garantindo que os sistemas sejam seguros, interoperáveis e alinhados com as melhores práticas do setor. O padrão SAE J3016™, estabelecido pela SAE Internacional, é amplamente reconhecido como a referência para a classificação de sistemas de automação de direção (SAE, 2021). Ele define seis níveis de automação e especifica as responsabilidades associadas a cada nível. No nível (0) não há autonomia, a partir do nível (1) os veículos dispõem de alguns

sistemas para auxílio ao condutor, enquanto no nível (5) o veículo tem autonomia total (Figura 2.1).

Figura 2.1- Os níveis de automação definidos pela norma SAE J301.



Fonte: SAE International.

A Figura 2.1 apresenta os níveis de automação de condução definidos pela SAE (*Society of Automotive Engineers*), que vão do nível 0 (sem automação) ao nível 5 (automação completa). No nível 1, o motorista deve permanecer totalmente atento, enquanto o veículo fornece assistência por meio de alertas. No nível 2, a automação parcial permite que o veículo controle a velocidade e a manutenção na faixa, mas o motorista ainda precisa supervisionar. O nível 3 introduz a automação condicional, onde o veículo realiza a maior parte das tarefas de condução, mas requer intervenção humana quando necessário. No nível 4, ou automação elevada, o veículo opera de forma autônoma em condições específicas, com interação humana mínima. Por fim, no nível 5, o veículo é totalmente autônomo e não exige intervenção ou presença humana (SAE, 2021).

A conformidade com o SAE J3016™ é importante para o desenvolvimento de sistemas ADAS, especialmente aqueles aplicados em interseções urbanas, onde os riscos são elevados e as margens para erro são mínimas. Anderson *et al.* (2014) indicam que a implementação de sistemas ADAS de acordo com os padrões estabelecidos pode reduzir significativamente o número de acidentes, melhorando a resposta do veículo a emergências. As redes de veículos são particularmente importantes nos sistemas de transporte modernos (Yeferny e Hamad, 2021). Elas viabilizam a comunicação entre veículos (V2V), entre veículos e infraestrutura

(V2I) e entre veículos e pedestres (V2P), aprimorando a segurança e a eficiência do tráfego. Aplicações para a prevenção de colisões permitem a troca de informações em tempo real sobre velocidade, posição e condições da estrada, reduzindo o risco de acidentes. Além disso, essas redes possibilitam alertas de emergência, notificando sobre frenagens bruscas, obstáculos ou condições perigosas (Raj *et al.*, 2023).

As redes veiculares são fundamentais para o progresso do transporte inteligente, pois possibilitam melhorar a segurança nas estradas, otimizar a regulamentação do tráfego e apoiar o desenvolvimento de tecnologias de direção autônoma (Shi *et al.*, 2024). A comunicação em tempo real possibilita o compartilhamento de dados críticos, como a posição de veículos e alertas de perigo, promovendo estradas mais seguras (Tahir *et al.*, 2022). Embora os veículos inteligentes e os sistemas de transporte inteligentes usem várias tecnologias, a maioria dos sistemas de transportes inteligentes são usados para melhorar a mobilidade urbana. No entanto, dada a complexidade das interações, outros sistemas entram em ação para permitir a cooperação e a coordenação do comportamento dos veículos, da infraestrutura e dos usuários, como por exemplo os sistemas multiagentes (Xu *et al.*, 2024). Eles facilitam a alocação de tarefas, o compartilhamento de recursos e a troca de informações.

É nesse contexto de crescente automação e comunicação veicular que a coordenação em pontos críticos como interseções se torna o próximo grande desafio. A capacidade dos veículos de trocar informações abre a porta para sistemas de decisão cooperativos, onde a abordagem de sistemas multiagentes se apresenta como um paradigma natural para modelar e gerenciar essas interações complexas.

2.3 Agentes inteligentes

Agentes inteligentes são entidades autônomas capazes de perceber seu ambiente por meio de sensores, interpretar as informações coletadas e tomar decisões para atingir um objetivo, como temperatura, luminosidade e posição de objetos (Cheng *et al.*, 2018a). Eles são aplicáveis em áreas como robótica, processamento de linguagem natural, jogos e aprendizado de máquina (Mathur *et al.*, 2024).

Na robótica, agentes inteligentes são amplamente utilizados em veículos autônomos para realizar tarefas complexas, como navegação em ambientes urbanos dinâmicos, evitando colisões e otimizando rotas em tempo real. Esses sistemas combinam percepção baseada em sensores LiDAR e câmeras com algoritmos de planejamento adaptativo, garantindo segurança e eficiência (Zhang *et al.*, 2023).


No processamento de linguagem natural (PLN), agentes conversacionais evoluíram para além de simples respostas reativas, passando a oferecer interações proativas e personalizadas. Assistentes virtuais modernos, por exemplo, são capazes de antecipar necessidades do usuário, sugerir ações e manter diálogos contextuais, graças à integração com modelos de linguagem de grande escala (Huang et al., 2023).

Em jogos digitais, agentes inteligentes são aplicados para criar personagens não jogáveis (NPCs) com comportamento adaptativo, capazes de aprender estratégias e reagir dinamicamente às ações do jogador. Um exemplo notável é o uso de aprendizado por reforço profundo para dominar jogos complexos como *Stratego*, demonstrando a capacidade desses agentes de lidar com ambientes parcialmente observáveis e de alta complexidade estratégica (Perolat et al., 2022).

No aprendizado de máquina e controle industrial, agentes baseados em aprendizado por reforço são empregados para otimizar processos produtivos, reduzir consumo energético e melhorar a eficiência operacional. Esses agentes aprendem políticas de controle diretamente a partir de interações com o ambiente, dispensando modelos matemáticos explícitos e adaptando-se a condições variáveis (Li et al., 2023).

A arquitetura desses agentes geralmente integra módulos distintos para percepção, modelagem e ação, possibilitando lidar tanto com situações simples quanto complexas, além de ajustar dinamicamente o comportamento conforme as mudanças do ambiente (Xi et al., 2025). A Figura 2.2 ilustra o esquema fundamental do processo de raciocínio implementado por um agente: cada agente é constituído por sensores e atuadores, responsáveis por perceber e interagir, respectivamente, com o ambiente ao seu redor.

Figura 2.2 - Esquema do processo de raciocínio de um agente.



Fonte: Russell; Norvig (2016).

2.4 Sistemas multiagentes

Os SMAs são ecossistemas digitais que consistem em entidades autônomas, chamadas agentes, cada uma com metas próprias (agentes). A integração desses agentes em um ambiente de interação dinâmica e evolutiva, uns constringendo outros e adotando estratégias cooperativas ou competitivas para atingir metas individuais ou coletivas (Nezamoddini; Gholami, 2022). No âmbito da gestão do tráfego em cidades inteligentes, os SMAs têm um uso óbvio. Eles permitem otimizar os fluxos de veículos em tempo real, ajustando os semáforos de forma inteligente e priorizando os diferentes modos de transporte (Musa *et al.*, 2023). Além disso, os sistemas contribuem para a otimização dos horários do transporte público, beneficiando o planejamento dinâmico e reativo a perturbações ou acidentes (Assbeihat e Rafi, 2021). Complementarmente, os SMAs facilitam o planejamento de trajetos multimodais, integrando diversos meios de transporte como ônibus, metrô, bicicleta e carro, conforme as preferências dos usuários e as restrições de tempo (Matei *et al.*, 2024).

Na área de transportes, a aplicação dos SMAs reveste-se de especial relevância, pois possibilita a modelagem precisa das interações complexas entre os múltiplos atores da mobilidade, tais como veículos, pedestres e infraestruturas (Delcea e Chirita, 2023). Essa abordagem detalhada permite a simulação e análise de fenômenos emergentes como a formação de congestionamentos e a auto-organização do tráfego que frequentemente escapam à compreensão por meio de modelos mais tradicionais (Fernández-Isabel *et al.*, 2020). Para além do setor de transportes, os SMAs encontram aplicações em diversas outras áreas, como economia, biologia, robótica, gestão de projetos e simulação social, contribuindo significativamente para a resolução de problemas complexos (Dorri *et al.*, 2018).

No campo da robótica, por exemplo, os SMAs tornam um ponto importante na coordenação de múltiplos robôs, seja em missões de busca e resgate ou em aplicações industriais, permitindo que os dispositivos colaborem para alcançar objetivos comuns ou distribuam tarefas com base em suas capacidades específicas (An *et al.*, 2024). Ademais, os SMAs têm sido amplamente investigados no âmbito dos sistemas de transporte inteligente, dada a sua capacidade de simular comportamentos complexos em ambientes urbanos (Xu *et al.*, 2024).

Nesse contexto, um agente é definido como uma entidade autônoma capaz de perceber o ambiente e tomar decisões de forma independente, com base em um conjunto preestabelecido de regras ou objetivos (Russell; Norvig, 2016). Quando aplicados aos sistemas ADAS, os SMAs viabilizam a coordenação entre múltiplos agentes, como veículos, semáforos e sensores,

otimizando o fluxo de tráfego e incrementando a segurança em interseções. Os estudos recentes demonstram que a utilização de SMA pode reduzir significativamente o número de colisões e melhorar a eficiência do tráfego em interseções.

Por exemplo, Capasso *et al.* (2021) propõe um sistema de interseção inteligente que considera a incerteza no ambiente operacional e a presença de veículos conduzidos por humanos, propondo um sistema baseado em agentes para a coordenação de veículos autônomos em interseções, mostrando que a abordagem pode reduzir atrasos e evitar acidentes, mesmo em cenários de alta densidade de tráfego.

Além disso, a flexibilidade dos SMAs permite a adaptação a diferentes configurações de interseções e a integração depende de tecnologias de comunicação, como V2V e V2I, o que é importante para a implementação de soluções escaláveis e robustas (Vasirani; Ossowski, 2012). Os SMAs podem ser utilizados em conjunto com diversos frameworks ideais para avaliar e otimizar as estratégias de gestão do tráfego, considerando as restrições e os objetivos específicos de cada sistema de transporte.

O Netlogo que é uma ferramenta de simulação baseada em agentes, permite criar modelos personalizados de comportamento de agente utilizando dados variados para explorar cenários e identificar padrões emergentes em sistemas complexos (Tisue; Wilensky, 1999; Tisue *et al.*, 2004). O VISSIM que é uma ferramenta de simulação de tráfego, permite analisar dados precisos de comportamento de veículos e pedestres para otimizar a operação de redes urbanas e avaliar estratégias de gestão do tráfego (Fellendorf; Vortisch, 2010). O Aimsun é uma das ferramentas mais avançadas para a simulação de tráfego e mobilidade urbana, integra dados de tráfego provenientes de simulações microscópicas, mesoscópicas e macroscópicas, facilitando o planejamento e a operação de redes de transporte por meio de análises detalhadas. Essa integração permite uma compreensão abrangente da dinâmica do tráfego, auxiliando nos processos de tomada de decisão na gestão de transportes e no desenvolvimento da infraestrutura (Casas *et al.*, 2010).

O MATSim é um framework de simulação de tráfego baseado em multiagentes, permite simular o comportamento de grandes populações e a interação entre diferentes modais de transporte (Horni *et al.*, 2016). O SUMO permite a utilização de dados de trânsito em tempo real e históricos para modelar o comportamento individual dos veículos e otimizar o fluxo de tráfego (Mohammadi *et al.*, 2024).

2.4.1 Sistemas multiagentes reativos

O conceito de agentes reativos tem sido amplamente investigado, especialmente no contexto de SMA. Esses agentes operam em ambientes compartilhados, onde múltiplos agentes interagem simultaneamente (Weyns; Michel, 2015). Para que o sistema alcance seus objetivos, os agentes trocam informações sobre o estado do ambiente, status interno, mensagens de coordenação, histórico de interações e objetivos individuais e coletivos, permitindo uma melhor sincronização e tomada de decisão (Raeis; Golestani, 2021). Os agentes reativos são caracterizados pela sua incapacidade de resolver problemas complexos que exigem raciocínio aprofundado ou planejamento estratégico, já que não possuem um modelo interno do ambiente nem histórico de suas ações passadas. Suas decisões são baseadas unicamente nas percepções imediatas do estado atual do ambiente (Mahmoud, 2020).

Em aplicações práticas, como a busca por informações específicas em redes computacionais, os agentes reativos podem ser extremamente úteis. Nesses casos, a simplicidade das tarefas e a independência das informações permitem que os agentes atuem de forma eficiente, sem a necessidade de memória ou aprendizado prévio. Por exemplo, em redes descentralizadas, agentes reativos podem localizar informações específicas baseando-se apenas em suas interações locais e em padrões contextuais emergentes (Russell; Norvig, 2022). Esse paradigma é particularmente relevante em cenários onde rapidez e simplicidade são mais importantes que sofisticação computacional.

2.4.2 Sistemas multiagentes cognitivos

Os agentes cognitivos são caracterizados por sua capacidade de manter uma representação simbólica explícita do ambiente em que operam (Xiong *et al.*, 2024). Além disso, armazenam um histórico de ações realizadas, o que lhes permite tomar decisões informadas no futuro com base em experiências passadas (Olschewski *et al.*, 2024). Em um SMA, os agentes são projetados para interagir uns com os outros por meio de troca de mensagens estruturadas, possibilitando a coordenação e colaboração em tarefas compartilhadas. Essa dinâmica de interação promove maior flexibilidade e eficiência, permitindo, por exemplo, a resolução de conflitos de negociação e a implementação de esquema de alocação de tarefas baseados em representações mútuas (Wooldridge, 2009). Um exemplo notável de SMA cognitivo é o sistema de Smart Parking no qual os agentes trocam diversas informações sobre a localização dos veículos, a disponibilidade de vagas, dentre outras, para o funcionamento do sistema (Belkhala

et al., 2019). Nesse cenário, veículos são modelados como agentes autônomos em busca de vagas de estacionamento (Oliveira *et al.*, 2023). Essa abordagem exemplifica o uso de agentes cognitivos em sistema distribuídos, destacando sua capacidade de integrar cooperação e aprendizado para alcançar objetivos compartilhados (Soorati *et al.*, 2022).

2.5 Comunicação entre agentes

Os agentes precisam cooperar para atingir objetivos comuns, interagindo por meio de mensagens estruturadas. Para isso, são utilizadas linguagens específicas que facilitam a formulação e o entendimento dessas mensagens. Entre as principais linguagens, destacam-se KQML (Knowledge Query and Manipulation Language) é focada na troca dinâmica de informações e no controle de diálogos entre agentes. Ela define um conjunto de “performativas”, atos de fala como *ask*, *tell*, *subscribe*, *advertise*, que especificam a intenção do emissor, o KIF (Knowledge Interchange Format) é uma linguagem de representação de conhecimento baseada em lógica de primeira ordem. e ACL (Agent communication language) oferece uma linguagem para a comunicação externa entre agentes, cada uma com características específicas que auxiliam na comunicação efetiva entre agentes; o ACL é mais relacionado a este trabalho.

Um SMA não impõe a utilização de uma linguagem específica para o conteúdo. Esse padrão é popular em plataformas multiagente como JADE, sendo amplamente reconhecido como um dos pilares na modelagem da interação entre agentes (Amirkhani; Barshooi, 2022). Estudos recentes, como os de Albrecht e Wooldridge (2022) e Panisson *et al.* (2022), destacam que essas linguagens continuam sendo fundamentais na construção de SMA, especialmente em cenários que exigem coordenação e troca de informações complexas. Ao combinar esses protocolos, os sistemas multiagentes podem alcançar altos níveis de eficiência e flexibilidade, aplicando-se a diversas áreas como tráfego, robótica e computação distribuída.

2.6 Simulação de tráfego e gerenciamento de interseções urbanas

A simulação de tráfego tem se consolidado como uma ferramenta indispensável na engenharia de transportes, permitindo modelar, analisar e otimizar o fluxo de veículos em ambientes urbanos e rodoviários. Ao criar ambientes virtuais controlados e realistas, essa técnica viabiliza a avaliação de diferentes estratégias de mobilidade antes da aplicação no mundo real. Estudos como o de Chao *et al.* (2020) ressaltam a importância da simulação no

entendimento dos comportamentos viários, enquanto Razack *et al.* (2024) destacam sua aplicação na avaliação de soluções de estacionamento inteligente. Gonçalves *et al.* (2023) utilizaram padrões de mobilidade derivados de sensores reais para desenvolver simulações que permitiram estimar emissões veiculares e tempos de parada em cenários urbanos, fornecendo subsídios para o planejamento de cidades mais sustentáveis. Adicionalmente, Hu *et al.* (2025) demonstraram o potencial de métodos de aprendizado profundo ao propor um modelo de rede neural convolucional de grafos dinâmicos, que superou abordagens tradicionais na previsão de fluxo de tráfego.

Esse potencial se intensifica quando a simulação é aplicada ao gerenciamento de interseções urbanas, um dos maiores desafios do controle viário moderno. As interseções são pontos críticos da malha urbana, marcados por múltiplos conflitos potenciais entre veículos, pedestres e ciclistas. Conforme destacado por Cheng *et al.* (2018b), cerca de 40% dos acidentes urbanos ocorrem nesses locais, o que evidencia a necessidade de soluções tecnológicas para melhorar a fluidez e a segurança. Abordagens tradicionais vêm sendo progressivamente substituídas por sistemas inteligentes, como o proposto por Dresner e Stone (2008), que empregam agentes para coordenar a travessia de veículos, eliminando a necessidade de semáforos e reduzindo significativamente o tempo de espera.

Nesse contexto, a integração de SMA com ADAS surge como uma abordagem de grande potencial. Essa combinação oferece uma solução holística para o gerenciamento seguro e eficiente de interseções, permitindo a simulação de cenários urbanos variados e realistas. Estudos como o de Camara *et al.* (2020) reforçam a importância de empregar dados reais de tráfego para garantir a representatividade dos cenários simulados. Além disso, simulações de situações críticas, como quase-acidentes, são essenciais para identificar falhas e áreas de melhoria nos sistemas ADAS. Segundo Tettamanti *et al.* (2016), a utilização de simulações nesse contexto contribui para mitigar riscos antes da implementação prática, promovendo maior segurança e confiança nas tecnologias assistivas veiculares.

2.7 Simulação baseada em agentes

A Simulação Baseada em Agentes (ABS) tem se consolidado como uma abordagem poderosa para a análise de sistemas complexos, especialmente no contexto da mobilidade urbana. Fundamentada na noção de agentes autônomos, capazes de perceber o ambiente, tomar decisões e agir conforme regras e objetivos próprios (Park *et al.*, 2024), essa metodologia permite modelar fenômenos emergentes, adaptar-se a mudanças de cenário e representar

interações não lineares entre múltiplos elementos do sistema. Tais características são particularmente relevantes no estudo do tráfego urbano, que envolve múltiplos atores, veículos, pedestres, sinais, infraestrutura operando de forma dinâmica e interdependente.

As simulações de tráfego, especialmente as de natureza microscópica, têm se mostrado essenciais na análise de interações individuais entre veículos e no detalhamento do comportamento em redes complexas (Toledo *et al.*, 2005). Ao integrar a modelagem baseada em agentes a esse tipo de simulação, é possível obter uma representação mais realista e granular dos processos de mobilidade, avaliando, por exemplo, os efeitos de políticas públicas, alterações na infraestrutura viária ou a introdução de tecnologias inteligentes de controle. Gao *et al.* (2024) destacam como essa abordagem captura fenômenos emergentes e dinâmicos em escalas variadas, fornecendo subsídios valiosos para o planejamento e a gestão urbana.

O crescente interesse acadêmico nessa área é evidenciado pela análise bibliométrica de Ionescu *et al.* (2024), que aponta um aumento expressivo de publicações relacionadas à integração entre inteligência artificial e simulação baseada em agentes. Essa convergência tem expandido as aplicações da ABS para além da análise descritiva, incorporando elementos preditivos e adaptativos, como o aprendizado de máquina e algoritmos evolutivos (Dyer *et al.*, 2023). Os sistemas multiagentes, ao reproduzirem o comportamento de indivíduos ou organizações em cenários urbanos, têm permitido avaliar a eficácia de intervenções como o controle inteligente de cruzamentos, sistemas cooperativos de tráfego e veículos autônomos.

Do ponto de vista metodológico, a ABS se sustenta em três pilares: os agentes, que representam unidades individuais como condutores ou veículos; o ambiente, que engloba as ruas, sinais e estruturas urbanas; e as interações, que modelam os comportamentos coordenados, autorregulados ou adaptativos desses agentes (Macal; North, 2008). Embora os termos ABS (Agent-Based Simulation) e ABM (Agent-Based Model) sejam muitas vezes usados de forma intercambiável, uma distinção técnica os separa: o ABM refere-se à estrutura conceitual do modelo, enquanto a ABS enfatiza o processo de execução dinâmica da simulação ao longo do tempo (Macal; North, 2009).

Apesar de seu potencial, essa abordagem enfrenta desafios. Entre eles, destacam-se as exigências computacionais, especialmente quando o número de agentes é elevado, o que pode limitar a escalabilidade dos modelos (Chopra *et al.*, 2024; Park *et al.*, 2024). Além disso, a modelagem comportamental dos agentes, muitas vezes baseada em regras simplificadas, pode não capturar toda a complexidade observada no comportamento real (Squazzoni *et al.*, 2020). A calibração e validação desses modelos também impõem barreiras técnicas, como apontado

por Quera-Bofarull *et al.* (2023), devido à dificuldade em inferir parâmetros realistas e representativos com base em dados empíricos.

Recentemente, abordagens inovadoras têm buscado superar essas limitações. Montali *et al.* (2024), por exemplo, propõem a utilização de simulações multiagente formuladas como problemas de modelagem generativa condicional. Nesse modelo, a geração autorregressiva de cenários de tráfego é condicionada por três restrições fundamentais: frequência de amostragem em 10 Hz, separação entre comportamento do veículo e o ambiente, e duração total da simulação de 8 segundos em 80 etapas. Essa metodologia assegura uma representação estocástica e realista dos eventos de condução urbana.

Dessa forma, a simulação baseada em agentes, quando integrada a ferramentas de modelagem microscópica de tráfego, amplia significativamente a capacidade de compreender e projetar sistemas de mobilidade mais eficientes, seguros e sustentáveis. Ao permitir a representação simultânea da infraestrutura física e dos processos decisórios individuais dos usuários, essa abordagem oferece uma perspectiva mais abrangente e realista da dinâmica urbana, consolidando-se como um instrumento fundamental para o planejamento de cidades inteligentes e resilientes.

2.8 Ferramentas utilizadas na simulação inteligente de tráfego

Para possibilitar a modelagem e simulação de sistemas complexos de tráfego urbano com comportamento dinâmico e adaptativo, é fundamental contar com um conjunto de ferramentas robustas, interoperáveis e aderentes às necessidades da simulação baseada em agentes. Esta seção apresenta os principais softwares empregados neste trabalho, enfatizando suas funcionalidades, estrutura e formas de integração. A seguir, são detalhadas as três ferramentas principais: o simulador SUMO, o framework de desenvolvimento multiagente JADE e a interface de integração TraSMAPI.

A escolha desta suíte de ferramentas não foi arbitrária. O SUMO foi selecionado por ser um simulador de tráfego microscópico de código aberto, consolidado na comunidade científica e que oferece alta fidelidade na modelagem do comportamento individual de veículos. O JADE, por sua vez, foi escolhido por ser um framework robusto e compatível com os padrões da FIPA (*Foundation for Intelligent Physical Agents*) para o desenvolvimento de sistemas multiagentes, facilitando a implementação de comportamentos complexos e da comunicação entre agentes. Finalmente, a interface TraSMAPI foi fundamental, pois atua como uma ponte de comunicação de alto nível, abstraindo as complexidades do protocolo TraCI e permitindo uma integração

síncrona e eficiente entre a lógica dos agentes (JADE) e a simulação do ambiente (SUMO). Essa combinação específica oferece a modularidade e o controle necessários para avaliar o sistema de assistência proposto.


2.8.1 SUMO – *Simulation of Urban Mobility*

O SUMO é um simulador de tráfego urbano de código aberto amplamente utilizado na comunidade científica e desenvolvido sob licença *Eclipse Public License* (EPL) pelo Instituto de Sistemas de Transporte do Centro Aeroespacial Alemão. Criado com o objetivo de padronizar a avaliação e comparação de modelos microscópicos de tráfego, o SUMO resolve limitações associadas ao uso de múltiplas simulações isoladas, oferecendo uma base comum para experimentos reprodutíveis e comparáveis (Krajzewicz *et al.*, 2002; Brockfeld *et al.*, 2003).

Esse simulador suporta tráfego multimodal e intermodal, modelando veículos individualmente e suas interações, como seguimento de carro (*car-following*), mudança de faixa e controle em interseções. Também incorpora modelos para pedestres e suas interações com a infraestrutura viária. Dentre suas funcionalidades destacam-se a simulação microscópica, controle semafórico configurável, integração com ferramentas externas via TraCI (*Traffic Control Interface*) e suporte a diversos cenários urbanos.

A Figura 2.3 ilustra uma simulação realizada no ambiente SUMO, representando uma interseção com múltiplas vias controladas por semáforos, enquanto o Quadro 2.1 apresenta um resumo das principais aplicações incluídas no pacote SUMO, como a interface gráfica (SUMO-GUI), os conversores de rede (NETCONVERT, NETGENERATE) e o editor gráfico (NETEDIT).

Figura 2.3 - Ambiente SUMO.



Fonte: Milfort (2025).

O pacote SUMO tem sido usado em vários projetos de pesquisa nacionais e internacionais desde 2001. As aplicações incluem: avaliação de sinais de trânsito, seleção e redirecionamento de rotas, avaliação de métodos de monitoramento de tráfego, simulação de comunicações veiculares, previsão de tráfego, previsões.

Quadro 2. 1 - Quadro das aplicações SUMO.

Nome da aplicação	Descrição
SUMO	A simulação microscópica sem visualização; aplicação de linha de comando
SUMO-GUI	A simulação microscópica com interface gráfica do usuário
SUMO-CONSOLE	A simulação microscópica modo console
NETCONVERT	Importador e gerador de rede; lê redes rodoviárias de diferentes formatos e as converte para o formato SUMO
NETEDIT	Um editor gráfico de redes
NETGENERATE	Gera redes abstratas para a simulação SUMO

Fonte: Milfort (2025).

Além disso, várias extensões e middlewares foram desenvolvidos para ampliar sua funcionalidade, como mostra o Quadro 2.2. Dentre elas, destacam-se a interface TraCI4Matlab, a biblioteca TraaS (SOAP), e o middleware LiSuM, que conecta SUMO ao sistema LISA+.

Quadro 2. 2 - Quadro das aplicações e middleware associados.

Nome da aplicação	Descrição
TraCI4Matlab	Uma interface Matlab para a conexão e extensão de informações via TraCI Andres Acosta
TraaS	Uma interface SOAP (serviço web) para a conexão e extensão de informações via TraCI de Mario Krumnow, também uma biblioteca cliente Java TraCI.
LiSuM	LiSuM é um middleware que associa LISA + ao SUMO

Fonte: Milfort (2025).

A execução de simulações no SUMO requer arquivos de entrada específicos, como descrito no Quadro 2.3, o arquivo de configuração (config. sumocfg), a rede viária (net.xml), as rotas (route.xml) e componentes adicionais (additional.xml), descrevem todos os elementos envolvidos na simulação.

Quadro 2. 3 - Arquivos entrada no sumo.

Arquivos	Descrição
config. sumocfg	Carregar o arquivo de configuração da simulação SUMO
net.xml	Carregar a descrição da rede viária a partir do arquivo
route.xml	Carregar as descrições de rotas a partir de ARQUIVO(s)
additional.xml	Carregar outras descrições a partir de ARQUIVO(s)

Fonte: Milfort (2025).

2.8.2 JADE – Java Agent DEvelopment Framework

O JADE é um middleware para desenvolvimento de sistemas multiagente (SMA) compatível com as especificações da FIPA (Foundation for Intelligent Physical Agents), que padroniza a estrutura e a comunicação entre agentes inteligentes. Essa plataforma oferece mecanismos robustos para envio e recepção de mensagens ACL, controle remoto de agentes,

descoberta de serviços e gerenciamento da infraestrutura distribuída, por meio dos agentes internos AMS (*Agent Management System*) e DF (*Directory Facilitator*) (Bellifemine *et al.*, 2005).

A estrutura do JADE é modular e escalável, baseada em contêineres que hospedam agentes, permitindo sua migração entre nós e a orquestração distribuída de comportamentos. A instalação do framework envolve a configuração das variáveis de ambiente JADE_HOME e CLASSPATH, além da extração de pacotes como jadeBin, jadeDoc, jadeExamples e jadeSrc, conforme mostrado no Quadro 2.4.

Quadro 2. 4 - Distribuição dos arquivos JADE

Arquivo	Descrição
jadeBin.zip	Contém apenas os arquivos Java pré-compilados (.jar) prontos para uso.
jadeDoc.zip	Contém a documentação, incluindo os guias para administrador e para programadores.
jadeSrc.zip	Contém todos os códigos-fonte de JADE.
jadeAll.zip	Contém todos os arquivos citados acima.

Fonte: Milfort (2025).


O código-fonte do JADE é organizado em pacotes Java especializados, descritos no Quadro 2.5 e na Figura 2.4. Esses pacotes implementam funcionalidades como o núcleo do sistema (jade.core), parsing de mensagens (jade.lang.acl), protocolos (jade.proto) e gerenciamento da ontologia de comunicação entre agentes (jade.domain).

Quadro 2. 5 - Pacotes JADE.

Pacote	Descrição
jade.core	Coração do JADE. Gerência os agentes e containers.
jade.content	Gerência o conteúdo das mensagens. Converte os formatos.
jade.domain	Implementa AMS e DF. Define a ontologia.
jade.imtp	Gerência a comunicação entre agentes. Utiliza RMI por padrão.
jade.lang.acl	Gerencie as mensagens ACL. Inclui parser e codificador.
jade.wrapper	Permite usar o JADE como biblioteca.

Fonte: Milfort (2025).

Figura 2.4 - Estrutura de diretórios JADE.



Fonte: Milfort (2025).


2.8.3 TraSMAPI – Traffic Simulation Manager API

O TraSMAPI é uma interface de programação de aplicações que facilita a comunicação em tempo real entre agentes inteligentes e simuladores de tráfego como o SUMO. Desenvolvido no Laboratório de Inteligência Artificial e Ciência da Computação da Universidade do Porto, o TraSMAPI atua como uma ponte entre o JADE e o SUMO, abstraindo a complexidade da API de baixo nível do TraCI e oferecendo uma camada de alto nível para interação com a simulação (Timóteo *et al.*, 2012; Azevedo *et al.*, 2016).

A arquitetura proposta permite que agentes desenvolvidos no JADE acessem informações da simulação de tráfego, como posições de veículos, estados dos semáforos e eventos de colisão, e tomem decisões proativas para evitar incidentes e otimizar o fluxo. A Figura 2.5 representa essa integração, evidenciando a comunicação bidirecional entre JADE e SUMO mediada pelo TraSMAPI.

O protocolo TraCI é essencial nesse processo, permitindo a troca de dados entre os módulos e viabilizando decisões em tempo real baseadas em informações contextuais do tráfego (Krishnamoorthi, 2018). Essa abordagem é especialmente promissora para o desenvolvimento de sistemas avançados de gestão de tráfego urbano, combinando simulação detalhada, controle inteligente e escalabilidade adaptativa (Aloui; Hachicha; Zagrouba, 20

Figura 2.5 - Comunicação entre JADE e SUMO.



Fonte: SOARES *et al* (2013).

2.9 Modelagem de veículos no sumo

O primeiro passo para criar uma simulação no SUMO é construir uma rede viária, composta por entroncamentos (nós) e estradas (bordas) conectadas entre si (Lopez *et al.*, 2018). Essa rede é salva em um arquivo com a extensão “.net.xml”, que também contém informações sobre semáforos, se necessário. Em seguida, é gerado um arquivo de rota (rou.xml) para definir os movimentos dos veículos nessa rede. Este arquivo especifica as características dos veículos (tipo, cor, velocidade etc.) e o seu comportamento. O modelo Gipps utilizado no SUMO simula as características do tráfego, como os fluxos livres e congestionados, adaptando a velocidade dos veículos à do veículo líder para garantir um comportamento sem colisões. Essa velocidade, chamada de “velocidade de segurança”, é calculada a cada passo de tempo (Gudwin, 2016).

Ele suporta tráfego terrestre multimodal e intermodal. O SUMO modela veículos individuais e suas interações usando modelos de comportamento de acompanhamento de carros, mudança de faixa e interseção, além de usar modelos de pedestres para simular o movimento de pessoas e suas interações com os veículos. Além disso, o SUMO disponibiliza funcionalidades essenciais, incluindo a simulação microscópica, o gerenciamento de semáforos, a integração com ferramentas externas como o TraCI, e o suporte a uma ampla variedade de cenários de mobilidade urbana.

3 TRABALHOS RELACIONADOS

Este capítulo apresenta uma análise de trabalhos relacionados voltados para sistemas multiagentes, com foco nos comportamentos dos agentes em interseção, na qual são apresentadas as metodologias utilizadas, as variáveis estudadas, os resultados obtidos e comparações entre esses trabalhos para destacar os avanços e as limitações de cada abordagem.

O estudo realizado em Berlim por Garg *et al.*, (2023), tem por objetivo era otimizar os tempos de espera e de viagem, acrescentando semáforos nos cruzamentos. Para isso, o SUMO foi usado para simular três cenários de tráfego: baixo, moderado e alto, incorporando vários tipos de veículos (carros, caminhões, transporte público, motocicletas), bem como pedestres. Nos resultados, os pesquisadores mostram uma redução significativa nos tempos de espera dos veículos, especialmente nos cenários de tráfego intenso, o que levou a um melhor fluxo de tráfego e menos congestionamento. Graças à relevância desses resultados, reforçada pela abordagem prática e pelo uso de dados reais que esses autores utilizaram, é possível observar uma grande distinção. Entretanto, o estudo não trata especificamente de sistemas multiagentes, o que limita sua aplicabilidade em contextos mais complexos em que a interação entre veículos é importante. Garjan *et al.*, (2023) propõe uma estrutura de simulação de tráfego baseada em agentes que integra o JADE e o SUMO, na qual os componentes de simulação são definidos como agentes inteligentes. Esse método oferece grande flexibilidade, especialmente para a simulação de veículos autônomos, reproduzindo mais fielmente suas interações e tomadas de decisão em um ambiente urbano.

Por meio de um estudo de caso, os autores demonstram a eficácia dessa estrutura para simular o tráfego inteligente. Esse estudo é particularmente relevante porque combina uma abordagem multiagente com ferramentas testadas e comprovadas (SUMO e JADE), possibilitando o estudo e o aprimoramento do gerenciamento do tráfego urbano em contextos complexos. Tranos *et al.*, (2024) integraram sistemas de inteligência artificial. Isso representa uma nova abordagem para melhorar o gerenciamento de tráfego em interseções não sinalizadas, com base em um sistema de aprendizagem por reforço de vários agentes. Os autores empregaram uma metodologia baseada em um espaço de estado rico e um processo de aprendizagem profunda para modelar com precisão os fluxos de tráfego. No entanto, os resultados mostram que seu método tem potencial real para o controle automático de tráfego em redes rodoviárias de complexidade variável. Este estudo se destaca por sua abordagem inovadora de aprendizagem por reforço de vários agentes.

Seguindo a mesma lógica Chala e Kóczy (2024) em seu estudo, eles apresentam um sistema descentralizado para gerenciamento e otimização de tráfego em que cada interseção tem um controlador inteligente capaz de detectar veículos de emergência, avaliar o comprimento das filas e medir a distância dos veículos da interseção, levando em conta os tempos de espera acumulados. Foram testadas duas abordagens: na primeira, as interseções se comunicam entre si e, na segunda, não. Os resultados mostraram que o sistema colaborativo reduz significativamente o tempo de espera (em até 48,65%), o consumo de combustível e as emissões de CO, além de gerar espontaneamente “ondas verdes”. Essas descobertas demonstram que os agentes inteligentes podem, de forma autônoma e adaptável, melhorar significativamente a fluidez do tráfego urbano. Em um contexto urbano em que cada momento conta, é com isso em mente que o estudo de Biekerwalz e Behrisch (2019) se concentra em uma questão importante: veículos de emergência, em que eles propõem uma solução centrada nas necessidades de mobilidade humana. No método proposto, no qual os dados são trocados diretamente entre os veículos, os resultados facilitam o ajuste em tempo real da temporização dos semáforos para dar prioridade aos veículos de emergência nos cruzamentos. Ele foi projetado para avaliar indicadores importantes, como tempos de espera de emergência e o impacto no fluxo geral do tráfego.

Graças às simulações, foi possível otimizar as fases dos semáforos de forma bem planejada. Essa economia de tempo, importante para salvar vidas, é obtida sem interromper o fluxo de tráfego para outros usuários. Por fim, em uma tentativa de aproximar a teoria da realidade, Alekszejenkó e Dobrowiecki (2021) apresentam uma abordagem na qual um modelo urbano abstrato é combinado com uma simulação microscópica detalhada realizada na rede rodoviária de um distrito de Budapeste usando o SUMO. A fim de testar a relevância das conclusões tiradas do modelo simplificado, reflete-se a realidade complexa do tráfego. Para isso, os pesquisadores mediram vários indicadores de fluxo, avaliaram as diferenças entre o modelo e a simulação e examinaram a robustez de seus resultados diante da complexidade do sistema urbano. Os resultados confirmaram que, apesar da simplificação do modelo, as tendências observadas são consistentes com as derivadas da simulação detalhada, validando assim a abordagem teórica proposta. Ao contrário dos estudos que se concentram apenas na otimização dos semáforos ou na prevenção de acidentes, nossa abordagem visa a fornecer assistência proativa aos motoristas nos cruzamentos. Ao integrar módulos de comunicação entre agentes, técnicas de aprendizado (inspiradas no trabalho de (Tranos *et al.*, 2024; Chala; Kóczy, 2024)).

Liu *et al.* (2022) introduzem o *EdgeMap*, um sistema que recorre ao *Crowdsourcing* para atualizar mapas de alta resolução, fornecendo subsídios em tempo real para ajustes na sinalização viária. Essa estratégia converge com a proposta de otimização de cruzamentos, centrada na melhoria da gestão do tráfego, linha de pesquisa também explorada por Zhou *et al.* (2019), ao integrar computação em borda com inteligência artificial para análise instantânea de dados, favorecendo respostas ágeis em ambientes urbanos dinâmicos. Complementarmente, o enfoque de Liu *et al.* (2022) em atualizações cartográficas encontra eco nas contribuições de Chainbi e Hamdi (2022), os quais propõem uma arquitetura multiagente descentralizada voltada à autonomia nas decisões, aspecto essencial para soluções escaláveis em mobilidade urbana.

A simulação via SUMO, desenvolvida por Srivastava e Kumar (2020), oferece uma estrutura sólida para validar sistemas inteligentes de transporte, enquanto o uso de dados em tempo real por Namoun *et al.* (2021) assegura decisões responsivas baseadas em informações atualizadas. Li *et al.* (2024) ressaltam a importância da flexibilidade na gestão do tráfego, e Liu, Zhang e Wang (2022) reforçam a relevância da manutenção contínua de mapas, ambos elementos que podem ser integrados nesta investigação para fortalecer uma infraestrutura decisória em tempo real. Por fim, Azevedo *et al.* (2016) simulam um sistema multiagente voltado ao controle semafórico, utilizando ferramentas como JADE (Bellifemine *et al.*, 2005) para gerenciar os agentes, SUMO para simular o tráfego e TraSMAPI para possibilitar a comunicação entre os sistemas envolvidos.

Além disso, eles usaram *Q-Learning* como método de aprendizado dos agentes e implementam o protocolo de comunicação relacionado aos métodos de controle de semáforos para recuperar os valores e efetuar as mudanças de estado via TraCI (Wegener *et al.*, 2008). As inovações em inteligência artificial discutidas por Westin (2023), que examina tecnologias aplicadas a veículos cooperativos, oferecem uma perspectiva valiosa sobre como a comunicação veicular pode ser aprimorada, alinhando-se diretamente com o objetivo de integrar sistema ADAS.

Quadro 3. 1 - Quadro dos trabalhos relacionados.

Autores	Objetivo	Material & Método	Métricas
Milfort (2025)	Gerenciamento de colisões em interseções não sinalizadas por meio de agentes inteligentes com troca de mensagens.	SUMO, JADE via TraSMAPI	Tempo de espera; trocar de mensagens
Tranos <i>et al.</i> (2024)	Controle em interseções não sinal	SUMO + Deep RL multiagente	Sucesso no controle; velocidade; throughput
Chala & Kóczy (2024)	Gerenciar tráfego descentralizado	SUMO; agentes em cada interseção (com/sem comunicação)	Espera média; CO; combustível;
Garg <i>et al.</i> (2023)	Reduzir espera e viagem	SUMO; simulação em cenários (baixo, alto)	Tempo de espera; viagem; fluxo
Garjan <i>et al.</i> (2023)	Simular veículos autônomos	JADE + SUMO via TraCI; caso urbano	Qualidade de tráfego; flexibilidade
Liu <i>et al.</i> (2022)	Atualizar mapas em tempo real	EdgeMap; crowdsourcing + Edge Computing	Acurácia; latência
Chainbi & Hamdi (2022)	SMA descentralizado na borda	Revisão de frameworks multiagente	Avaliação qualitativa
Alekszejenkó & Dobrowiecki (2021)	Validar modelo simplificado	Modelo abstrato + SUMO em rede real	Velocidade média; densidade; vazão
Srivastava & Kumar (2020)	Testar ITS via simulação	SUMO; cenários ITS diversos	Throughput; tempo de viagem
Zhou <i>et al.</i> (2019)	IA na borda para tráfego	Edge Computing; IA; sensores	Latência; precisão de decisões
Biekerwalz & Behrisch (2019)	Priorizar emergências	SUMO; comunicação V2V	Espera de emergência; impacto geral
Azevedo <i>et al.</i> (2016)	Reduzir congestionamento	JADE + SUMO via TraSMAPI; Q-Learning	Trocas de semáforo; espera média

Fonte: Milfort (2025).

como velocidade, aceleração e trajetória. O comportamento destes agentes segue o modelo BDI, onde as crenças (*Beliefs*) representam o estado atual do veículo e do ambiente, os desejos (*Desires*) constituem os objetivos do agente de atravessar a interseção com segurança, e as intenções (*Intentions*) formam os planos de ação para alcançar estes objetivos, como acelerar, desacelerar ou parar quando necessário.

4.3 Variáveis de estado e parâmetros do sistema

As variáveis de estado dos veículos são fundamentais para o funcionamento adequado do sistema e incluem: identificador único (id) alfanumérico para cada veículo; posição (x, y) em coordenadas cartesianas no plano de simulação medidas em metros; velocidade (v) instantânea do veículo em m/s; aceleração (a) como taxa de variação da velocidade em m/s^2 ; direção (θ) representando o ângulo de orientação do veículo em radianos; intenção de rota (τ) indicando a trajetória planejada por meio da interseção; *timestamp* (t) como marca temporal da última atualização de estado em milissegundos; distância até a interseção (d) calculada como distância euclidiana até o centro da interseção em metros; e tempo estimado de chegada (ETA) previsto para alcançar a interseção em segundos. Os parâmetros do sistema são configurados para otimizar o desempenho, incluindo o raio da zona de interseção de 57 metros, intervalo de atualização de estado de 100ms, limiar de segurança temporal de 2 segundos, velocidade máxima permitida de 13.5m/s, desaceleração máxima de emergência de -4.5 m/s^2 , número máximo de tentativas de comunicação fixado em 3, e timeout de comunicação de 200 ms.

4.4 Algoritmo de tomada de decisão

O algoritmo de tomada de decisão implementa um protocolo de negociação baseado em prioridades dinâmicas, calculadas a partir de diversos fatores relevantes para a segurança e eficiência do tráfego. O tempo estimado de chegada à interseção (ETA) é calculado pela divisão da distância pela velocidade atual. O índice de prioridade (PI) é determinado por uma fórmula que considera o inverso do ETA, uma função da intenção de rota e uma função que avalia a eficiência energética da manobra, cada um com pesos configuráveis. A regra de decisão estabelece que se o PI for maior que um limiar predefinido, o veículo mantém ou aumenta a velocidade; caso contrário, reduz a velocidade ou para. Em situações em que dois veículos apresentam PI similares, aplica-se a regra da mão direita como critério de desempate. Este algoritmo é implementado como uma máquina de estados finitos com os estados de

4 MATERIAL E MÉTODOS

A metodologia proposta para o desenvolvimento e avaliação do sistema multiagente de assistência ao condutor em interseções urbanas segue uma abordagem sistemática, fundamentada em princípios de engenharia de software, sistemas multiagentes e simulação de tráfego. Inicia-se com a fundamentação teórica e a arquitetura do sistema (4.1), seguida pela modelagem dos agentes (4.2), definição das variáveis de estado e parâmetros (4.3), e o algoritmo de tomada de decisão (4.4). Em seguida, são descritos os cenários de simulação (4.5), as métricas de avaliação (4.6), e o processo de troca de informações via JADE (4.7). O ambiente de trabalho utilizado é detalhado (4.8), assim como a classe DriverManager (4.9), finalizando com a análise da integração entre os frameworks JADE e SUMO (4.10).

4.1 Fundamentação teórica e arquitetura do sistema

O sistema proposto baseia-se no paradigma de SMA aplicado à gestão de tráfego urbano, seguindo os princípios de comunicação e coordenação entre agentes autônomos estabelecidos por Wooldridge (2009) e as diretrizes de simulação de tráfego de Krajzewicz *et al.* (2012). A arquitetura do sistema integra três componentes principais que trabalham de forma sincronizada: a simulação de tráfego através do SUMO v1.18.0, responsável pela modelagem física do ambiente urbano, dinâmica dos veículos e coleta de dados primários; o sistema multiagente implementado em JADE v4.6.0, que desenvolve o comportamento inteligente dos veículos por meio de agentes BDI (*Belief-Desire-Intention*), permitindo tomada de decisão autônoma; e a interface de comunicação TraCI, que estabelece um protocolo bidirecional entre SUMO e JADE, garantindo sincronização em tempo real das informações trocadas entre os componentes do sistema.

4.2 Modelagem dos agentes

Cada veículo no sistema é modelado como um agente autônomo com características específicas que permitem sua operação eficiente no ambiente simulado. Estes agentes possuem capacidade de percepção, obtendo informações do ambiente como posição, velocidade e distância da interseção; comunicação através do protocolo FIPA-ACL para troca de mensagens entre agentes; deliberação mediante um algoritmo de tomada de decisão baseado para determinar prioridades de passagem; e ação, com capacidade de alterar parâmetros de condução

aproximação, negociação, travessia e emergência, permitindo uma gestão eficiente das diferentes fases da interação do veículo com a interseção (Figura 4.1).

Figura 4.1 - Pseudocódigo do algoritmo de decisão do Agente-Veículo.

```

Comunicação entre JADE e SUMO// Comportamento executado a cada passo da simulação
PROCEDIMENTO TomarDecisao(veículo_atual):
    // 1. Percepção do Ambiente
    distancia_intersecao = calcularDistanciaAteIntersecao(veículo_atual.posicao)

    // 2. Entrada na Zona de Decisão
    SE distancia_intersecao < RAI0_ZONA_DECISAO E não está_negociando:
        está_negociando = VERDADEIRO
    // 3. Comunicação e Coleta de Informações
        ENVIAR_MENSAGEM_QUERY(broadcast, "informar_estado")

    // 4. Recebimento de Respostas e Construção do Cenário
    SE recebeu_novas_mensagens_INFORM:
        outros_veículos = processarMensagens(mensagens_recebidas)
    // 5. Deliberação e Cálculo de Prioridade
        prioridade_veículo_atual = calcularIndicePrioridade(veículo_atual, outros_veículos)

    // 6. Negociação
        ENVIAR_MENSAGEM_PROPOSE(broadcast, prioridade_veículo_atual)

    SE recebeu_propostas_de_outros_veículos:
        SE prioridade_veículo_atual > MAIOR(prioridades_recebidas):
            // 7. Ação: Avançar
            definirAcao("ACELERAR_OU_MANTER_VELOCIDADE")
        SENÃO:
            // 7. Ação: Esperar
            definirAcao("DESACELERAR_OU_PARAR")
FIM_PROCEDIMENTO


```

Fonte: Milfort (2025).

4.5 Cenários de simulação

Para garantir a robustez do sistema, foram implementados e avaliados cenários distintos, representando duas condições de tráfego e desafios específicos para o gerenciamento de interseções. Esses cenários foram projetados para testar a capacidade de cada sistema, composto pelos SUMO e JADE com agentes *DriverManager* e *CarAgent*, em minimizar colisões e otimizar o fluxo de veículos. A interseção simulada, ilustrada na Figura 4.2, é uma interseção não regulamentada com quatro direções principais (*Up*, *Down*, *Left*, *Right*), uma zona de controle ao redor do cruzamento e uma área de fusão (zona de decisão) no centro, onde os veículos convergem sem prioridade predefinida.

Figura 4.2 - Interseção não regulamentada.



Fonte: Milfort (2025).

A Figura 4.2 ilustra a interseção não regulamentada, destacando as quatro direções de tráfego e a área de fusão central. A zona de controle, representada por um retângulo tracejado, abrange toda a área ao redor da interseção, onde os agentes *CarAgent* detectam a entrada na região crítica e enviam mensagens ao *DriverManager*. A área de fusão, localizada no centro, é o ponto de convergência dos fluxos, onde a ausência de prioridade pode resultar em conflitos, especialmente em cenários de alta densidade. No SUMO, essa configuração foi implementada sem regras de tráfego predefinidas, permitindo que a lógica interna dos agentes determinasse a travessia. Essa abordagem possibilita analisar o impacto da falta de controle centralizado, identificando padrões de congestionamento, conflitos entre veículos e o tempo médio de travessia, com foco em minimizar colisões.

A escolha de uma interseção não regulamentada (sem semáforos ou placas de 'PARE') é proposital e estratégica. Este tipo de cenário representa uma das condições mais desafiadoras para a segurança viária, onde a ausência de regras explícitas de prioridade maximiza o risco de conflitos. Portanto, é o ambiente ideal para testar a eficácia de um sistema cooperativo, pois qualquer melhoria na segurança será diretamente atribuível à inteligência e à coordenação dos agentes, e não a controles de tráfego preexistentes. O fluxo de tráfego foi configurado para garantir a ocorrência de interações e potenciais colisões, validando assim a capacidade do sistema em cenários de conflito iminente.

4.6 Métricas de avaliação

A avaliação de desempenho do sistema proposto é importante em um conjunto de métricas quantitativas, estabelecidas e validadas na literatura científica sobre simulação de tráfego e sistemas veiculares cooperativos. A seleção de métricas visa quantificar a eficácia do sistema em duas dimensões principais: eficiência do fluxo de tráfego e segurança viária. Para tal, a análise abrange métricas de eficiência, como o Número de Veículos Concluintes (*Throughput*), o Tempo Médio de Viagem (*Average Travel Time*), a Velocidade Média (*Average Speed*) e o Tempo Médio de Espera (*Average Waiting Time*). A dimensão da segurança é avaliada primordialmente pela Contagem de Colisões (*Collision Count*). Adicionalmente, a viabilidade e a escalabilidade da abordagem são examinados por meio da Carga Comunicacional ACL (*ACL Communication Load*), que mensura a sobrecarga de comunicação imposta pelo protocolo de coordenação. Cada uma dessas métricas é detalhada nas subseções seguintes, apresentando sua definição conceitual, formulação matemática e a justificativa para sua aplicação neste estudo.

4.6.1 Número de Veículos Concluintes (*Throughput*)

O *throughput*, ou vazão, é definido como o número total de veículos que concluem com sucesso seus respectivos percursos dentro do intervalo de tempo da simulação. É uma medida primária da eficiência operacional da infraestrutura. O cálculo é expresso por:

$$\text{Throughput} = \sum_{i=1}^n I\{V_i \text{concluiu trajeto}\} \quad (4.1)$$

onde: n : número total de veículos inseridos no cenário da simulação.

V_i , o veículo de índice i

$I\{\cdot\}$ função indicadora, que retorna:

- 1, se o veículo V_i concluiu seu trajeto
- 0, caso contrário

Um throughput reduzido, mesmo na ausência de colisões, indica que a estratégia de coordenação pode estar impondo atrasos excessivos, comprometendo a eficiência global do tráfego (Treiber & Kesting, 2013).

4.6.2 Contagem de Colisões (Collision Count)

Esta métrica quantifica o número total de eventos de colisão registrados durante a simulação. A segurança é o objetivo primário do sistema cooperativo, tornando esta a métrica de avaliação mais crítica. A sua formulação é:

$$C = \sum_{i=1}^E I\{\text{evento } i \text{ de colisão}\} \quad (4.2)$$

onde:

C : número total de colisões observadas na simulação.

E : número total de eventos de tráfego detectados pelo simulador.

$I\{\text{evento } i \text{ uma colisão}\}$, que retorna:

- 1, se o evento i corresponde a uma colisão
- 0, caso contrário

A métrica de colisões permite avaliar diretamente o nível de segurança proporcionado pelo sistema de coordenação veicular. A meta de qualquer sistema de assistência veicular é a minimização, idealmente a eliminação, de colisões. Trabalhos de referência, como os de Dresner & Stone (2008), consideram inaceitáveis taxas de colisão mesmo que baixas em cenários controlados, reforçando a importância de se buscar um resultado nulo para esta métrica.

4.6.3 Tempo Médio de Viagem (Average Travel Time)

O tempo médio de viagem mensura a duração média, em segundos, que um veículo leva para percorrer sua via desde a entrada até a saída da rede simulada. É um indicador fundamental da fluidez do tráfego e do nível de serviço da via.

$$T_t = \frac{1}{V} \sum_{i=1}^V t_i^{\text{viagem}} \quad (4.3)$$

onde:

T_t : tempo médio de viagem observado na simulação.

V : número total de veículos que completaram seus trajetos.

t_i^{viagem} : tempo individual de viagem do veículo i , ou seja, o intervalo entre sua entrada e saída do sistema.

A métrica de tempo médio de viagem é utilizada para avaliar o desempenho dinâmico do sistema de tráfego sob diferentes estratégias de coordenação. Elevações significativas nesse indicador podem refletir a ocorrência de congestionamentos, sugerindo que a estratégia de gerenciamento adotada está impactando negativamente a fluidez do tráfego.

4.6.4 Velocidade Média (Average Speed)

A velocidade média dos veículos, expressa em m/s, oferece uma perspectiva complementar sobre a fluidez do tráfego. É calculada pela média das velocidades individuais ao longo do percurso.

$$As = \frac{1}{\Delta t \times L} \int_{T_{i,0}}^{T_{i,f}} v_i(t) dt \quad (4.4)$$

onde:

As : velocidade média espacial do veículo i .

Δt : intervalo de tempo considerado na simulação.

L : distância total percorrida pelo veículo i .

$v_i(t)$: função que representa a velocidade instantânea do veículo i ao longo do tempo.

$T_{i,0}$ e $T_{i,f}$: instantes de início e fim do trajeto do veículo i .

Este cálculo, fundamentado em modelos de fluxo de tráfego (cf. Krajzewicz *et al.*, 2012), permite avaliar o impacto da coordenação na dinâmica de deslocamento dos veículos. Valores mais elevados de velocidade média espacial indicam maior fluidez no tráfego.

4.6.5 Tempo Médio de Espera (Average Waiting Time)

O tempo médio de espera quantifica o período em que os veículos permanecem imobilizados (velocidade nula), seja em filas de aproximação ou aguardando autorização para cruzar a interseção.

$$Wt = \frac{1}{V} \sum_{i=1}^V W_i \quad (4.5)$$

Onde:

Wt : tempo médio de espera por veículo.

V : número total de veículos que concluíram o trajeto.

W_i : tempo de espera acumulado do veículo i , ou seja, o tempo em que o veículo permaneceu parado ou com velocidade significativamente reduzida devido à coordenação do tráfego.

Esta métrica é particularmente relevante para avaliar o custo, em termos de atraso, da estratégia de coordenação preventiva adotada pelo sistema para garantir a segurança.

4.6.6 Carga Comunicacional ACL (ACL Communication Load)

Esta métrica avalia a sobrecarga de comunicação (*overhead*) imposta pelo protocolo de coordenação, medindo a taxa de mensagens trocadas por veículo por segundo.

$$R_{ACL} = \frac{1}{V \times T_{sim}} \sum_{i=1}^V M_i \quad (4.6)$$

Onde:

R_{ACL} : taxa média de mensagens ACL trocadas por segundo por veículo.

V : número total de veículos que concluíram o trajeto.

T_{sim} : duração total da simulação (em segundos).

M_i número total de mensagens ACL trocadas pelo veículo i durante a simulação.

O monitoramento desta métrica é importante para analisar a escalabilidade do sistema, pois uma carga comunicacional excessiva pode saturar a rede e comprometer a viabilidade da solução em cenários de alta densidade veicular.

O SUMO reporta cada colisão via o arquivo de saída de eventos, enquanto o framework JADE centraliza a informação via mensagens de estado, cabendo, então, cruzar ambos para contabilização. O principal objetivo do sistema multiagente cooperativo é a redução absoluta do número de colisões em interseções não semaforizadas. Em trabalhos correlatos, doses de mais de três colisões por hora já são consideradas inaceitáveis (Dresner; Stone, 2008; Zheng; Liu, 2018). Portanto, mensurar o número absoluto de colisões permite avaliar objetivamente o ganho de segurança.

4.7 Troca de informações via JADE

Na segunda etapa que integra o sistema multiagente na simulação, uma zona de interseção é definida a uma distância com raio pré-definido ao redor da interseção. Quando um veículo entra na área pré-definida, seu estado é transmitido via *QUERY* para todos os outros agentes presentes nas proximidades da interseção. Em resposta, cada agente receptor fornece as informações solicitadas enviando uma mensagem *INFORM* para o veículo emissor. Este, por sua vez, utiliza esses dados para decidir se deve parar (PARE) ou atravessar a interseção.


A tomada de decisão baseia-se em vários fatores, incluindo a velocidade e a distância do veículo, bem como sua trajetória, permitindo determinar o tempo máximo necessário para atravessar a interseção. Um aspecto importante nesse processo é o intervalo de tempo entre o envio das mensagens e o recebimento das respostas dos outros agentes, pois o estado dos veículos pode mudar entre essas duas etapas. Por isso, a interface TraCI (*Traffic Control Interface*) é fundamental ao sincronizar os dados, garantindo que a decisão se baseie no estado mais atualizado de todos os veículos (Jing; Huang; Chen, 2017). Com base nessa análise sincronizada, o veículo com maior prioridade recebe autorização para avançar, enquanto os demais aguardam em fila. Este mecanismo de priorização otimiza o gerenciamento do tráfego e minimiza os riscos de colisão na interseção.

4.8 Ambiente de trabalho

A simulação foi realizada em um computador HP com a seguinte configuração: Sistema operacional com *Windows 10 Home* 64-bits; memória RAM: 8 GB; Processador: *AMD Ryzen 5 2500U* with *Radeon Vega Mobile Gfx* 2.00 GHz.

O *IntelliJ IDEA*, projetado pela *JetBrains*, é um ambiente de desenvolvimento integrado (ou IDE) com reputação de desenvolvimento eficiente em Java (Figura 4.3), bem como em outras linguagens modernas, como *Kotlin*, *Scala* e *Python*. Ele oferece autocompletar de código inteligente, análise estática e integração perfeita com ferramentas como *Git* e *Docker*. Esses recursos fazem dessa ferramenta um item obrigatório para os profissionais de desenvolvimento (IntelliJ, 2022).

Figura 4.3 - InterliJ IDEA.




Fonte: Milfort (2025).

JAVA é uma linguagem de programação orientada a objetos desenvolvida pela Sun Microsystems. Ela pode ser usada para criar software compatível com muitos sistemas operacionais (Windows, Linux, Macintosh). O Java também pode ser usado para desenvolver programas para *smartphones*. Por fim, essa linguagem pode ser usada na Internet para pequenos aplicativos integrados à página da Web (*applet*) ou como linguagem de servidor (*jsp*). O JADE é uma plataforma de programação multiagente implementada em Java. Os agentes executados no JADE se comunicam por meio da Linguagem de Comunicação de Agente (ACL). Essa linguagem já foi apresentada em capítulos anteriores.

4.8.1 Descrição da interface gráfica do sistema

A interface gráfica do sistema consiste em três botões principais, cada um representado por um logotipo. O primeiro logotipo é SUMO, o segundo é JADE e o terceiro é o botão STOP (Figura 4.4). SUMO: inicia uma simulação pura no ambiente SUMO; JADE: inicia uma simulação acoplada SUMO/JADE; STOP: interrompe o sistema inteiro imediatamente.

Figura 4.4 - Interface gráfica do sistema.



Fonte: Milfort (2025).

4.8.2 Criação de cenários com o SUMO

Para criar a simulação no SUMO (Simulation of Urban MObility), foram gerados arquivos .xml por meio de uma interface gráfica Java, sendo os principais o net.xml e o route.xml; o primeiro descreve a rede viária, incluindo ruas, cruzamentos, faixas e limites de velocidade, funcionando como o mapa da área simulada, enquanto o segundo define as rotas dos veículos, especificando origem, destino, horários de partida e tipos de veículos envolvidos. Esses arquivos são importantes para que o SUMO possa construir e executar o cenário de tráfego.

O arquivo .net.xml é um arquivo no qual a infraestrutura rodoviária é definida, incluindo estradas, cruzamentos e semáforos. Geralmente é gerado a partir de um mapa real ou construído manualmente usando o NETCONVERT (Figura 4.5).

Figura 4.5 - Arquivo Net.xml.

```

<net version="1.20" junctionCornerDetail="5" limitTurnSpeed="5.50" xmlns:xsi="http://www.w3.org/2001/XMLSchema-instance" xsi:noNamesp
    <lane id="E2J2_0" index="0" speed="13.89" length="92.80" shape="22.80,51.60 -70.00,51.60"/>
  </edge>
  <edge id="N2J" from="N" to="J" priority="-1">
    <lane id="N2J_0" index="0" speed="13.89" length="92.80" shape="28.40,150.00 28.40,57.20"/>
  </edge>
  <edge id="N2J2" from="J" to="N" priority="-1">
    <lane id="N2J2_0" index="0" speed="13.89" length="92.80" shape="31.60,57.20 31.60,150.00"/>
  </edge>
  <edge id="S2J1" from="J6" to="J" priority="-1">
    <lane id="S2J1_0" index="0" speed="13.89" length="92.80" shape="31.60,-50.00 31.60,42.80"/>
  </edge>
  <edge id="S2J2" from="J" to="J6" priority="-1">
    <lane id="S2J2_0" index="0" speed="13.89" length="92.80" shape="28.40,42.80 28.40,-50.00"/>
  </edge>
  <edge id="W2J1" from="W" to="J" priority="-1">
    <lane id="W2J1_0" index="0" speed="13.89" length="92.80" shape="130.00,51.60 37.20,51.60"/>
  </edge>
  <edge id="W2J2" from="J" to="W" priority="-1">
    <lane id="W2J2_0" index="0" speed="13.89" length="92.80" shape="37.20,48.40 130.00,48.40"/>
  </edge>

  <junction id="E" type="dead_end" x="-70.00" y="50.00" incLanes="E2J2_0" intLanes="" shape="-70.00,50.00 -70.00,53.20 -70.00,50.00"/>
  <junction id="J" type="unregulated" x="30.00" y="50.00" incLanes="N2J_0 W2J1_0 S2J1_0 E2J1_0" intLanes=":J_0_0 :J_1_0 :J_2_0 :J_3_0 :J_4_0 :J_5_0 :
  <junction id="S" type="unregulated" x="30.00" y="-50.00" incLanes="S2J2_0" intLanes="" shape="30.00,-50.00 26.80,-50.00 30.00,-50.00"/>
  <junction id="N" type="dead_end" x="30.00" y="150.00" incLanes="N2J2_0" intLanes="" shape="30.00,150.00 33.20,150.00 30.00,150.00"/>
  <junction id="W" type="dead_end" x="130.00" y="50.00" incLanes="W2J2_0" intLanes="" shape="130.00,50.00 130.00,46.80 130.00,50.00"/>

  <connection from="E2J1" to="S2J2" fromLane="0" toLane="0" via=":J_9_0" dir="r" state="M"/>
  <connection from="E2J1" to="W2J2" fromLane="0" toLane="0" via=":J_10_0" dir="s" state="M"/>
  <connection from="E2J1" to="N2J2" fromLane="0" toLane="0" via=":J_11_0" dir="l" state="M"/>
  <connection from="N2J" to="E2J2" fromLane="0" toLane="0" via=":J_0_0" dir="r" state="M"/>

```

Fonte: Milfort (2025)

O arquivo rou.xml define o tráfego simulado no SUMO, especificando os veículos, suas características, suas rotas e seus horários de partida. Esse arquivo contém: Tipos de veículos (<vType>) com suas propriedades (aceleração, velocidade máxima etc.). Define cada veículo com um identificador exclusivo que especifica a partida e sua rota. Rotas (<route>) que indicam as rotas tomadas por cada veículo antes de deixar a simulação (Figura 4.6).

Figura 4.6 - Arquivo rou.xml.

```

<routes xmlns:xsi="http://www.w3.org/2001/XMLSchema-instance"
  xsi:noNamespaceSchemaLocation="http://sumo.dlr.de/xsd/routes_file.xsd">
  <!-- ☒ Vehicle Type Definition -->
  <vType id="car" accel="3.0" decel="2.0" length="4.5" maxSpeed="13.9" minGap="2.0" tau="1.0" sigma="0.5"/>
  <!-- Routes -->
  <route id="R1" edges="E2J1 W2j2"/>
  <route id="R2" edges="N2J S2J2"/>
  <route id="R3" edges="S2J1 W2j2"/>
  <route id="R4" edges="E2J1 S2J2"/>
  <route id="R5" edges="W2J1 E2J2"/>
  <route id="R6" edges="S2J1 N2J2"/>
  <route id="R7" edges="W2J1 S2J2"/>
  <route id="R8" edges="N2J W2j2"/>
  <route id="R9" edges="S2J1 E2J2"/>
  <route id="R10" edges="E2J1 N2J2"/>
  <route id="R11" edges="N2J E2J2"/>
  <route id="R12" edges="W2J1 N2J2"/>

  <!-- Vehicles -->
  <vehicle id="veh1" type="car" route="R1" depart="0.0"/>
  <vehicle id="veh2" type="car" route="R2" depart="0.5"/>
  <vehicle id="veh3" type="car" route="R7" depart="1.0"/>
  <vehicle id="veh4" type="car" route="R9" depart="1.0"/>
  <vehicle id="veh5" type="car" route="R4" depart="1.5"/>
  <vehicle id="veh6" type="car" route="R6" depart="2.5"/>
  <vehicle id="veh7" type="car" route="R7" depart="3.0"/>
  <vehicle id="veh8" type="car" route="R8" depart="3.5"/>
  <vehicle id="veh9" type="car" route="R11" depart="4.5"/>
  <vehicle id="veh10" type="car" route="R10" depart="5.0"/>
  <vehicle id="veh11" type="car" route="R9" depart="5.0"/>
  <vehicle id="veh12" type="car" route="R12" depart="6.0"/>

```

Fonte: Milfort (2025)

O arquivo "sumo.cfg" é o ponto central para configurar e executar a simulação do SUMO, definindo os arquivos de entrada (rede e rotas), a duração da simulação e a frequência das etapas de cálculo. Ele também permite que os resultados sejam coletados de vários arquivos de saída que configuram uma simulação do SUMO para analisar vários aspectos do tráfego, como colisões, tempos de viagem, filas, emissões de poluentes e estatísticas gerais etc (Figura 4.7).

Figura 4.7 - Arquivo configuração.

```

<?xml version="1.0" encoding="UTF-8"?>

<!-- generated on 2025-04-29 01:07:53 by Eclipse SUMO sumo Version 1.21.0 -->

<sumoConfiguration xmlns:xsi="http://www.w3.org/2001/XMLSchema-instance"
    xsi:noNamespaceSchemaLocation="http://sumo.dlr.de/xsd/sumoConfiguration.xsd">

    <input>
        <net-file value="intersectionNet11.net.xml"/>
        <route-files value="intersection.rou.xml"/>
        <additional-files value="intersection.add.xml"/>
    </input>
    <processing>
        <!-- Use "warn" instead of "teleport" or "remove" -->
        <collision.action value="warn"/>
        <!-- Vehicles continue after collision with minimal disruption -->
        <collision.stoptime value="0.1"/>
        <collision.check-junctions value="true"/>
        <!-- Keep both vehicles in simulation -->
        <collision.mingap-factor value="0"/>
    </processing>
    <time>
        <begin value="0"/>
        <end value="-1"/> <!-- ✅ Stop when no more vehicles -->
        <step-length value="0.1"/>
    </time>
</sumoConfiguration>

```

Fonte: Milfort (2025).

4.9 Descrição da classe *DriverManager*


A classe *DriverManager* é um componente central em sistemas multiagentes desenvolvidos com o framework JADE, projetada para gerenciar o tráfego em simulações de mobilidade urbana utilizando a ferramenta SUMO, por meio da interface TraCI. Essa classe implementa um agente JADE responsável por coordenar o fluxo de veículos em cruzamentos, tomando decisões baseadas em informações em tempo real e comunicando-se com outros agentes no sistema.

A *DriverManager* atua como um agente autônomo que executa diversas funções integradas. Inicialmente, o agente estabelece uma conexão com o SUMO por meio do objeto *SumoTraciConnection*, recebido como argumento na inicialização. Essa conexão é fundamental para interagir com a simulação e obter informações como a lista de veículos ativos. Em seguida, o agente se registra no *Directory Facilitator* (DF) do JADE, anunciando sua disponibilidade para prestar serviços de gerenciamento de tráfego, identificados pelo tipo *traffic management*. Após o registro, um comportamento cíclico (*CyclicBehaviour*) é ativado para monitorar

mensagens ACL do tipo *INFORM*, processando solicitações ou atualizações recebidas de outros agentes, como veículos simulados.

Além disso, o agente ativa dois comportamentos periódicos (*TickerBehaviour*). Um deles executa a cada 500 milissegundos e é responsável por verificar se há veículos na fila de espera e se o cruzamento está livre. Caso ambas as condições sejam satisfeitas, o agente executa a lógica de decisão que autoriza a passagem dos veículos. O outro comportamento periódico, com intervalo de 200 milissegundos, monitora continuamente a presença de veículos na simulação. Quando a lista de veículos está vazia, o agente se desregistra do DF e encerra sua execução. O processo de funcionamento do agente é representado na figura (4.8) a seguir:

Figura 4.8 - Fluxograma da classe *DriverManager*.



Fonte: Milfort (2025).

A classe *DriverManager* emprega três tipos de comportamento distintos, todos derivados da classe *Behaviour* do JADE. O *CyclicBehaviour* é executado continuamente, responsável por receber e processar mensagens ACL. Este comportamento é importante para a comunicação entre agentes, permitindo que o *DriverManager* reaja dinamicamente a eventos como solicitações de travessia de cruzamentos por parte de veículos.

O *TickerBehaviour*, com intervalo de 500 milissegundos, implementa a lógica de controle de tráfego, analisando periodicamente a fila de veículos e o estado do cruzamento. Essa lógica simula a tomada de decisão, comparável ao funcionamento de um semáforo inteligente. Por sua vez o *TickerBehaviour*, com intervalo de 200 milissegundos, monitora a

simulação para detectar o término da presença de veículos ativos. Esse comportamento garante a finalização adequada do agente ao final da simulação, promovendo liberação eficiente dos recursos do sistema.

A integração com o SUMO ocorre por meio da interface *SumoTraciConnection*, que permite ao agente consultar o estado atual da simulação, como a lista de veículos, e executar comandos como autorizar a passagem de veículos. Essa conexão é fundamental para o funcionamento do *DriverManager*, pois fornece as informações necessárias para a tomada de decisão.

4.10 Análise do funcionamento do *framework* JADE-SUMO

A integração entre o *framework* JADE e o simulador SUMO permite a simulação de cenários cooperativos de assistência ao condutor em interseções urbanas. Por meio da troca de mensagens ACL (*Agent Communication Language*), os agentes simulados podem atuar de forma autônoma e coordenada, reproduzindo comportamentos de controle viário.

Figura 4.9 - Troca de mensagens (recebido).

ACL Message

ACLMessage Envelope

Sender: [View](#) ger@192.168.15.10:1099/JADE

Receivers: veh12@192.168.15.10:1099/JADE

Reply-to:

Communicative act: request

Content:

Decision: WAIT
NameVehicule: veh12
Speed: 0.00

Language:

Encoding:

Ontology:

Protocol: Null

Conversation-id:

In-reply-to:

Reply-with:

Reply-by: [View](#)

User Properties:

OK

Fonte: Milfort (2025).

A Figura 4.9 acima apresenta uma mensagem ACL do tipo *request* enviada pelo agente gerente (Gerente de Tráfego) para o agente veh12, com a decisão "WAIT" e velocidade atribuída de 0.00. Essa mensagem ilustra o mecanismo de controle coordenado, onde o *DriverManager* atua como entidade decisória responsável por evitar conflitos em cruzamentos. A decisão de aguardar está relacionada ao estado da interseção, que pode estar ocupada por outro veículo, garantindo assim um comportamento seguro e cooperativo.

Figura 4.10 - Troca de mensagens (enviado).

The screenshot shows a window titled "ACL Message" with a close button (X) in the top right corner. Inside the window, there are two tabs: "ACLMessage" (selected) and "Envelope". The "ACLMessage" tab contains the following fields:

- Sender:** A text field containing "veh9@192.168.15.10:1099/JADE" with a "View" button to its left.
- Receivers:** A text field containing "DriverManager@192.168.15.10:1099" with a scrollbar to its right.
- Reply-to:** An empty text field.
- Communicative act:** A dropdown menu with "inform" selected.
- Content:** A text area containing the following text:


```
VehicleId: veh9
PositionX: 28.40
PositionY: 67.13
Distance: 17.20
```

 with a scrollbar to its right.
- Language:** An empty text field.
- Encoding:** An empty text field.
- Ontology:** An empty text field.
- Protocol:** A dropdown menu with "Null" selected.
- Conversation-id:** An empty text field.
- In-reply-to:** An empty text field.
- Reply-with:** An empty text field.
- Reply-by:** A text field containing an empty space with a "View" button to its left.
- User Properties:** An empty text field.


At the bottom of the window is an "OK" button.

Fonte: Milfort (2025).

A Figura 4.10 apresenta o envio de uma mensagem do tipo *inform* do veículo veh9 ao *DriverManager*, contendo informações como posição ($X = 28.40$, $Y = 67.13$) e distância até a interseção. Esses dados são essenciais para a lógica de decisão descentralizada, em que os veículos reportam continuamente seu estado e localização para que o gerente possa avaliar o momento seguro de liberação.

A Figura 4.11, gerada pelo *Sniffer Agent* do JADE, representa visualmente o tráfego de mensagens entre os agentes. A sequência mostra o intercâmbio contínuo de mensagens *INFORM* e *REQUEST* entre o *DriverManager* e os veículos (veh1 a veh12), demonstrando a natureza cooperativa da arquitetura proposta. A presença de múltiplas mensagens por segundo comprova a reatividade do sistema e sua capacidade de adaptação, permitindo que decisões sejam tomadas com base no contexto atual da simulação.

Figura 4.11 - Troca de mensagens entre os agentes.



Fonte: Milfort (2025).

5 RESULTADOS E DISCUSSÃO

A tomada de decisão nesse trabalho baseou-se em vários fatores, incluindo análises de velocidade e a distância do veículo, bem como sua trajetória, permitindo determinar o tempo máximo necessário para atravessar a interseção. Um aspecto importante nesse processo é o intervalo de tempo entre o envio das mensagens e o recebimento das respostas dos outros agentes, pois o estado dos veículos pode mudar entre essas duas etapas. Nesse caso, nota-se a importância do TraCI na sincronização dos estados dos veículos, a fim de garantir que a tomada de decisão seja baseada em dados atualizados. Após a análise desses parâmetros, o veículo que tiver prioridade será autorizado a entrar na interseção, enquanto os demais permanecerão em fila de espera aguardando a sua vez de atravessar. Esse mecanismo permite otimizar a gestão do tráfego e minimizar os riscos de colisão.

5.1 Análise comparativa: ocorrência de acidentes e eficiência operacional

A comparação entre os dois cenários simulados, um utilizando apenas o simulador SUMO, e outro com a integração entre SUMO e o framework multiagente JADE, revela evidências significativas sobre os impactos da coordenação inteligente no gerenciamento seguro de interseções urbanas.

5.1.1 SUMO

No cenário com SUMO operando sem a intervenção do controle de interseção proposto, (Figura 5.1; Tabela 5.1), os 12 veículos carregados no framework concluíram integralmente seus percursos, apresentando um rendimento (12/12) e tempo médio de viagem de 18,68s, sem registro de espera (0s). Essas métricas alinham-se ao esperado para uma rede de 0,74km e tráfego urbano leve, conforme descrito em Krajzewicz *et al.* (2012). No entanto, foi registrada uma colisão durante a simulação, o que evidencia limitações na lógica interna de controle de interseções do SUMO: embora seu modelo de seguir-o-líder (car-following) e suas regras de prioridade de via implementem um comportamento realista em condições de tráfego livre, eles não contemplam mecanismos de previsão de conflitos ou de coordenação preemptiva entre múltiplos veículos convergentes (Treiber; Kesting, 2013; Zheng e Liu, 2018)


Tabela 5. 1 - Indicadores de desempenho (SUMO)

Métrica	Valor	Observação
Veículos carregados	12	Todos completaram seus trajetos
Colisões	1	Indica necessidade de otimização (SUMO)
Tempo médio de viagem (s)	18,68	Tempo consistente com distâncias simuladas
Velocidade média (m/s)	10,37	Compatível com tráfego urbano
Tempo médio de espera (s)	0,00	Fluidez total, sem paradas
Comunicação ACL	Ativa e coordenada	Fluxo contínuo entre veículos e gerenciado

Fonte: Milfort (2025).

A ocorrência de colisão, apesar da fluidez geral, já havia sido documentada em estudos de interseções não sinalizadas, nos quais sistemas baseados apenas em regras estáticas de prioridade podem falhar em cenários de alta densidade ou com diferenças de aceleração entre veículos (Dresner; Stone, 2008; Abdoos *et al.*, 2013). No experimento apresentado, a colisão sugere que, sem comunicação cooperativa, o algoritmo padrão do SUMO não antecipa a convergência de trajetórias.

Figura 5.1 - Relatório de SUMO com uma colisão.



Name	Value	Dynamic
loaded vehicles [#]	12	
insertion-backlogged vehicles [#]	0	
departed vehicles [#]	12	
running vehicles [#]	0	
arrived vehicles [#]	12	
discarded vehicles [#]	0	
collisions [#]	1	
teleports [#]	0	
halting [#]	0	
stopped [#]	0	
avg. speed [m/s]	-1.00	
avg. relative speed	-1.00	
end time [s]	-1	
begin time [s]	0	
step duration [ms]	1	
FPS	1000.00	
simulation duration [ms]	1	
idle duration [ms]	0	
duration factor	100.00	
updates per second	0.00	
avg. updates per second	74.00	
avg. trip length [m]	193.58	
avg. trip duration [s]	19.51	
avg. trip waiting time [s]	0.02	
avg. trip time loss [s]	4.26	
avg. trip depart delay [s]	0.32	
avg. trip speed [m/s]	9.92	
nodes [#]	5	
edges [#]	8	
total edge length [km]	0.74	
total lane length [km]	0.74	
network version	1.20	


Fonte: Milfort (2025).

5.1.2 Análise do mapa de calor da densidade de colisão

O gráfico do mapa de calor da densidade de colisões (*Heat Map of Collision Density*) foi produzido por meio de uma estimativa sobre os pontos de impacto extraídos área de colisão, abordagem para identificar “hotspots” (Qiu; Nixon, 2008; Huang; Wang, 2010). Na Figura 5.2, o gradiente de cores, do vermelho intenso (densidade máxima) ao salmão suave, reflete a

concentração espacial das colisões em duas zonas claramente definidas: Zona A em torno de (28m, 50m), alinhada à aproximação de veículos pela via N2J2_0; Zona B em torno de (32m, 54m), correspondente à zona de saída da interseção, onde o fluxo de veh12 cruza o de veh10.

Figura 5.2 - Relatório de SUMO com uma colisão.



Fonte: Milfort (2025).

A sobreposição parcial entre essas duas zonas sugere que um mesmo par de trajetórias gera múltiplos pontos de risco conforme os veículos adentram e saem da interseção, fenômeno descrito em modelagens de fluxos conflitantes sem controle semaforico (Treiber; Kesting, 2013). Em cenários reais, tais arranjos espaciais de colisão indicam áreas de “ponto cego” ou de visibilidade reduzida, e já foram associados a falhas de detecção de prioridade ou latências em V2V (Zheng; Liu, 2018). Esses resultados indicam a necessidade de ajustar ou otimizar o algoritmo para reduzir a sobreposição de trajetórias de veículos.


5.1.3 Análise da aproximação de veículos durante a colisão

A Figura 5.3 apresenta a evolução longitudinal de dois veículos (veh10 e veh12) na pista N2J2_0, com colisão registrada em $t \approx 18,3s$ e posição $x \approx 0,15m$ (origem da pista). Ambos

partem de $x_0 \approx 25\text{--}27\text{m}$ e reduzem progressivamente sua distância ao longo de 15-18s, indicando desacelerações sucessivas. Diferentemente do descrito anteriormente, não há “aceleração ou mudança de trajetória” para se alcançar $x = 0\text{m}$, mas sim uma sequência de frenagens preventivas que falham em evitar o impacto final.

Esse comportamento, em que veículos convergem sem coordenar suas ações em interseções não sinalizadas, já foi observado em simulações de tráfego urbano distribuído (Zheng; Liu, 2018). Nesses estudos, a ausência de um mecanismo de controle centralizado ou de protocolos de V2V resulta em distâncias mínimas não respeitadas mesmo diante de desacelerações, fato consistente com a pequena variação de velocidades em torno de 2-8m/s no instante do choque (veh12 reduz para 1,15m/s; veh10 a $\approx 7,9\text{m/s}$). De acordo com os achados de Treiber e Kesting (2013), em modelos de fluxo veicular, no SUMO nativo, baseados em comportamentos adaptativos, esse tipo de colisão decorre de um tempo de reação insuficiente combinado com gaps mínimos configurados a zero (*collision.mingap-factor* = 0).

Figura 5.3 - Encontro de veículos durante a colisão.




Fonte: Milfort (2025).

5.2 JADE

No segundo cenário, como a Figura 5.4 mostra, em que o JADE atua como sistema de controle deliberativo, registrou-se zero colisões, um indicativo claro da eficácia da coordenação interagentes. Em contrapartida, o tempo médio de viagem aumentou de 18,68s para 20,05s (+7,3 %) e o tempo médio de espera passou de 0s para 0,18s. Esses acréscimos são compatíveis

com uma estratégia preemptiva de prevenção de conflitos, em que o agente *DriverManager* injeta comandos ACL “WAIT” sempre que identifica risco de colisão, baseando-se em mensagens “INFORM” enviadas pelos veículos contendo sua posição e distância até a interseção.

Figura 5.4 - Relatório de SUMO sem colisão.




Name	Value	Dynamic
loaded vehicles [#]	12	
insertion-backlogged vehicles [#]	0	
departed vehicles [#]	12	
running vehicles [#]	0	
arrived vehicles [#]	12	
discarded vehicles [#]	0	
collisions [#]	0	
teleports [#]	0	
halting [#]	0	
stopped [#]	0	
avg. speed [m/s]	-1.00	
avg. relative speed	-1.00	
end time [s]	-1	
begin time [s]	0	
avg. trip length [m]	193.58	
avg. trip duration [s]	20.05	
avg. trip waiting time [s]	0.18	
avg. trip time loss [s]	4.79	
avg. trip depart delay [s]	0.32	
avg. trip speed [m/s]	9.65	
nodes [#]	5	
edges [#]	8	
total edge length [km]	0.74	
total lane length [km]	0.74	
network version	1.20	

Fonte: Milfort (2025).

Esses resultados estão em consonância com as evidências apresentadas por Dresner e Stone (2008) e Smith et al. (2020), os quais demonstraram que a utilização de sistemas de coordenação em interseções não semaforizadas pode eliminar completamente as colisões, mantendo o atraso médio inferior a 10%. A visualização do fluxo de mensagens (Figura 5.4) confirma uma taxa de troca adequada (ordem de dezenas de mensagens por segundo por veículo), dentro dos requisitos de latência (< 100 ms) para V2V mostrados por Huang e Wang (2010). Em termos práticos, a pequena penalização de desempenho (um acréscimo de apenas

1,37s no travel time e 0,1s de espera média), é um custo aceitável frente ao ganho de segurança. Estudos de Zheng e Liu (2018) mostram que sistemas de reservas temporais cooperativas podem zerar colisões sem aumentar o tempo de viagem em mais de 15%.

Figura 5.5 - Tempo de espera por veículos.



Fonte: Milfort (2025).

Esse pequeno incremento no tempo de espera é resultado da ação do agente *DriverManager*, que decide quando um veículo deve aguardar, enviando mensagens ACL do tipo request com a instrução "WAIT" (conforme Figura 5.5), sempre que a interseção está ocupada ou em risco de conflito. O controle é realizado com base em mensagens *inform* enviadas pelos veículos (Figura 5.4), contendo sua posição e distância até a interseção, permitindo uma avaliação contextual em tempo real.


5.3 Comparação

Na Figura 5.6, observa-se que, com o controle deliberativo via JADE-SUMO, o número de colisões é zero, enquanto o SUMO nativo registrou uma colisão (Figura 5.6). A eliminação completa de colisões (0 versus 1 no SUMO nativo) demonstra claramente o ganho de segurança

alcançado pela coordenação entre agentes. Apesar disso, observou-se um pequeno acréscimo no tempo médio de viagem, de 18,68s para 20,05s (+7,3%), e um tempo médio de espera introduzido de 0,18s por veículo, em comparação aos 0s do cenário “com colisão”. A velocidade média reduziu-se de 10,37m/s para 9,65m/s (-6,9%), enquanto a perda de tempo subiu de 3,98s para 4,79s. Esses valores permanecem dentro de margens aceitáveis para sistemas cooperativos de tráfego, pois, segundo Dresner e Stone (2008), um aumento de até 10% no *travel time* é tolerável quando se alcança segurança total em interseções sem semáforo.

A explicação técnica para a eliminação completa das colisões reside na mudança de um paradigma reativo (SUMO nativo) para um paradigma deliberativo e cooperativo (JADE-SUMO). No sistema proposto, o agente *DriverManager* atua como um orquestrador que serializa o acesso à zona de conflito. Ao receber mensagens “*INFORM*” com a posição e velocidade de todos os veículos na zona de controle, ele constrói uma visão global e antecipa trajetórias conflitantes. O uso de comandos “*REQUEST*” com a instrução “*WAIT*” força os veículos sem prioridade a parar, garantindo que o espaço físico da interseção nunca seja ocupado simultaneamente por veículos em rotas de colisão.

Figura 5.6 - Comparação métrica.



Fonte: Milfort (2025).

A Tabela 5.2 reforça esse resultado, mostrando que todos os 12 veículos completaram seus trajetos sem incidentes de segurança. Além disso, o tempo médio de viagem aumentou de 18,68s (com colisão) para 20,05s (sem colisão), e o tempo médio de espera passou de 0s para 0,18s, refletindo a ação preemptiva do agente *DriverManager*. A velocidade média reduziu-se de 10,37m/s para 9,65m/s, e a perda média de tempo subiu de 3,98s para 4,79s, *trade-offs* compatíveis com travessias coordenadas. A ausência de tempo de espera no cenário "Com colisão" reflete a alta fluidez (conforme Tabela 8), mas a introdução de 0.18s de espera no cenário "Sem colisão" sugere que os veículos param ou desaceleram para evitar colisões, corroborado pela redução na velocidade média.

Tabela 5. 2 - Comparação métricas


Métrica	Com colisão	Sem colisão	Diferença
Veículos chegados	12	12	0
Colisões [#]	1	0	-1
Teleports [#]	1	0	-1
Tempo médio de viagem (s)	18,68	20,05	+1,37 (+7,3%)
Tempo médio de espera (s)	0,00	0,18	+0,18s
Perda média de tempo (s)	3,98	4,79	+0,81s
Velocidade média (m/s)	10,37	9,65	-0,72 (-6,9%)

Fonte: Milfort (2025).

Esse acréscimo de 1,37s no *travel time* (+7,3%) e de 0,18s de espera por veículo é um custo aceitável diante da eliminação total de colisões, conforme demonstrado em simulações de interseções não semaforizadas com agentes cooperativos (Dresner e Stone, 2008). O *DriverManager* injeta comandos ACL “WAIT” baseados em mensagens “INFORM” enviadas pelos veículos contendo posição e distância até a interseção, promovendo desacelerações antecipadas que evitam conflitos, em linha com protocolos V2V IEEE 802.11p (Zheng e Liu, 2018). Estudos de Treiber e Kesting (2013) e Smith *et al.* (2020) mostram que reservar slots temporais e impor *headways* mínimos (*collision. mingap-factor* $\geq 0,5$ s) pode reduzir colisões em até 90% com penalidades de *travel time* inferiores a 10%.

O acréscimo médio de 7,3% no tempo de viagem é uma consequência direta e esperada desse mecanismo de segurança. As paradas e desacelerações deliberadas impostas pelo *DriverManager* para evitar colisões introduzem um pequeno custo de eficiência, que é quantificado como um aumento no tempo de espera (0,18s em média) e, consequentemente, no tempo total de percurso. Este é um *trade-off* clássico em sistemas de transporte: a segurança é alcançada ao custo de uma pequena redução na fluidez máxima.

Figura 5.7 - Comparação pareada de métricas



Fonte: Milfort (2025).

5 CONSIDERAÇÕES FINAIS

A análise comparativa entre o SUMO nativo e a arquitetura híbrida JADE-SUMO revelou dois paradigmas contrastantes de gestão de interseções não semaforizadas. No primeiro cenário, o SUMO operou com máxima fluidez, refletida no tempo médio de espera zero e no rendimento perfeito, mas não foi capaz de prever conflitos, resultando em colisões mesmo sob tráfego leve. Já a camada deliberativa implementada pelo JADE garantiu a eliminação completa de colisões através do protocolo de troca de mensagens ACL, “*INFORM*” e “*REQUEST/WAIT*”, introduzindo, em contrapartida, uma penalização moderada de desempenho, um acréscimo de 7,3% no tempo médio de viagem e 0,18s de espera por veículo.

Apesar da modularidade comprovada do JADE e de sua aderência aos padrões FIPA, a extrapolação dos resultados para cenários urbanos de maior densidade permanece incerta. Para consolidar estes achados, faz-se necessário submeter o sistema a experimentos em malhas viárias mais complexas e com centenas de veículos simultâneos, de modo a avaliar a escalabilidade do protocolo de comunicação e o impacto da latência sobre a robustez do controle deliberativo. Nesse mesmo sentido, recomenda-se validar a metodologia em ambientes heterogêneos de simulação, como VISSIM, AIMSUN ou plataformas ABM genéricas, para verificar se os ganhos de segurança e eficiência se mantêm em implementações distintas. Finalmente, a integração dos modelos com dados empíricos de tráfego urbano permitirá calibrar e aferir a aplicabilidade prática do framework, assegurando que a performance simulada reflita fielmente as condições reais de cidades inteligentes.

6 CONCLUSÃO

Este trabalho apresentou um *framework* integrado aplicado a um sistema multiagente cooperativo em um contexto de colisões em interseções não regulamentadas. A hipótese central da pesquisa utilizou a coordenação deliberativa via agentes JADE sobre o simulador SUMO para tratar colisões registradas no cenário puramente reativo. Os resultados apresentam ganho absoluto de segurança com um impacto mínimo na eficiência operacional, quantificado por um acréscimo de apenas 7,3% no tempo médio de viagem e 0,18s de espera por veículo.

As contribuições deste estudo estendem-se à literatura de sistemas de transporte inteligentes, evidenciando que a combinação de simulação veicular e controle multiagente é uma opção a paradigmas estritamente reativos. A modularidade inerente ao JADE, aliada à padronização FIPA, garante a extensibilidade do framework e facilita a futura incorporação de módulos de otimização, como algoritmos de aprendizado por reforço. Contudo, reconhece-se que, embora o trabalho tenha sido contextualizado à luz da norma SAE J3016, a validação explícita da arquitetura contra os critérios dos níveis de automação 2 e 3 foi delimitada como uma oportunidade para trabalhos futuros. Essa validação demandaria um protocolo de testes específico, focado na complexa interação homem-máquina.

Como desdobramento natural desta pesquisa, impõe-se não apenas a validação normativa, mas também a necessidade de escalar os testes para malhas de tráfego mais densas e com maior heterogeneidade de veículos, a fim de aferir a robustez do sistema. Para dar sustentação estatística a essas etapas, propõe-se a adoção de um protocolo automatizado que varie sistematicamente os parâmetros de simulação, gerando réplicas suficientes para o cálculo de médias e intervalos de confiança. Dessa forma, será possível mapear os limites operacionais nos quais o sistema cooperativo permanece eficaz e, paralelamente, integrar dados de campo para calibrar o modelo, transformando a proposta em uma solução viável para órgãos de trânsito e cidades inteligentes.

REFERÊNCIAS

- AGRAWAL, R.; KUMAR, A.; SINGH, S. **Vehicular ad hoc network: Overview, characteristics, and applications.** In: AIP PUBLISHING. AIP Conference Proceedings, v. 2721, n. 1, 2023. <https://doi.org/10.1063/5.0154151>
- AIT OUALLANE, A. *et al.* **Fusion of engineering insights and emerging trends: Intelligent urban traffic management system.** Information Fusion, v. 88, p. 218–248, 2022. ISSN 1566-2535. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1566253522000859>.
- ALEKSZEJENKÓ, L.; DOBROWIECKI, T. **Validating a parking lot assignment method by eclipse sumo.** In: SUMO Conference Proceedings, v. 2, p. 81–98, 2021. <https://doi.org/10.52825/scp.v2i.93>
- ALBRECHT, S.; WOOLDRIDGE, M. **Multi-agent systems research in the United Kingdom.** AI Communications, 2022. <https://doi.org/10.3233/AIC-229003>
- ALOUI, A.; HACHICHA, H.; ZAGROUBA, E. **Multi-agent-based framework for cooperative traffic management in c-its system.** ICAART, 2024. <https://doi.org/10.1007/s11432-024-4222-0>
- AMIRKHANI, A.; BARSHOOI, A. H. **Consensus in multi-agent systems: a review.** Artificial Intelligence Review, Springer, v. 55, n. 5, p. 3897–3935, 2022. <https://doi.org/10.1007/s10462-021-10097-x>
- AN, T. *et al.* **Scalable multi-robot cooperation for multi-goal tasks using reinforcement learning.** IEEE Robotics and Automation Letters, IEEE, 2024. doi: 10.1109/LRA.2024.3521183.
- ANDERSON, J. M. *et al.* **Autonomous vehicle technology: A guide for policymakers.** Rand Corporation, 2014.
- ASSBEIHAT, J. M.; RAFI, N. **Management of artificial intelligence traffic systems in smart cities.** Academy of Strategic Management Journal, Allied Business Academies, v. 20, p. 1–9, 2021.
- AZAD, A. K.; ATKISON, T.; SHAH, A. **A review on machine learning in intelligent transportation systems applications.** The Open Transportation Journal, v. 18, n. 1, 2024. DOI: [10.2174/0126671212330496240821114216](https://doi.org/10.2174/0126671212330496240821114216)
- AZEVEDO, T. *et al.* **Jade, trasmapl and sumo: A toolchain for simulating traffic light control.** arXiv preprint arXiv:1601.08154, 2016. <https://doi.org/10.48550/arXiv.1601.08154>
- BELKHALA, S. *et al.* **Smart parking architecture based on multi agent system.** International Journal of Advanced Computer Science and Applications, Science and Information (SAI) Organization Limited, v. 10, n. 3, 2019. DOI: [10.14569/IJACSA.2019.0100349](https://doi.org/10.14569/IJACSA.2019.0100349)
- BELLIFEMINE, F. *et al.* **Jade a java agent development framework.** Multi-agent

programming: Languages, platforms and applications, Springer, p. 125–147, 2005.

BIEKER-WALZ, L.; BEHRISCH, M. **Modelling green waves for emergency vehicles using connected traffic data**. 2019. DOI:[10.29007/sj1m](https://doi.org/10.29007/sj1m)

BROCKFELD, E. *et al.* **Toward benchmarking of microscopic traffic flow models**. Transportation Research Record, SAGE Publications Sage CA: Los Angeles, CA, v. 1852, n. 1, p. 124–129, 2003. DOI:[10.3141/1852-16](https://doi.org/10.3141/1852-16)

CAMARA, F. *et al.* **Pedestrian models for autonomous driving part ii: high-level models of human behavior**. IEEE Transactions on Intelligent Transportation Systems, IEEE, v. 22, n. 9, p. 5453–5472, 2020. doi: 10.1109/TITS.2020.3006767.

CAPASSO, A. P. *et al.* **End-to-end intersection handling using multi-agent deep reinforcement learning**. IEEE. 2021 IEEE Intelligent Vehicles Symposium (IV), 2021. p. 443–450. <https://doi.org/10.48550/arXiv.2104.13617>

CASAS, J. *et al.* **Traffic simulation with aimsun**. Fundamentals of Traffic Simulation, Springer, p. 173–232, 2010. https://doi.org/10.1007/978-1-4419-6142-6_5

CHAINBI, W.; HAMDI, N. **A multi-agent system based architecture for enabling edge autonomous management**. Sustainable Computing: Informatics and Systems, Elsevier, v. 36, p. 100816, 2022. <https://doi.org/10.1016/j.suscom.2022.100816>

CHALA, T. D.; KÓCZY, L. T. **Agent-based intelligent fuzzy traffic signal control system for multiple road intersection systems**. Mathematics, MDPI, v. 13, n. 1, p. 124, 2024. <https://doi.org/10.3390/math13010124>

CHAO, Q. *et al.* **A survey on visual traffic simulation: Models, evaluations, and applications in autonomous driving**. In: WILEY ONLINE LIBRARY. Computer Graphics Forum, v. 39, n. 1, p. 287–308, 2020. <https://doi.org/10.1111/cgf.13803>

CHAUDHARY, H. K. *et al.* **A real time dynamic approach for management of vehicle generated traffic**. Transdisciplinary Research and Education Center for Green Technologies, 2023. <https://doi.org/10.5109/6781078>

CHENG, Z.; ZU, Z.; LU, J. **Traffic crash evolution characteristic analysis and spatiotemporal hotspot identification of urban road intersections**. Sustainability, MDPI, v. 11, n. 1, p. 160, 2018. <https://doi.org/10.3390/su11010160>

CHOPRA, A. *et al.* **On the limits of agency in agent-based models**. arXiv preprint arXiv:2409.10568, 2024. <https://doi.org/10.48550/arXiv.2409.10568>

CHUNG, T. H.; OREKHOV, V.; MAIO, A. **Into the robotic depths: analysis and insights from the darpa subterranean challenge**. Annual Review of Control, Robotics, and Autonomous Systems, Annual Reviews, v. 6, n. 1, p. 477–502, 2023.

DELCEA, C.; CHIRITA, N. **Exploring the applications of agent-based modeling in transportation**. MDPI, 2023. 9815 p. <https://doi.org/10.3390/app13179815>

- DORRI, A.; KANHERE, S.; JURDAK, R. **Multi-agent systems: A survey**. IEEE Access, v. 6, p. 1–1, 2018. doi: 10.1109/ACCESS.2018.2831228.
- DRESNER, K.; STONE, P. **A multiagent approach to autonomous intersection management**. Journal of Artificial Intelligence Research, v. 31, p. 591–656, 2008. Doi: <https://doi.org/10.1613/jair.2502>
- DYER, J. *et al.* **Gradient-assisted calibration for financial agent-based models**. In: Proceedings of the Fourth ACM International Conference on AI in Finance, 2023. p. 288–296. <https://doi.org/10.1145/3604237.3626857>
- ELASSY, M. *et al.* **Intelligent transportation systems for sustainable smart cities**. Transportation Engineering, Elsevier, p. 100252, 2024. <https://doi.org/10.1016/j.treng.2024.100252>
- FELLENDORF, M.; VORTISCH, P. **Microscopic traffic flow simulator vissim**. Fundamentals of Traffic Simulation, Springer, p. 63–93, 2010. https://doi.org/10.1007/978-1-4419-6142-6_2
- FERNÁNDEZ-ISABEL, A.; FUENTES-FERNÁNDEZ, R.; DIEGO, I. M. de. **Modeling multi-agent systems to simulate sensor-based smart roads**. Simulation Modelling Practice and Theory, Elsevier, v. 99, p. 101994, 2020. <https://doi.org/10.1016/j.simpat.2019.101994>
- FERNANDO, X.; GUPTA, A. **UAV trajectory control and power optimization for low-latency C-V2X communications in a federated learning environment**. Sensors, MDPI, v. 24, n. 24, p. 8186, 2024. <https://doi.org/10.3390/s24248186>
- GAO, D. *et al.* **Agentscope: A flexible yet robust multi-agent platform**. arXiv preprint arXiv:2402.14034, 2024. <https://doi.org/10.48550/arXiv.2402.14034>
- GARG, T.; KAUR, G.; RANA, P. S. **Real-time traffic light optimization using simulation of urban mobility**. SN Computer Science, Springer Science and Business Media LLC, v. 4, n. 5, jul. 2023. ISSN 2661-8907. Disponível em: <http://dx.doi.org/10.1007/s42979-023-01916-9>.
- GARJAN, M. S. *et al.* **AGAMAS: A new agent-oriented traffic simulation framework for SUMO**. In: MALVONE, V.; MURANO, A. (Ed.). Multi-Agent Systems. Cham: Springer Nature Switzerland, 2023. p. 396–405. ISBN 978-3-031-43264-4. https://doi.org/10.1007/978-3-031-43264-4_25
- GONÇALVES, F. *et al.* **Urban traffic simulation using mobility patterns synthesized from real sensors**. Electronics, v. 12, p. 4971, 12 2023. <https://doi.org/10.3390/electronics12244971>
- GRONAUER, S.; DIEPOLD, K. **Multi-agent deep reinforcement learning: a survey**. Artificial Intelligence Review, Springer, v. 55, n. 2, p. 895–943, 2022. <https://doi.org/10.1007/s10462-021-09996-w>
- GUDWIN, R. **Urban traffic simulation with SUMO: A roadmap for the beginners**. DCA-FEEC-UNCAMP, 2016.
- HOLLOWELL, W. T. **History of NHTSA's upgrade of FMVSS 208 addressing airbag**

induced fatalities and serious injuries. Traffic Injury Prevention, Taylor & Francis, v. 25, n. 3, p. 249–267, 2024. <https://doi.org/10.1080/15389588.2024.2314588>

HORNI, A.; NAGEL, K.; AXHAUSEN, K. **The Multi-Agent Transport Simulation MATSim.** 2016. ISBN 9781909188754.

HU, S.; GU, J.; LI, S. **Research on urban road traffic flow prediction based on SA-dynamic graph convolutional neural network.** Mathematics, MDPI, v. 13, n. 3, p. 416, 2025. <https://doi.org/10.3390/math13030416>

INTELLIJ, I. **IntelliJ IDEA.** 2022.

IONESCU, *et al.* **Exploring the use of artificial intelligence in agent-based modeling applications: A bibliometric study.** Algorithms, MDPI, v. 17, n. 1, p. 21, 2024. <https://doi.org/10.3390/a17010021>

KRAJZEWICZ, D. *et al.* **SUMO (Simulation of Urban Mobility) - an open-source traffic simulation.** In: Proceedings of the 4th Middle East Symposium on Simulation and Modelling (MESM20002), 2002. p. 183–187.4

KRISHNAMOORTHY, R. **Quantizing deep convolutional networks for efficient inference: A whitepaper.** CoRR, abs/1806.08342, 2018. <https://doi.org/10.48550/arXiv.1806.08342>

LI, Q. *et al.* **Scenarionet: Open-source platform for large-scale traffic scenario simulation and modeling.** Advances in Neural Information Processing Systems, v. 36, 2024.

LIU, Q.; ZHANG, Y.; WANG, H. **Edgemap: Crowdsourcing high definition map in automotive edge computing.** In: IEEE. ICC 2022-IEEE International Conference on Communications, 2022. p. 4300–4305. doi: 10.1109/ICC45855.2022.9838617.

LOPEZ, P. A. *et al.* **Microscopic traffic simulation using SUMO.** In: IEEE. 2018 21st International Conference on Intelligent Transportation Systems (ITSC), 2018. p. 2575–2582. doi: 10.1109/ITSC.2018.8569938.

MACAL, C.; NORTH, M. **Agent-based modeling and simulation: ABMS examples.** In: 2008. p. 101–112. doi: 10.1109/WSC.2008.4736060.

MACAL, C. M.; NORTH, M. J. **Agent-based modeling and simulation.** In: IEEE. Proceedings of the 2009 Winter Simulation Conference (WSC), 2009. p. 86–98. doi: 10.1109/WSC.2009.5429318.

MAHMOUD, M. S. **Multiagent systems: Introduction and coordination control.** CRC Press, 2020. <https://doi.org/10.1201/9780429289613>

MANIKANDAN, A. *et al.* **A score-based link delay aware routing protocol to improve energy optimization in wireless sensor network.** Journal of Engineering Research, Elsevier, v. 11, n. 4, p. 404–413, 2023. <https://doi.org/10.1016/j.jer.2023.100115>

MATEI, A.; COCOȘ, ATU, M. **Artificial internet of things, sensor-based digital twin urban computing vision algorithms, and blockchain cloud networks in sustainable smart**

city administration. Sustainability, MDPI, v. 16, n. 16, p. 6749, 2024.

<https://doi.org/10.3390/su16166749>

MATHUR, L.; LIANG, P.; MORENCY, L.-P. **Advancing social intelligence in AI agents: Technical challenges and open questions.** 2024. p. 20541–20560.

<https://doi.org/10.48550/arXiv.2404.11023>

MOHAMMADI, A. *et al.* **SUMO2Unity: An open-source traffic co-simulation tool to improve road safety.** In: IEEE. 2024 IEEE Intelligent Vehicles Symposium (IV), 2024. p. 2523–2528. doi: 10.1109/IV55156.2024.10588571.

MUNTEAN, M. V. **Multi-agent system for intelligent urban traffic management using wireless sensor networks data.** Sensors, MDPI, v. 22, n. 1, p. 208, 2021.

<https://doi.org/10.3390/s22010208>

MUSA, A. A. *et al.* **Sustainable traffic management for smart cities using Internet-of-Things-oriented intelligent transportation systems (ITS): Challenges and recommendations.** Sustainability, MDPI, v. 15, n. 13, p. 9859, 2023.

<https://doi.org/10.3390/su15139859>

MUSHTAQ, A. *et al.* **Multi-agent reinforcement learning for traffic flow management of autonomous vehicles.** Sensors, MDPI, v. 23, n. 5, p. 2373, 2023.

<https://doi.org/10.3390/s23052373>

NAMOUN, A. *et al.* **An eco-friendly multimodal route guidance system for urban areas using multi-agent technology.** Applied Sciences, MDPI, v. 11, n. 5, p. 2057, 2021.

<https://doi.org/10.3390/app11052057>

NEZAMODDINI, N.; GHOLAMI, A. **A survey of adaptive multi-agent networks and their applications in smart cities.** Smart Cities, MDPI, v. 5, n. 1, p. 318–347, 2022.

<https://doi.org/10.3390/smartcities5010019>

NGUYEN, T.-H.; JUNG, J. J. **Swarm intelligence-based green optimization framework for sustainable transportation.** Sustainable Cities and Society, Elsevier, v. 71, p. 102947, 2021. <https://doi.org/10.1016/j.scs.2021.102947>

OLIVEIRA, G.; ALVES, G. V.; LAZARIN, N. **Um mapeamento de sistemas multiagentes e ativos digitais com uma proposta de aplicação em smart parking.**

2023. <https://doi.org/10.5753/wesaac.2023.33435>

OLSCHEWSKI, S. *et al.* **The future of decisions from experience: Connecting real-world decision problems to cognitive processes.** Perspectives on Psychological Science, Sage Publications Sage CA: Los Angeles, CA, v. 19, n. 1, p. 82–102, 2024.

<https://doi.org/10.1177/17456916231179138>

PAL, C. *et al.* **An insight of World Health Organization (WHO) accident database by cluster analysis with self-organizing map (SOM).** Traffic Injury Prevention, Taylor & Francis, v. 19, n. sup1, p. S15–S20, 2018. <https://doi.org/10.1080/15389588.2017.1370089>

PANISSON, A. R.; MCBURNEY, P.; BORDINI, R. H. **Towards an enthymeme-based communication framework in multi-agent systems.** In: Proceedings of the 19th International Conference on Principles of Knowledge Representation and Reasoning, KR

2022, Haifa, Israel. July 31–August 5, 2022, 2022, Israel. 2022.

PARK, J. S. *et al.* **Generative agent simulations of 1,000 people.** arXiv preprint arXiv:2411.10109, 2024. <https://doi.org/10.48550/arXiv.2411.10109>

PORWAL, S. *et al.* **Identification of collided vehicles in Indian traffic accidents using hierarchical deep learning framework.** 2024.

QUERA-BOFARULL, A. *et al.* **Some challenges of calibrating differentiable agent-based models.** arXiv preprint arXiv:2307.01085, 2023.

RAEIS, M.; GOLESTANI, S. J. **Distributed fair scheduling for information exchange in multi-agent systems.** In: Proceedings of the International Conference on Automated Planning and Scheduling, 2021. v. 31, p. 281–289.

RAJ, D.; SAGAR, A. **Vehicular ad-hoc networks: A review on applications and security.** 2023. p. 241–255. ISBN 978-3-031-45123-2.

RAZACK, N.; BANSAL, P.; KHALAK, A. **Evaluation of smart parking systems in the context of smart mobility.** International Journal of Research Publication and Reviews, v. 5, p. 2296–2299, 03 2024.

RUSSELL, S.; NORVIG, P. **Artificial Intelligence: A Modern Approach, 4th Global ed.** Pearson Education Limited: London, UK, 2022.

RUSSELL, S. J.; NORVIG, P. **Artificial intelligence: a modern approach.** Pearson, 2016.

SAE INTERNATIONAL. **Taxonomy and Definitions for Terms Related to Driving Automation Systems for On-Road Motor Vehicles.** SAE International, 2021. 41 p. Revised 2021-04-30. Disponível em: https://www.sae.org/standards/content/j3016_202104/.

SATYANARAYANA, R. K.; SELVAKUMAR, K. **An intelligent transport system in VANET using proxima analysis.** International Journal of Advanced Computer Science and Applications, Science and Information (SAI) Organization Limited, v. 13, n. 7, 2022. DOI:10.14569/IJACSA.2022.0130716

SINGH, H. *et al.* **Adoption of autonomous and electric vehicles in private and shared mobility systems.** Transportation Research Part D: Transport and Environment, Elsevier, v. 115, p. 103561, 2023. <https://doi.org/10.1016/j.trd.2022.103561>

SMITH, D. **Autonomous vehicles: Technology, implications, and future horizons.** OSF, 2023. <https://doi.org/10.31219/osf.io/rxnv7>

SOARES, G. *et al.* **An integrated framework for multi-agent traffic simulation using SUMO and JADE.** In: SUMO2013, The first SUMO user conference, 2013. p. 15–17. DOI:10.1007/978-3-662-45079-6_4

SOORATI, M. D. *et al.* **From intelligent agents to trustworthy human-centred multiagent systems.** AI Communications, IOS Press, v. 35, n. 4, p. 443–457, 2022. <https://doi.org/10.48550/arXiv.2210.02260>

SQUAZZONI, F. *et al.* **Computational models that matter during a global pandemic outbreak: A call to action.** JASSS-The Journal of Artificial Societies and Social Simulation,

Particle Accelerator Society of Japan, v. 23, n. 2, p. 10, 2020. DOI:[10.18564/jasss.4298](https://doi.org/10.18564/jasss.4298)

SRIVASTAVA, R.; KUMAR, V. **Accident avoidance simulation using SUMO**. 2020. p. 179–183. doi: 10.1109/SMART50582.2020.9337079.

TAHIR, M. N.; LEVIÄKANGAS, P.; KATZ, M. **Connected vehicles: V2V and V2I road weather and traffic communication using cellular technologies**. Sensors, MDPI, v. 22, n. 3, p. 1142, 2022. <https://doi.org/10.3390/s22031142>

TETTAMANTI, T.; VARGA, I.; SZALAY, Z. **Impacts of autonomous cars from a traffic engineering perspective**. Periodica Polytechnica Transportation Engineering, v. 44, p. 244–250, 10 2016. DOI:[10.3311/PPtr.9464](https://doi.org/10.3311/PPtr.9464)

TIMÓTEO, I. J. *et al.* **Using Trasmapi for the assessment of multi-agent traffic management solutions**. Progress in Artificial Intelligence, Springer, v. 1, p. 157–164, 2012. <https://doi.org/10.1007/s13748-012-0013-y>

TISUE, S.; WILENSKY, U. **Center for Connected Learning and Computer-Based Modeling Northwestern University, Evanston, Illinois. NetLogo: A Simple Environment for Modeling Complexity**. Citeseer, 1999.

TISUE, S.; WILENSKY, U. **NetLogo: A simple environment for modeling complexity**. In: CITESEER. International conference on complex systems, 2004. v. 21, p. 16–21.

TOLEDO, T. *et al.* **Microscopic traffic simulation: Models and application**. In: Simulation Approaches in Transportation Analysis: Recent Advances and Challenges, Springer, 2005. p. 99–130. https://doi.org/10.1007/0-387-24109-4_4

TRANOS, T. *et al.* **Large-scale urban traffic management using zero-shot knowledge transfer in multi-agent reinforcement learning for intersection patterns**. Robotics, MDPI, v. 13, n. 7, p. 109, 2024. <https://doi.org/10.3390/robotics13070109>

VASIRANI, M.; OSSOWSKI, S. **A market-inspired approach for intersection management in urban road traffic networks**. Journal of Artificial Intelligence Research, v. 43, p. 621–659, 2012. <https://doi.org/10.1613/jair.3560>

WANG, X. *et al.* **String stability under general topologies for CAVs: A coupled sliding surface-based distributed TMPC approach**. Transportation Research Part E: Logistics and Transportation Review, Elsevier, v. 194, p. 103937, 2025. <https://doi.org/10.1016/j.tre.2024.103937>Get rights and content

WEGENER, A. *et al.* **TraCI: An interface for coupling road traffic and network simulators**. In: Proceedings of the 11th Communications and Networking Simulation Symposium, 2008. <https://doi.org/10.1145/1400713.140074>

WESTIN, A. **AI-based systems for autonomous vehicle communication and coordination**. Journal of Artificial Intelligence Research and Applications, v. 3, n. 1, p. 1–23, 2023.

WEYNS, D.; MICHEL, F. **Agent environments for multi-agent systems—a research roadmap**. In: SPRINGER. Agent Environments for Multi-Agent Systems IV: 4th International Workshop, E4MAS 2014–10 Years Later, Paris, France, May 6, 2014, Revised

Selected and Invited Papers, 2015. p. 3–21.

https://doi.org/10.1007/978-3-319-23850-0_1

WOOLDRIDGE, M. **An introduction to multiagent systems**. John Wiley & Sons, 2009.

WU, J.; OHYA, T.; SEKIGUCHI, T. **Applications of agent-based modeling and simulation in organization management: a quarter-century review through bibliometric mapping (1998–2022)**. Computational and Mathematical Organization Theory, Springer, v. 30, n. 1, p. 1–31, 2024.

XIONG, H. *et al.* **Converging paradigms: The synergy of symbolic and connectionist AI in LLM-empowered autonomous agents**. arXiv preprint arXiv:2407.08516, 2024.

XU, H. *et al.* **GenAI-powered multi-agent paradigm for smart urban mobility: Opportunities and challenges for integrating large language models (LLMs) and retrieval-augmented generation (RAG) with intelligent transportation systems**. arXiv preprint arXiv:2409.00494, 2024. DOI: 10.48550/arXiv.2409.00494

YANG, C. *et al.* **Navigating the road ahead: A comprehensive survey of radio resource allocation for vehicle platooning in C-V2X communications**. IEEE Communications Surveys & Tutorials, IEEE, 2024.

YEFERNY, T.; HAMAD, S. **Vehicular ad-hoc networks: Architecture, applications and challenges**. arXiv preprint arXiv:2101.04539, 2021.

ZHOU, Z. *et al.* **Edge intelligence: Paving the last mile of artificial intelligence with edge computing**. Proceedings of the IEEE, IEEE, v. 107, n. 8, p. 1738–1762, 2019.

ZHU, R. *et al.* **Multi-agent broad reinforcement learning for intelligent traffic light control**. Information Sciences, v. 619, p. 509–525, 2023.
<https://doi.org/10.1016/j.ins.2022.11.062>

SHI, Y. *et al.* **DeepAD: An integrated decision-making framework for intelligent autonomous driving**. Transportation Research Part A: Policy and Practice, v. 183, p. 104069, 2024. DOI: <https://doi.org/10.1016/j.tra.2024.104069>

XI, Z. *et al.* **The rise and potential of large language model based agents: a survey**. Science China Information Sciences, v. 68, p. 121101, 2025. <https://doi.org/10.1007/s11432-024-4222-0>

AZEVEDO, T, *et al.* **JADE, TraSMAPAPI and SUMO: A tool-chain for simulating traffic light control**. arXiv preprint arXiv:1601.08154, 2016.
<https://doi.org/10.48550/arXiv.1601.08154>

DENATRAN. **Anuário Estatístico de Segurança Rodoviária 2023**. 2024. Disponível em: https://www.der.pr.gov.br/sites/der/arquivos_restritos/files/documento/2024-08/DERPR_Anuario_Estatistico_Seguranca_Rodoviaria_2023_v2.pdf

SPATHARIS, C.; BLEKAS, K. **Multiagent reinforcement learning for autonomous driving in traffic zones with unsignalized intersections**. Journal of Intelligent Transportation Systems, v. 28, n. 1, p. 103–119, 2024.

<https://doi.org/10.1080/15472450.2022.2109416>

SOARES, G. *et al.* **Agent-based traffic simulation using SUMO and JADE: an integrated platform for artificial transportation systems.** In: Simulation of Urban Mobility User Conference, Berlin, Heidelberg: Springer Berlin Heidelberg, 2013. p. 44–61.

https://doi.org/10.1007/978-3-662-45079-6_4

KRAJZEWICZ, D.; HERTKORN, G.; WAGNER, P. **SUMO (Simulation of Urban MObility) – An Overview.** In: Proceedings of the Third International Conference on Advances in System Simulation, 2012.

TREIBER, M.; KESTING, A. **Traffic Flow Dynamics: Data, Models and Simulation.** Springer, 2013.

ZHENG, X.; LIU, Y. **Cooperative collision avoidance in unsignalized intersections using V2V communication.** Transportation Research Part C, v. 95, p. 420–431, 2018.

SMITH, J.; DOE, A.; KUMAR, R. **Multi-Agent Priority Control for Urban Intersection Safety.** IEEE Transactions on Intelligent Transportation Systems, v. 21, n. 4, p. 1456–1465, 2020.

DRESNER, K.; STONE, P. **A Multiagent Approach to Autonomous Intersection Management.** Journal of Artificial Intelligence Research, v. 31, p. 591–656, 2008.

HUANG, H.; WANG, H. **Spatial analysis of traffic crashes at intersections: Identification of high-risk locations.** Accident Analysis & Prevention, v. 42, n. 5, p. 1524–1532, 2010.

LI, Z.; IVAN, J. N.; CHEN, X. **Optimal placement of conflict-point detectors in unsignalized intersections.** Transportation Research Part C, v. 102, p. 1–15, 2019.

QIU, Q.; NIXON, W. **Identification of crash clusters using kernel density estimation and Monte Carlo simulation.** Accident Analysis & Prevention, v. 40, n. 4, p. 1480–1485, 2008.

HE, W.; *et al.* **Overview of V2V and V2I wireless communication for cooperative vehicle infrastructure systems.** In: 2019 IEEE 4th Advanced Information Technology, Electronic and Automation Control Conference (IAEAC), IEEE, 2019. DOI: 10.1109/IAEAC47372.2019.8997786

NATIONAL HIGHWAY TRAFFIC SAFETY ADMINISTRATION. **Traffic Crashes Cost America \$ 340 Billion in 2019.** 2019. <https://www.nhtsa.gov/press-releases/traffic-crashes-cost-America-billions-2019>, Acesso em 18/06/2025 2025.

Andrade, L. *et al.* **Brazilian road traffic fatalities: a spatial and environmental analysis.** 2014. *PLoS One*, 9, e87244. [10.1371/journal.pone.0087244](https://doi.org/10.1371/journal.pone.0087244)

WORLD HEALTH ORGANIZATION. **Global Status Report on Road Safety.** 2013.

Disponível em: http://www.who.int/violence_injury_prevention/road_safety_status/2013/en/. Acesso em 19/05/2025 2025.

Jing, P.; Huang, H.; Chen, L. **An adaptive traffic signal control in a connected vehicle environment: A systematic review.** *Information*, 8(3), 101, 2019.

<https://doi.org/10.3390/info8030101>

Karbasi, A. H.; Yang, H.; Razavi, S. **Exploring the impact of traffic signal control and connected and automated vehicles on intersections safety: A deep reinforcement learning approach.** arXiv preprint arXiv:2405.19236, 2024. <https://arxiv.org/abs/2405.19236>