

Soluções Inteligentes para Semáforos

Erick Lucas Machado Figueiredo Da Silva

erick.lucas0973@gmail.com

Maria José Pereira Dantas

mjdantas@pucgoias.edu.br

Solange Da Silva

solansilva.ucg@gmail.com

Pontifícia Universidade Católica de Goiás (PUCGO)

1ª Avenida, 458-590 - Setor Leste Universitário, Goiânia - GO, 74605-020

RESUMO

A revisão de literatura apresenta soluções inteligentes para semáforos (*ITS*) voltadas à mitigação de congestionamentos urbanos. Uma busca sistemática na *WoS*, no período de 2006-2024, com termos como “*Smart Traffic Light*”, “*Intelligent Traffic Light System*”, “*Heuristic*” e “*IA*” resultou em 5.618 artigos, analisados via planilha Excel com *Methodi Ordinatio*, *pybibx* e *VOSviewer*. A análise bibliométrica revelou *clusters* focados em *deep learning*, *IoT* e *edge computing*, segurança e *blockchain*, otimização de fluxo e lógica *fuzzy*. A combinação de Excel e Python refinou a seleção para 351 artigos, possibilitando gráficos de publicações e citações ao longo dos anos. Observou-se crescimento expressivo de publicações a partir de 2016, embora com menor média de citações recentes. Entre os 22 artigos avaliados, destacaram-se contribuições de *frameworks fog/edge*, modelos *ML* quantizados, meta-heurísticas híbridas, *RL* multiagente e *blockchain* para controle adaptativo de semáforos. Desafios incluem integração com sistemas legados, sobrecarga computacional e necessidade de calibração contínua.

PALAVRAS-CHAVE. Semáforo, Sistema de Semáforo Inteligente, Heurística, IA.

Tópicos

Logística e Transportes, *PO Analytics* em Estatística e Aprendizagem de Máquina

ABSTRACT

The literature review presents intelligent traffic light (*ITS*) solutions aimed at mitigating urban congestion. A systematic search in *WoS*, covering the period 2006–2024 and using terms such as “*Smart Traffic Light*,” “*Intelligent Traffic Light System*,” “*Heuristic*,” and “*AI*,” retrieved 5,618 articles, analyzed with Excel spreadsheets using *Methodi Ordinatio*, *pybibx*, and *VOSviewer*. The bibliometric analysis revealed clusters focused on deep learning, *IoT* and edge computing, security and blockchain, flow optimization, and fuzzy logic. Combining Excel and Python refined the selection to 351 articles, enabling the construction of publication and citation graphs over time. A significant growth in publications was observed from 2016 onward, although recent works show lower citation averages. Among the 22 core studies, notable contributions included fog/edge frameworks, quantized ML models, hybrid metaheuristics, multi-agent reinforcement learning, and blockchain for adaptive traffic light control. Key challenges remain in legacy system integration, computational overhead, and the need for continuous calibration.

KEYWORDS. Traffic Light, Intelligent Traffic Light System, Heuristic, IA.

Paper topics

Logistics and Transport, *PO Analytics* in Statistics and Machine Learning

1. Introdução

As zonas urbanas vêm enfrentando um aumento considerável nos congestionamentos de tráfego. Em contrapartida, o avanço das tecnologias possibilitou o surgimento dos Sistemas de Transporte Inteligente (ITS), que buscam aprimorar a gestão do tráfego por meio de soluções baseadas em sistemas inteligentes [Akopov e Beklaryan 2024], [Cruz-Piris et al. 2018]. Esses sistemas integram componentes como infraestrutura, veículos e usuários, promovendo melhorias em toda a rede viária.

Entre as soluções propostas, destacam-se os Semáforos Inteligentes (STLs), que oferecem controle adaptativo dos fluxos de veículos e pedestres [Akopov e Beklaryan 2024]. Esses sistemas têm como principal objetivo minimizar o congestionamento, caracterizando-se como um problema de otimização.

Diversas abordagens foram apresentadas na literatura para enfrentar esse desafio, como o uso de Inteligência Artificial (IA), Aprendizado por Reforço (QL) [Dimon et al. 2022], Teoria dos Jogos [Bui et al. 2017] e *Blockchain* [Zeng et al. 2020].

Este artigo de revisão de literatura está estruturado em 4 seções. A seção 2 descreve a metodologia aplicada na seleção dos artigos, apresentando as questões de pesquisa e palavras-chave. A seção 3 apresenta resultados e discussões, abordando achados importantes e as respostas às questões de pesquisa. A seção 4 discute tendências e lacunas que podem direcionar novas pesquisas.

2. Metodologia

Para encontrar os artigos foi utilizado o Periódicos da CAPES, com o acesso da PUC/GOIÁS e *Web of Science (WoS)*, no período de 2006-2024. Para a análise desses artigos foi usada uma ferramenta em Excel para seleção de artigos de maior relevância criada pela [Borges et al. 2023], o uso de uma biblioteca em *Python* chamada *pybibx* [Pereira et al.] e o *VOSviewer*.

Foi usada uma ferramenta em Excel com o objetivo de auxiliar a tarefa de buscar artigos científicos para um determinado tema, a planilha em Excel aceita dados exportados da *WoS*, selecionando apenas artigos que tenham *Journal Citation Reports (JCR)*, eliminando duplicados e permitindo pesquisas com até 20 palavras-chave: título, resumo, palavra-chave do autor e palavra-chave da base [Borges et al. 2023]. A planilha usa como critério de relevância o *Methodi Ordinatio* criado pela Professora Regina Negri Pagani [Pagani et al. 2017], baseado em 3 fatores: ano de publicação, fator de impacto e citações.

•Fórmula: $\text{InOrdinatio} = \text{Citações} + \text{Fator impacto} + (10 \cdot \alpha) - (\alpha \cdot \text{Idade publicação})$, onde $\alpha = 10$ para artigos mais recentes e 1 para artigos mais antigos.

O *JCR* é um sistema da *Clarivate Analytics* que avalia a relevância de periódicos científicos com base em indicadores bibliométricos, principalmente o Fator de Impacto (*Impact Factor, IF*).

Questões de pesquisa: **(Q1)**: Quais são as principais contribuições propostas? **(Q2)**: Como os métodos propostos se comparam com abordagens do estado-da-arte (eficiência e robustez)? **(Q3)**: Quais foram os desafios práticos reportados na implantação (custo, energia, manutenção)? **(Q4)**: Quais limitações cada artigo reconhece (carga de processamento, generalização, necessidade de calibração)? **(Q5)**: Como esses sistemas contribuem para metas de cidades inteligentes (sustentabilidade, redução de congestionamentos)?

Uso do software *VOSviewer* para identificação de agrupamentos temáticos.

Uso de Excel e Python para a organização de uma análise estatística sobre os artigos avaliados.

As palavras-chave usadas foram “*Smart Traffic Light*” e “*Intelligent Traffic Light System*”. Com essas duas palavras-chave foram obtidos 5618 artigos, 2263 artigos referentes a “*Smart Traffic Light*” e 3355 artigos com “*Intelligent Traffic Light System*” no site da *WoS*. Outras palavras-chave também foram utilizadas, como “*Heuristic*”, “*Meta-Heuristic*”, IA etc., mas os artigos obtidos eram poucos, para que se tivesse uma boa análise, essas palavras-chave não foram descartadas.

3. Resultados e discussão

3.1. Análise Estatística

A partir da combinação de Excel e código em *Python* para fazer uma melhor análise desses 355 artigos, chegou-se a 351 artigos que atendem aos requisitos de *JCR* e número de citações como mostra a Figura 1.

Figura 1 – análise feita a partir de um código.

```
Resumo Estatístico:  
Total de Artigos: 351  
Ano mais antigo: 2006  
Ano mais recente: 2024  
Média de citações (WoS Core): 15.527065527065528  
Média de citações (Total): 16.641025641025642  
Mediana de citações (WoS Core): 5.0  
Mediana de citações (Total): 5.0  
Artigos sem citações (WoS Core): 76  
Artigos com mais de 10 citações (WoS Core): 114
```


Fonte: autoria própria.

Com a Figura 1 tem-se o ano mais antigo e o mais recente de publicação, assim como as médias de citações, a mediana, artigos sem citações e artigos com mais de 10 citações.

As Figuras 2 e 3 apresentam, respectivamente, a evolução do número de publicações e a média de citações por ano (com base na *WoS Core*) relacionadas ao tema de semáforos inteligentes e tecnologias correlatas aplicadas à mobilidade urbana.

A Figura 2 evidencia um crescimento expressivo na produção científica a partir de 2016, com destaque para os anos de 2020, 2022 e 2023, que concentram os maiores volumes de publicações do período analisado, superando 40 artigos por ano. Esse aumento reflete um interesse crescente da comunidade acadêmica e tecnológica em soluções inteligentes para o controle de tráfego, impulsionado pela consolidação de tecnologias como Internet das Coisas (*IoT*), inteligência artificial (IA), aprendizado por reforço e veículos conectados. Além disso, o avanço de iniciativas ligadas a cidades inteligentes contribuiu significativamente para a intensificação das pesquisas nessa área.

Figura 2 –Número de publicações por ano.



Fonte: autoria própria.


Por outro lado, a Figura 3 revela que os artigos publicados a partir de 2016 apresentam, em média, um número mais baixo de citações em comparação com os anos anteriores. Essa queda

A imagem apresenta seis agrupamentos temáticos principais, cada um identificado por uma cor distinta. O agrupamento em vermelho reúne aplicações de *deep learning* e *machine learning* voltadas para modelagem e previsão em sistemas de transporte inteligente (ITS). No campo verde estão as soluções de conectividade, como Internet das Coisas (IoT), comunicação veículo-a-qualquer-coisa (V2X) e computação de borda. O conjunto marrom aborda protocolos seguros, mecanismos de autenticação e o uso de *blockchain* em redes veiculares. Já o agrupamento azul foca em modelos de fluxo de tráfego, controle de semáforos e agendamento de sinais. Em amarelo, destacam-se estudos sobre o comportamento dos motoristas, fatores de risco e a severidade de acidentes. Por fim, o bloco roxo engloba aplicações de lógica *fuzzy* em sistemas inteligentes de controle de tráfego.

Os termos com maior destaque visual são: *intelligent transportation systems*, *deep learning*, *optimization*, *internet of things* (IoT), *security*, *traffic flow*, *machine learning*. Outros termos têm conexões relevantes como *smart city* que atua como ponte entre os termos IoT, *machine learning* e mobilidade urbana, os termos *vehicle detection* e *object detection* estão ligados a *deep learning* e outros termos como V2X, VANET e *vehicular ad hoc networks* que conectam os temas de comunicação e segurança.

Ao escolher as palavras obtidas na análise feita para esta pesquisa, pode-se usar as seguintes palavras-chave *traffic flow*, *deep learning*, *travel behavior*, *internet of things* (IoT), *artificial intelligence*, *blockchain*, *vehicular ad hoc networks*, *wireless sensor networks* e ao combinar essas palavras-chave chegou-se a 355 artigos e pode-se gerar a Figura 5, no VOSviewer.

Figura 5 – Nuvem de palavras.



Fonte: autoria própria (VOSviewer.)

A Figura 5 destaca quatro grupos temáticos identificados por cores distintas. O verde refere-se aos Sistemas Veiculares e à Infraestrutura, enfatizando a comunicação V2X e soluções de Internet das Coisas para veículos conectados, com atenção especial à segurança viária e ao processamento distribuído em borda. O vermelho concentra-se em Visão Computacional e Inteligência Artificial, reunindo aplicações de *deep learning* e processamento de imagens voltadas

à detecção de objetos e ao suporte à condução autônoma. Em azul, observa-se iniciativas de Controle de Tráfego e Aprendizado por Reforço, nas quais técnicas de *reinforcement learning* e sistemas em tempo real são empregadas para otimizar sinais de trânsito de forma adaptativa. Já o amarelo agrupa estudos sobre Mobilidade Urbana Sustentável e Previsão, envolvendo modelagem de fluxo, simulações e previsões de desempenho para cidades mais sustentáveis. No núcleo central, essas áreas convergem na proposta de integração de sistemas de transporte inteligente (ITS) com as *Smart Cities*, articulando otimização, *machine learning* e Internet das Coisas como elementos conceituais para criar redes urbanas mais seguras, eficientes e resilientes.

3.3. Discussão

A ferramenta de Excel [Borges et al. 2023]] possibilitou a seleção de 22 artigos relevantes segundo o *methodi inOrdinatio*, conforme aba Indicação de leitura, como mostra a Figura 6.

Figura 6 – Aba Indicação de leitura.

137	23	TÍTULO	0	RESUM	Indicador de leitura (10%) - 6-14 de	Ano	Citações	1	7	2	11	7	0	7	5	1	4	0
Análise de Palavras-chave	Indicador Automático de Leitura do TÍTULO		Pertinente		InOrdinatio			1	7	2	11	7	0	7	5	1	4	0
								1	7	2	11	7	0	7	5	1	4	0
2.0017	x	CCITL: A cloud-based smart traffic management protocol using intelligent traffic light system in VANETs	Road con		84,831	2023	3		x								x	
2.0023	x	Internet of smart-cameras for traffic lights optimization in smart cities	Smart an		81,711	2020	26	x	x		x							
2.0046	x	A novel intelligent smart traffic system using a deep-learning architecture	Traffic co		82,577	2023	0					x						x
2.0053	x	A Novel and Optimised Thread-based Virtual Traffic Light Framework	Green int		90,555	2024	0				x						x	
2.0062	x	Edge ML Technique for Smart Traffic Management in Intelligent Transportation Systems	In urban i		102,476	2024	9		x		x			x				
2.0087	x	Game theoretic approach on Real-time decision making for IoT-based traffic light control	Smart tra		33,831	2017	36		x		x							
2.0093	x	Multi-Agent System for Intelligent Urban Traffic Management Using Wireless Sensor Networks Data	Intelligen		84,847	2022	11				x							x
2.0096	x	A Scheme of Intelligent Traffic Light System Based on Distributed Security Architecture of Blockchain	In recent		64,476	2020	11			x							x	
2.0116	x	Traffic Efficiency Applications over Downtown Roads: A New Challenge for Intelligent Connected Vehicles	Vehicula		79,324	2020	15				x							x
2.0147	x	Traffic Improvement in Manhattan Road Networks With the Use of Parallel Hybrid Biobjective Genetic Algorithm	There are		116,476	2024	23		x		x							
2.0158	x	Intelligent IoT systems for traffic management: A practical application	The inco		80,568	2021	18							x	x			
2.0160	x	SDN Control-Enabled and Time-Quantum-Driven Max-Pressure Approach for Intersection Management in Smart City	Congesti		92,802	2023	8		x		x							
2.0164	x	Multi-Agent Reinforcement Learning for Traffic Flow Management of Autonomous Vehicles	Intelligen		97,847	2023	14				x	x						
		An Information Fusion Approach to Intelligent Traffic Signal Control Using																

Fonte: autoria própria

Uma análise mostrou as principais tendências para a otimização de semáforos inteligentes que atuam em função do fluxo de tráfego foram identificadas e podem ser agrupadas em blocos de discussão, conforme descrito a seguir.

Bloco 1: Arquiteturas de Controle Inteligente Distribuído

Os artigos de [Fraga-Lamas et al. 2019], [Khattak et al. 2019], [Younes & Boukerche 2020] e [Ahmed et al. 2024] abordam a utilização de arquiteturas distribuídas para semáforos inteligentes, destacando o uso de *LPWANs* (*Low Power Wide Area Networks*) e redes veiculares como *VANETs* e *Veicular Clouds*. A ideia central desses trabalhos é permitir uma comunicação eficiente entre sensores, veículos e controladores de tráfego, além de garantir o controle descentralizado dos semáforos. As principais contribuições incluem o aumento da cobertura e a redução de latência através do uso de tecnologias como *LoRaWAN* e *5G/D2D* para interconectar dispositivos e sensores de tráfego. A integração com *IoT* facilita a automação da gestão de tráfego, enquanto o uso de computação em névoa (*fog computing*) permite o processamento local e rápido dos dados. No entanto, as limitações apontadas incluem o alto custo da infraestrutura de sensores em larga escala

e a dificuldade de implementação em redes reais, especialmente em áreas urbanas de alta densidade.

Bloco 2: Técnicas de Aprendizado de Máquina para Otimização de Semáforos

Nos artigos de [Mushtaq et al. 2023], [Yang et al. 2022], [Kumar et al. 2021] e [Muntean 2022], o uso de aprendizado de máquina (*ML*), especialmente *Reinforcement Learning (RL)* e *Multi-Agent Systems (MAS)*, tem sido uma abordagem popular para otimizar o controle de semáforos. Esses métodos permitem que os semáforos ajustem dinamicamente seus ciclos de acordo com o fluxo de tráfego em tempo real. As principais vantagens incluem a capacidade de realizar ajustes dinâmicos e a coordenação entre múltiplos semáforos, o que melhora a fluidez do tráfego e reduz os congestionamentos. O uso de sistemas de inferência *fuzzy*, combinados com *RL*, também permite decisões mais rápidas e precisas, levando em consideração parâmetros como o fluxo de veículos e as prioridades de emergência. No entanto, o alto custo computacional do treinamento de modelos de *RL* e a necessidade de dados em tempo real são limitações importantes, pois a qualidade dos dados pode afetar a precisão das decisões.

Bloco 3: Aplicações de Visão Computacional e *Deep Learning* para Semáforos Inteligentes

No campo de visão computacional e *Deep Learning (DL)*, os artigos de [Hazarika et al. 2024], [Khan et al. 2021], [Alsheikhy et al. 2023], [Tchuitcheu et al. 2020] e [Singh et al. 2021] apresentam o uso de câmeras e sensores visuais para a detecção de veículos e pedestres, uma técnica central para otimizar os tempos de semáforo. O modelo *YOLO (You Only Look Once)* é amplamente utilizado para detecção em tempo real, contando veículos e ajustando os tempos de luz verde conforme a intensidade do tráfego. As principais vantagens observadas incluem a detecção dinâmica de objetos e a priorização de veículos de emergência. Além disso, a utilização de *Generative Adversarial Networks (GANs)* ajuda a melhorar a robustez dos modelos, especialmente em condições adversas de tráfego. O uso de *edge computing* também permite um processamento mais rápido das imagens e decisões de controle. No entanto, as limitações incluem o alto custo de *hardware* necessário para as câmeras e o impacto que as condições climáticas adversas, como chuva ou neblina, podem ter na performance da visão computacional.

Bloco 4: Soluções Baseadas em *Blockchain* e Segurança

Os artigos de [Zeng et al. 2020] e [Khattak et al. 2019] exploram o uso de *blockchain* para aumentar a segurança e garantir a integridade dos dados nos sistemas de semáforos inteligentes. A arquitetura distribuída do *blockchain* elimina a necessidade de um controle centralizado, o que melhora a resiliência do sistema e a transparência das operações. Com o uso de contratos inteligentes, o sistema se torna mais confiável, minimizando manipulações de dados entre semáforos e sensores. No entanto, a sobrecarga computacional e a escalabilidade são desafios importantes, pois o uso de *blockchain* pode aumentar o custo computacional e a latência, o que precisa ser otimizado, especialmente para redes de semáforos em grande escala.

Bloco 5: Prototipagem e Testes em Campo

Enquanto muitos dos artigos analisados utilizam simulações para validar suas ideias, alguns, como [Hazarika et al. 2024] e [Mushtaq et al. 2023], avançaram para a prototipagem real. Esses testes são essenciais para validar soluções em um ambiente urbano real, no qual as condições de tráfego podem variar significativamente. A validação em campo traz maior confiabilidade nos resultados, permitindo ajustes finos em tempo real. Um exemplo de sucesso foi o teste de semáforos inteligentes em Gwalior, Índia, que demonstrou a escalabilidade da solução. No entanto, a replicabilidade em diferentes cidades com infraestrutura variável é um desafio, já que os sistemas precisam ser ajustados para diferentes realidades de tráfego e tecnologia.

Baseados nos blocos de discussão foram respondidas as 5 questões de pesquisa propostas.

Q1) Quais são as principais contribuições?

Diversos trabalhos deslocam o processamento para camadas *fog* e *edge*, reduzindo latência e tráfego de rede, conforme demonstrado em [Fraga-Lamas et al. 2019] e em [Guillen-Pérez 2021]. [Hazarika et al. 2024] e [Alsheikhy et al. 2024] mostram que técnicas de *pruning* e quantização viabilizam modelos de aprendizado de máquina leves em dispositivos embarcados, com

desempenho comparável a soluções baseadas em nuvem. [Arora et al. 2024], [Mushtaq et al. 2023] e [Muntean 2022] combinam meta-heurísticas híbridas e esquemas de aprendizado por reforço multi-agente para ajustar dinamicamente tempos de semáforo. [Zeng et al. 2020] exploram *blockchain* para garantir integridade e auditabilidade dos dados de controle de tráfego, enquanto [Yang et al. 2022] propõem fusão multimodal de câmeras, loops indutivos e sensores de presença para alimentar agentes de *Q-learning* mais robustos.

Q2) Como os métodos propostos se comparam com abordagens do estado-da-arte (eficiência e robustez)?

Em *hardware* restrito, certos modelos alcançam inferências de até ~200 FPS, superando SSD e *Faster-R-CNN*, conforme [Hazarika et al. 2024] e [Alsheikhy et al. 2024]. Métodos de aprendizado por reforço híbrido relatam ganhos de reward entre 15 % e 30 % sobre *Q-learning* puro ou *FRAP* [Kumar et al. 2021] [Mushtaq et al. 2023]. Em simulações urbanas, esses esquemas podem reduzir em até 40 % os tempos de espera em relação a semáforos estáticos [Kumar et al. 2021] [Sachan & Kumar 2023]. Porém, CNNs tendem a perder até 20 % de acurácia sob condições climáticas adversas [Muhammad et al. 2021], destacando a necessidade de adaptação às variações ambientais. O equilíbrio entre processamento local e transmissão remota chega a melhorar em cerca de 30 % a eficiência energética do sistema [Hazarika et al. 2024] [Fraga-Lamas et al. 2019].

Q3) Quais foram os desafios práticos reportados na implantação (custo, energia, manutenção)?

A validação de cobertura e confiabilidade em redes *LoRaWAN* exige testes de campo dispendiosos e demorados [Fraga-Lamas et al. 2019]. A execução de modelos de *ML* em dispositivos como *Raspberry Pi* apresenta um *trade-off* entre consumo de energia e *throughput*, como relatado por [Hazarika et al. 2024]. Soluções baseadas em *blockchain* sofrem com a sobrecarga de armazenamento, elevando custos de comunicação [Zeng et al. 2020]. A integração com semáforos legados e sistemas de emergência demanda firmware e protocolos customizados para compatibilidade com a infraestrutura pré-existente [Silva et al. 2015], [Bui et al. 2017]. Além disso, o ajuste fino de parâmetros de *duty-cycle* e potência de transmissão em arquiteturas *fog/LPWAN* requer constante calibração para equilibrar latência e confiabilidade [Fraga-Lamas et al. 2019].

Q4) Quais limitações cada artigo reconhece (carga de processamento, generalização, necessidade de calibração)?

Muitos autores apontam que modelos de *CNN* profundos não são viáveis em tempo real sem quantização ou *hardware* especializado, inviabilizando sua adoção em dispositivos comuns [Alsheikhy et al. 2024], [Khan et al. 2021]. Há também falta de generalização entre cenários distintos, exigindo retreinamento ou recalibração sempre que se muda o ambiente de aplicação [Anagnostopoulos et al. 2021], [Kumar et al. 2021]. Sistemas distribuídos demandam calibração contínua de sensores e *thresholds*, sob o risco de degradação de desempenho [Silva et al. 2015], [Tchuitcheu et al. 2020]. Por fim, a sensibilidade ao ruído e a falhas pontuais nos sensores impõe a necessidade de filtros adicionais ou de redundância de fontes de dados para garantir a robustez do controle de tráfego [Tchuitcheu et al. 2020], [Yang et al. 2022].

Q5) Como esses sistemas contribuem para metas de cidades inteligentes (sustentabilidade, redução de congestionamentos)?

As abordagens adaptativas conseguem reduzir em até 40 % os congestionamentos ao ajustar dinamicamente os ciclos semafóricos [Kumar et al. 2021], [Sachan & Kumar 2023]. O deslocamento do processamento para a borda resulta em economia de energia da ordem de 25–30 % e em menor emissão de CO₂, conforme evidenciam [Hazarika et al. 2024] e [Guillen-Pérez 2021]. A priorização de veículos de emergência e a definição de corredores verdes aumentam a segurança viária e a fluidez do tráfego [Muntean 2022], [Singh et al. 2021]. Além disso, o design modular e replicável dessas arquiteturas facilita sua adoção em diferentes malhas urbanas [Ahmed et al. 2024], [Guillen-Pérez 2021], e a integração com fontes renováveis em nós de *IoT* promove a sustentabilidade energética das cidades [Ahmed et al. 2024].

4. Conclusão

Responder às questões de pesquisa (Q1-Q5) permitiu concluir que essa revisão de literatura evidenciou que os estudos sobre semáforos inteligentes vêm se concentrando em três grandes frentes: otimização do fluxo de tráfego, segurança viária e controle adaptativo baseado em lógica difusa.

Do ponto de vista metodológico, destacam-se propostas que combinam modelos de aprendizado de máquina – especialmente *CNNs* e arquiteturas híbridas *GRASP-VNS* – com a ferramenta de Excel de avaliação que considera métricas de impacto (fator de impacto, citações e idade de publicação) para ranqueamento de soluções [Borges et al. 2023], [Anagnostopoulos et al., 2021]. Em termos de contribuições, os estudos relatam melhorias expressivas na redução de congestionamentos (até 40%) e no consumo de energia (até 30%) por meio de semáforos adaptativos e processamento local em nós *IoT* [Kumar et al. 2021], [Hazarika et al. 2024].

Contudo, a implantação prática enfrenta desafios relevantes: a integração com sistemas legados e de emergência requer *firmware* personalizado [Silva et al. 2015], [Bui et al. 2017], enquanto modelos profundos demonstram sobrecarga computacional que impede o funcionamento em tempo real sem quantização ou simplificação [Khan et al. 2021], [Alsheikhy et al. 2024]. Além disso, há limitações de generalização entre diferentes cenários, exigindo retreinamento contínuo e calibração de *thresholds* [Anagnostopoulos et al. 2021], [Tchuitcheu et al. 2020], bem como sensibilidade ao ruído de sensores que demanda filtragem adicional.

Na perspectiva das cidades inteligentes, as soluções apresentadas promovem diretamente a sustentabilidade e a mobilidade urbana, ao priorizar corredores verdes e garantir prioridade a veículos de emergência [Muntean 2022] [Singh et al. 2021]. Além disso, mostram viabilidade de integração com fontes de energia renovável [Ahmed et al. 2024]. Para avançar nesse campo, é fundamental desenvolver modelos mais leves para *edge devices*, adotar métricas de avaliação padronizadas e conduzir testes em ambientes reais, de modo a comprovar a robustez e a escalabilidade antes da implementação em larga escala.

A literatura sobre controle de tráfego inteligente revela lacunas importantes que representam obstáculos à sua adoção em larga escala. A maioria dos estudos recorre a simulações ou pilotos de pequena abrangência, faltando validação contínua em malhas urbanas reais [Muntean 2022] [Mushtaq et al. 2023] [Fraga-Lamas et al. 2019] [Guillen-Pérez 2021]. Além disso, há escassez de *benchmarks* e métricas padronizadas, o que reduz a reprodutibilidade e dificulta comparações; modelos de *ML/RL* também apresentam generalização limitada entre cenários, frequentemente exigindo retreinamento ou calibração [Kumar et al., 2021] [Mushtaq et al. 2023] [Anagnostopoulos et al. 2021]. A robustez frente a condições adversas (chuva, neblina, baixa luminosidade), a ausência de garantias formais de latência para aplicações críticas e a escalabilidade de soluções multi-agente continuam pouco demonstradas [Muhammad et al. 2021] [Tchuitcheu et al. 2020] [Hazarika et al. 2024]. Por fim, aspectos práticos: interoperabilidade com infraestrutura legada, análise de custo-benefício, privacidade e segurança contra ataques reais, sustentabilidade energética ao longo do ciclo de vida, disponibilidade de artefatos reprodutíveis e explicabilidade dos modelos, permanecem lacunas relevantes para pesquisa e implantação [Silva et al. 2015] [Bui et al., 2017] [Zeng et al. 2020] [Khattak et al. 2019] [Ahmed et al. 2024].

Referências

- Ahmed, Rana, et al. “Navigating Urban Congestion: A Comprehensive Strategy Based on an Efficient Smart IoT Wireless Communication for PV Powered Smart Traffic Management System”. *PLOS ONE*, vol. 19, nº 10, outubro de 2024, p. e0310002. *PLoS Journals*, <https://doi.org/10.1371/journal.pone.0310002>.
- Akopov, Andranik S., e Levon A. Beklaryan. “Traffic Improvement in Manhattan Road Networks With the Use of Parallel Hybrid Biobjective Genetic Algorithm”. *IEEE Access*, vol. 12, 2024, p. 19532–52. *IEEE Xplore*, <https://doi.org/10.1109/ACCESS.2024.3361399>.

- Alsheikhy, Ahmed A., et al. "A Novel Intelligent Smart Traffic System Using a Deep-Learning Architecture". *Multimedia Tools and Applications*, vol. 83, nº 13, abril de 2024, p. 37913–26. link-springer-com.ez280.periodicos.capes.gov.br, <https://doi.org/10.1007/s11042-023-17003-3>.
- Anagnostopoulos, Theodoros, et al. "Challenges and Solutions of Surveillance Systems in IoT-Enabled Smart Campus: A Survey". *IEEE Access*, vol. 9, 2021, p. 131926–54. *IEEE Xplore*, <https://doi.org/10.1109/ACCESS.2021.3114447>.
- Arora, Parul, et al. "A Novel and Optimised Thread-Based Virtual Traffic Light Framework: OPTIMIZED VIRTUAL TRAFFIC LIGHT FRAMEWORK". *Journal of Scientific & Industrial Research (JSIR)*, vol. 83, nº 10, 10, outubro de 2024, p. 1095–103. or.niscpr.res.in, <https://doi.org/10.56042/jsir.v83i10.7710>.
- Borges, Jucelina Leandro, et al. "FERRAMENTA FERRAMENTA COMPUTACIONAL EM EXCEL: UMA PROPOSTA DE METODOLOGIA PARA SELEÇÃO DE ARTIGOS CIENTÍFICOS RELEVANTES". *Open Science Research X*, organizado por Editora Científica Digital, 1º ed, Editora Científica Digital, 2023, p. 1024–38. *DOI.org (Crossref)*, <https://doi.org/10.37885/230111849>.
- Bui, Khac-Hoai Nam, et al. "Game Theoretic Approach on Real-Time Decision Making for IoT-Based Traffic Light Control". *Concurrency and Computation: Practice and Experience*, vol. 29, nº 11, 2017, p. e4077. *Wiley Online Library*, <https://doi.org/10.1002/cpe.4077>.
- Cruz-Piris, Luis, et al. "Optimized Sensor Network and Multi-Agent Decision Support for Smart Traffic Light Management". *Sensors*, vol. 18, nº 2, 2, fevereiro de 2018, p. 435. www.mdpi.com, <https://doi.org/10.3390/s18020435>.
- Design and Experimental Validation of a LoRaWAN Fog Computing Based Architecture for IoT Enabled Smart Campus Applications*. <https://www.mdpi.com/1424-8220/19/15/3287>. Acesso em 13 de maio de 2025.
- Dimon, Catalin, et al. "Optimization of Road Traffic Using Intelligent Traffic Light Systems". *INTERNATIONAL JOURNAL OF COMPUTERS COMMUNICATIONS & CONTROL*, vol. 17, nº 4, 4, julho de 2022. univagora.ro, <https://doi.org/10.15837/ijccc.2022.4.4866>.
- Hazarika, Anakhi, et al. "Edge ML Technique for Smart Traffic Management in Intelligent Transportation Systems". *IEEE Access*, vol. 12, 2024, p. 25443–58. *IEEE Xplore*, <https://doi.org/10.1109/ACCESS.2024.3365930>.
- Intelligent IoT systems for traffic management: A practical application - Guillen-Perez - 2021 - IET Intelligent Transport Systems - Wiley Online Library*. <https://ietresearch-onlinelibrary-wiley-com.ez280.periodicos.capes.gov.br/doi/10.1049/itr2.12021>. Acesso em 13 de maio de 2025.
- Khan, Sulaiman, et al. "Smart Object Detection and Home Appliances Control System in Smart Cities". *Computers, Materials & Continua*, vol. 67, nº 1, 2021, p. 895–915. www.techscience.com, <https://doi.org/10.32604/cmc.2021.013878>.

- Khattak, Hasan Ali, et al. "Toward Integrating Vehicular Clouds with IoT for Smart City Services". *IEEE Network*, vol. 33, n° 2, março de 2019, p. 65–71. *IEEE Xplore*, <https://doi.org/10.1109/MNET.2019.1800236>.
- Kumar, Neetesh, et al. "Fuzzy Inference Enabled Deep Reinforcement Learning-Based Traffic Light Control for Intelligent Transportation System". *IEEE Transactions on Intelligent Transportation Systems*, vol. 22, n° 8, agosto de 2021, p. 4919–28. *IEEE Xplore*, <https://doi.org/10.1109/TITS.2020.2984033>.
- Muhammad, Khan, et al. "Deep Learning for Safe Autonomous Driving: Current Challenges and Future Directions". *IEEE Transactions on Intelligent Transportation Systems*, vol. 22, n° 7, julho de 2021, p. 4316–36. *IEEE Xplore*, <https://doi.org/10.1109/TITS.2020.3032227>.
- Muntean, Maria Viorela. "Multi-Agent System for Intelligent Urban Traffic Management Using Wireless Sensor Networks Data". *Sensors*, vol. 22, n° 1, 1, janeiro de 2022, p. 208. *www.mdpi.com*, <https://doi.org/10.3390/s22010208>.
- Mushtaq, Anum, et al. "Multi-Agent Reinforcement Learning for Traffic Flow Management of Autonomous Vehicles". *Sensors*, vol. 23, n° 5, 5, janeiro de 2023, p. 2373. *www.mdpi.com*, <https://doi.org/10.3390/s23052373>.
- Pagani, Regina Negri, et al. "Avanços na composição da Methodi Ordinatio para revisão sistemática de literatura". *Ciência da Informação*, vol. 46, n° 2, 2, 2017. *revista.ibict.br*, <https://doi.org/10.18225/ci.inf.v46i2.1886>.
- Pereira, Valdecy, et al. "pyBibX -- A Python Library for Bibliometric and Scientometric Analysis Powered with Artificial Intelligence Tools". *Data Technologies and Applications*, janeiro de 2025. *arXiv.org*, <https://doi.org/10.1108/DTA-08-2023-0461>.
- Sachan, Anuj, e Neetesh Kumar. "SDN Control-Enabled and Time-Quantum-Driven Max-Pressure Approach for Intersection Management in Smart City". *IEEE Systems Journal*, vol. 17, n° 1, março de 2023, p. 1694–702. *IEEE Xplore*, <https://doi.org/10.1109/JSYST.2022.3211933>.
- Silva, Cristiano M., et al. "Smart Traffic Light for Low Traffic Conditions". *Mobile Networks and Applications*, vol. 20, n° 2, abril de 2015, p. 285–93. *Springer Link*, <https://doi.org/10.1007/s11036-015-0571-x>.
- Singh, Rajesh, et al. "Highway 4.0: Digitalization of highways for vulnerable road safety development with intelligent IoT sensors and machine learning". *Safety Science*, vol. 143, novembro de 2021, p. 105407. *ScienceDirect*, <https://doi.org/10.1016/j.ssci.2021.105407>.
- Tchuitcheu, Willy Carlos, et al. "Internet of smart-cameras for traffic lights optimization in smart cities". *Internet of Things*, vol. 11, setembro de 2020, p. 100207. *ScienceDirect*, <https://doi.org/10.1016/j.iot.2020.100207>.
- Yang, Xiaoxian, et al. "An Information Fusion Approach to Intelligent Traffic Signal Control Using the Joint Methods of Multiagent Reinforcement Learning and Artificial Intelligence of Things". *IEEE Transactions on Intelligent Transportation Systems*, vol. 23, n° 7, julho de 2022, p. 9335–45. *IEEE Xplore*, <https://doi.org/10.1109/TITS.2021.3105426>.

Younes, Maram Bani, e Azzedine Boukerche. “Traffic Efficiency Applications over Downtown Roads: A New Challenge for Intelligent Connected Vehicles”. *ACM Comput. Surv.*, vol. 53, nº 5, setembro de 2020, p. 102:1-102:30. *ACM Digital Library*, <https://doi.org/10.1145/3403952>.

Zeng, Pengjie, et al. “A Scheme of Intelligent Traffic Light System Based on Distributed Security Architecture of Blockchain Technology”. *IEEE Access*, vol. 8, 2020, p. 33644–57. *IEEE Xplore*, <https://doi.org/10.1109/ACCESS.2020.2972606>.