

## Modelagem e Simulação Comparativa entre Semáforo Inteligente e Tradicional para Detecção de Veículos de Urgência em Cruzamento Urbano

Luis Fernando Castilho Maschi<sup>1,3</sup> , Edivaldo Pastori Valentini<sup>2,3</sup> ,  
Elson Avallone<sup>3</sup> , Fábio Luiz Viana<sup>3</sup> , Sarita Mazzini Bruschi<sup>2</sup> ,  
Rodolfo Ipolito Meneguette<sup>2</sup> 

<sup>1</sup> Programa de Pós-Graduação em Ciência da Computação  
Universidade Estadual Paulista (UNESP) – IBILCE  
São José do Rio Preto – SP – Brasil

<sup>2</sup>Instituto de Ciências Matemáticas e de Computação (ICMC)  
Universidade de São Paulo (USP)  
São Carlos – SP – Brasil

<sup>3</sup>Instituto Federal de São Paulo (IFSP) – Campus Catanduva  
Catanduva – SP – Brasil

luis.maschi@unesp.br, edivaldopv@usp.br  
{elson.avallone, viana.fabio}@ifsp.edu.br  
{sarita, meneguette}@icmc.usp.br

**Abstract.** *Emergency vehicles face difficulties in providing assistance on urban roads. This complexity demands solutions that can improve and optimize traffic flow at intersections during rescue operations. The resources of Intelligent Transportation Systems integrated with Internet of Things technologies, embedded in traffic lights, establish a Smart Traffic Light (STL). STL solutions contribute to monitoring and managing intersections, freeing up passage for emergency vehicles. A ten-minute delay in pre-hospital care increases the chance of death by 9%. In Brazil, out of 44,822 SAMU-192 incidents, only 11% of calls occurred in less than five minutes, while 62% exceeded 10 minutes. Given this problem, this work carried out an analytical modeling and comparative analysis by simulation (SUMO) between a traditional traffic light and a smart traffic light for prioritizing the crossing of emergency vehicles at a realistic urban intersection. An experimental model was also implemented to physically reproduce the investigated scenario. The results demonstrated consistent gains for emergency vehicles, reducing the total response time to 5.7 seconds, with minimal trade-offs for regular vehicles at the intersection.*

**Resumo.** *Veículos de urgência enfrentam dificuldades na prestação de socorro em vias urbanas. Esta complexidade, exige soluções que possam melhorar e otimizar o tráfego para travessias de cruzamentos durante o resgate. Os recursos dos Sistemas de Transporte Inteligente integrados com tecnologias da Internet das Coisas, embarcados aos semáforos, estabelecem um Semáforo Inteligente (Smart Traffic Light - STL). Soluções STL contribuem em monitorar e gerenciar cruzamentos, liberando a passagem de veículos de urgência. Dez minutos de atraso no atendimento pré-hospitalar aumentam a chance de óbito em 9%. No Brasil em 44.822 ocorrências do SAMU-192, apenas 11% dos atendimentos ocorreram em menos de cinco minutos, enquanto 62% ultrapassaram 10 minutos. Diante desse problema, este trabalho realizou uma modelagem analítica e análise comparativa por simulação (SUMO) entre semáforo tradicional e semáforo inteligente para priorização da travessia de veículos de urgência*

*em cruzamento urbano realístico. Também foi implementada uma maquete experimental, para reproduzir fisicamente o cenário investigado. Os resultados demonstraram ganhos consistentes para os veículos de urgência, reduzindo o tempo total no atendimento para 5,7 seg e com mínimos impactos (trade-offs) para os veículos comuns do cruzamento.*

## 1. Introdução

A Internet das Coisas (*Internet of Things* - IoT) possibilita a interconexão de dispositivos físicos à internet, permitindo coleta, processamento e compartilhamento de dados em tempo real [Maschi et al. 2018, Choudhary 2024]. No contexto urbano, essa infraestrutura sustenta o conceito de Cidades Inteligentes (*Smart Cities*), que integra tecnologias digitais aos serviços públicos com o objetivo de promover eficiência operacional, sustentabilidade e melhoria da qualidade de vida [Elassy et al. 2024]. No âmbito da mobilidade urbana, as Redes Veiculares *Ad Hoc* (*Vehicle Ad Hoc Networks* - VANETs) viabilizam a comunicação veículo-veículo (V2V) e veículo-infraestrutura (V2I), constituindo base para Sistemas de Transporte Inteligente (*Intelligent Transportation Systems* - ITS) [Valentini et al. 2023, Meneguette et al. 2023]. Entre os componentes estratégicos desses sistemas destacam-se os semáforos inteligentes (*Smart Traffic Lights* - STL), capazes de adaptar dinamicamente seus ciclos de sinalização de acordo com as condições de tráfego [Tomar et al. 2022, Khang and Singh 2025].

O tráfego urbano apresenta inúmeros desafios e complexidades. Semáforos convencionais com temporização fixa possuem limitações significativas, especialmente em situações de urgência, onde o atraso no atendimento de socorro pode causar sérios riscos de vida ou até mortes. Um dos desafios mais críticos nesse contexto refere-se ao deslocamento de veículos de resgates com mínimo de tempo de chegada a unidade de pronto socorro. Em cruzamentos controlados por semáforos convencionais de tempo fixo, esses veículos frequentemente enfrentam atrasos que podem comprometer o tempo de resposta e impactar diretamente a eficiência do atendimento do resgate [Hao et al. 2024]. Na França o estudo de [Gauss et al. 2019] analisou 10.216 pacientes e demonstrou que a cada 10 minutos adicionais de atendimento pré-hospitalar a chance de óbito aumenta em 9%. No Brasil, o desempenho operacional do SAMU-192 evidencia déficit crítico, conforme análise de [Forastieri Filho et al. 2022], em 44.822 ocorrências, verificaram que apenas 11% dos atendimentos tiveram tempo-resposta inferior a 5 minutos, ao passo que 62% ultrapassaram o limite de 10 minutos - sendo 26% classificados como “péssimo”, com chegada superior a 20 minutos.

Mediante a estes desafios e complexidades em otimizar e minimizar o tempo de atendimento do socorro em travessias de cruzamentos urbanos, este estudo é motivado na investigação e implantação de um semáforo inteligente com detecção de veículos de urgência. Considerando uma via urbana de sentido único em direção a um hospital, foi realizada uma análise comparativa entre dois controles semaforicos (tradicional e inteligente). Por meio de técnicas de avaliação de desempenho de sistemas computacionais, foram aplicados procedimentos de modelagem e simulação para comparar a efetividade das operações destes dois modelos semaforicos. Os resultados demonstraram a redução do tempo total de resgate em 5,7 segundos a menos do que no semáforo tradicional e mínimos impactos (*trade-offs*) aos demais veículos do cruzamento. As principais contribuições desta pesquisa são:

- Modelagem analítica de operações de dois modelos de semáforos (tradicional e inteligente) no gerenciamento da travessia de cruzamento urbano como uma rede de filas com centro de serviço e duas classes de clientes (veículos comuns e veículos prioritários);

- Avaliação experimental e comparativa por meio de técnica de simulação utilizando um simulador de mobilidade urbana aplicado em um cruzamento urbano realístico;
- Implementação de um protótipo experimental com tecnologias IoT de baixo custo para validação empírica e prática do cenário investigado;
- Validação de execuções pareadas de simulações para comparação robusta entre os cenários tradicional e inteligente, validando o ganho de tempo durante a passagem de veículo de urgência.

A estrutura deste estudo é organizada em: Seção 2, discute os trabalhos relacionados com esta linha de pesquisa. Seção 3 descreve a metodologia e etapas da modelagem, simulação do cenário urbano, dados, métricas e maquete experimental. Seção 4 apresenta os resultados comparativos entre semáforo tradicional e inteligente. Seção 5 conclui e discute as limitações do estudo e aponta trabalhos futuros.

## 2. Trabalhos Relacionados

A priorização de veículos de emergência em Sistemas de Transporte Inteligente tem sido amplamente investigada no contexto da mobilidade urbana em Cidades Inteligentes. Diferentes abordagens metodológicas têm sido propostas, variando desde modelagens formais de controle semaforico até soluções baseadas em aprendizado de máquina e visão computacional.

O uso de aprendizado de máquina para controle adaptativo de sinais tem sido amplamente explorado. Em [SenthilPrabha et al. 2023] aplicaram Deep Q-Network (DQN) integrado ao simulador SUMO para substituir o controle tradicional baseado em ciclos fixos, demonstrando redução no atraso total dos veículos em cenários simulados.

O estudo de [Prabha et al. 2025] propuseram um método baseado em *ensemble learning* para coordenação distribuída de múltiplas interseções, com foco na redução do atraso médio e do comprimento de filas. A abordagem apresenta menor sobrecarga computacional em comparação a modelos profundos, porém é direcionada à otimização em nível de rede.

A proposta de [Vandana et al. 2025] introduz uma arquitetura de dupla camada baseada em comunicação embarcada e modelos de aprendizado de máquina executados na borda, utilizando Random Forest e Hidden Markov Models para prever a trajetória de veículos de emergência. Apesar dos ganhos reportados em tempo de resposta, a solução exige infraestrutura adicional e integração entre múltiplos módulos embarcados.

O uso de visão computacional para detecção de veículos e ajuste dinâmico de sinais baseados em YOLO têm sido empregados para identificação de veículos de emergência e estimativa de densidade de tráfego em tempo real [Divyesh et al. 2024]. De forma semelhante, em [Shilpa et al. 2025] integraram câmeras de vigilância, modelos treinados em nuvem e aplicações móveis para preempção baseada na estimativa de chegada.

A análise da literatura, apresenta boas contribuições experimentais, no entanto indicam que grande parte das soluções recentes concentram-se em soluções que dependem de infraestrutura de processamento contínuo de imagens e, em alguns casos, conectividade com serviços em nuvem, fatores que aumentam custos operacionais e complexidades de implantação. A incorporação de modelos avançados de aprendizado de máquina e visão computacional, requerem maior capacidade computacional, infraestrutura adicional ou coordenação de múltiplas interseções.

Em comparação aos trabalhos relacionados, esta pesquisa conduziu integralmente a execução de ferramentas e sistemas homologados para os processos de: modelagem,

**Tabela 1. Análise comparativa entre trabalhos relacionados e pesquisa desenvolvida**

Trabalho	Modelagem	Simulação	Mapa Realístico	Impacto ( <i>trade-off</i> )	Prototipação
[SenthilPrabha et al. 2023]	✓	✓	✓	✓	
[Divyesh et al. 2024]		✓		✓	
[Prabha et al. 2025]	✓	✓		✓	
[Vandana et al. 2025]	✓	✓		✓	✓
[Shilpa et al. 2025]	✓			✓	✓
<b>Este trabalho</b>	✓	✓	✓	✓	✓

simulação utilizando o simulador de mobilidade urbana - SUMO (*Simulation of Urban MObility*) [Lopez et al. 2018] e aplicação de mapa realístico extraído do OpenStreetMap [OpenStreetMap 2026]. Requisitos que sustentaram e validaram os dados de forma realística inerente ao cenário avaliado. Nas contribuições anteriores, nenhuma destas realizaram esta integração, somente a utilização de ferramentas de maneira isolada. Sendo assim, este estudo validou uma arquitetura mais simples e determinística para priorização de veículos de urgência em interseções individuais, especialmente em cenários urbanos onde soluções de baixo custo e fácil implantação são desejáveis. Outra ponto importante foi o desenvolvimento da maquete experimental e física como estudo de caso, por meio de dispositivos IoT de baixo custo.

### 3. Desenvolvimento Experimental: Modelagem e Simulação Comparativa entre Semáforo Inteligente e Tradicional

Para validar o uso de STL na otimização do tráfego de veículos de urgência, minimizando o tempo total de resgate (socorro) em comparação ao uso semáforo tradicional, esta pesquisa conduziu a seguinte metodologia de desenvolvimento.

#### 3.1. Modelagem por Redes de Filas com Centro de Serviço

Redes de filas constituem um ramo da probabilidade aplicado ao estudo da formação de filas de solicitantes de serviço diante de recursos com capacidade limitada [Kleinrock 1975]. Em uma abstração conceitual, uma rede de tráfego urbano pode ser interpretada como uma rede de filas, na qual os cruzamentos representam os principais gargalos do sistema. Nesse contexto, os veículos deslocam-se entre aproximações, acumulam-se em filas durante restrições de passagem e deixam a rede ao atingirem seus destinos. Em interseções semaforizadas, o controle do semáforo regula os instantes em que cada movimento recebe atendimento, influenciando diretamente a formação e a dissipação das filas [Oblakova et al. 2022].

Assim, neste trabalho, o cruzamento foi modelado como um sistema aberto de filas com um centro de serviço, no qual: (a) cada aproximação ao semáforo possui uma fila (*buffer*) de veículos; (b) a região de conflito do cruzamento constitui o centro de serviço, cuja capacidade é modulada pelas fases semaforicas; (c) distinguem-se duas classes de veículos para fins de interpretação do sistema e implementação da lógica de prioridade na simulação: (i) classe N (Normal): veículos comuns e (ii) classe E (Emergência): ambulâncias. A principal funcionalidade deste centro de serviço é o direito de passagem concedido pelo semáforo. Quando uma fase recebe indicação verde, o sistema passa a atender a fila correspondente, promovendo o escoamento dos veículos. Quando a fase fecha, o atendimento é interrompido e ocorre acúmulo de veículos na fila. Um modelo de atendimento cíclico, alternando períodos de serviço e de interrupção.

Para cada aproximação  $i$ , definem-se:

- $\lambda_i$ : taxa média de chegada (veículos/s), derivada dos fluxos configurados no SUMO;
- $\mu_i$ : taxa de serviço efetiva (veículos/s), aproximada como a capacidade de descarga ponderada pela fração de verde no ciclo.

A taxa de serviço efetiva pode ser expressa por:

$$\mu_i \approx s_i \cdot \frac{g_i}{C}, \quad (1)$$

em que  $s_i$  é a vazão de saturação da aproximação  $i$ ,  $g_i$  é o tempo de verde efetivo e  $C$  é o ciclo semafórico. Quando  $s_i$  for expresso em veículos por hora, a forma equivalente em veículos por segundo é:

$$\mu_i \approx \frac{s_i}{3600} \cdot \frac{g_i}{C}. \quad (2)$$

A intensidade de utilização do sistema na aproximação  $i$  é dada por:

$$\rho_i = \frac{\lambda_i}{\mu_i}. \quad (3)$$

Valores de  $\rho_i$  próximos de 1 indicam operação mais carregada, com maior tendência à formação de filas e ao aumento dos atrasos.

No experimento considerado neste estudo, os fluxos foram configurados no SUMO como:

- **Corredor principal:** 600 veh/h

$$\lambda_{\text{corr}} = \frac{600}{3600} = 0,1667 \text{ veh/s} \quad (4)$$

- **Via transversal:** 300 veh/h

$$\lambda_{\text{cross}} = \frac{300}{3600} = 0,0833 \text{ veh/s} \quad (5)$$

Isso equivale, em média, à chegada de aproximadamente 1 veículo a cada  $\sim 6$  s no corredor principal ( $1/\lambda_{\text{corr}} \approx 6$  s) e de 1 veículo a cada  $\sim 12$  s na via transversal ( $1/\lambda_{\text{cross}} \approx 12$  s), durante o horizonte em que os fluxos permanecem ativos.

No cenário de semáforo tradicional, o ciclo adotado foi de  $C = 90$  s, com verde efetivo de  $g = 42$  s. Assim, a fração de verde do sistema é:

$$\frac{g}{C} = \frac{42}{90} = 0,4667. \quad (6)$$

Logo, para o cenário fixo, a taxa de serviço efetiva pode ser escrita como:

$$\mu_i \approx 0,4667 s_i, \quad (7)$$

se  $s_i$  estiver em veículos por segundo, ou

$$\mu_i \approx \frac{0,4667 s_i}{3600}, \quad (8)$$

se  $s_i$  estiver em veículos por hora.

### 3.2. Métricas de fila e tempo

Como aproximação analítica principal, adotou-se o modelo  $M/D/1$  para representar a fase de descarga da fila durante o verde. Segundo a notação de Kendall,  $M$  indica que o processo de chegadas é markoviano, usualmente modelado por chegadas Poisson;  $D$  indica que o tempo de serviço é determinístico, isto é, aproximadamente constante; e  $1$  indica a existência de um único servidor ou centro de atendimento [Kleinrock 1975]. No contexto deste estudo, essa formulação é empregada como aproximação analítica para representar uma aproximação semaforizada em que os veículos chegam ao sistema e, durante o intervalo de verde, são atendidos por um único recurso de passagem com padrão de descarga mais regular do que no caso exponencial. Essa escolha é mais coerente com o contexto do cruzamento semaforizado, pois, durante o escoamento, o atendimento tende a apresentar menor variabilidade do que no caso exponencial [Oblakova et al. 2022],

Nesse caso, a espera média em fila é dada por:

$$W_{q,i}^{M/D/1} \approx \frac{\rho_i}{2\mu_i(1 - \rho_i)} \quad (9)$$

ou, de forma equivalente,

$$W_{q,i}^{M/D/1} \approx \frac{\lambda_i}{2\mu_i(\mu_i - \lambda_i)}. \quad (10)$$

O tempo médio no sistema é:

$$W_i^{M/D/1} \approx \frac{1}{\mu_i} + \frac{\rho_i}{2\mu_i(1 - \rho_i)}. \quad (11)$$

Em termos do número médio de veículos em fila, obtém-se:

$$L_{q,i}^{M/D/1} = \lambda_i W_{q,i}^{M/D/1} \quad (12)$$

e, de forma equivalente,

$$L_{q,i}^{M/D/1} \approx \frac{\rho_i^2}{2(1 - \rho_i)}. \quad (13)$$

Além disso, para relacionar o número médio de veículos no sistema, a taxa média de chegada e o tempo médio de permanência, utiliza-se a Lei de Little [Little 1961, Oblakova et al. 2022]:

$$L = \lambda W. \quad (14)$$

Quando  $W$  representa apenas o tempo médio em fila, a forma correspondente é:

$$L_q = \lambda W_q. \quad (15)$$

Essas expressões não substituem a simulação, que captura interações veiculares, bloqueios, acelerações, desacelerações e efeitos espaciais da rede. Seu papel é fornecer uma interpretação matemática complementar sobre como o particionamento de verde e o nível de utilização influenciam os atrasos observados.

### 3.3. Simulação no SUMO e controle via TraCI

A validação foi realizada por simulação por meio do simulador de mobilidade urbana SUMO [Lopez et al. 2018]. O controlador inteligente opera externamente via TraCI (Python 3.12), própria ferramenta do simulador, monitorando a chegada do veículo prioritário ao se aproximar 15 metros de distância do semáforo inteligente e, assim, alterando o estado do semáforo ao ocorrer a detecção (evento RFID lógico no simulador). A abstração funcional do semáforo inteligente, aplicada na simulação, é visualizada na Figura 1.

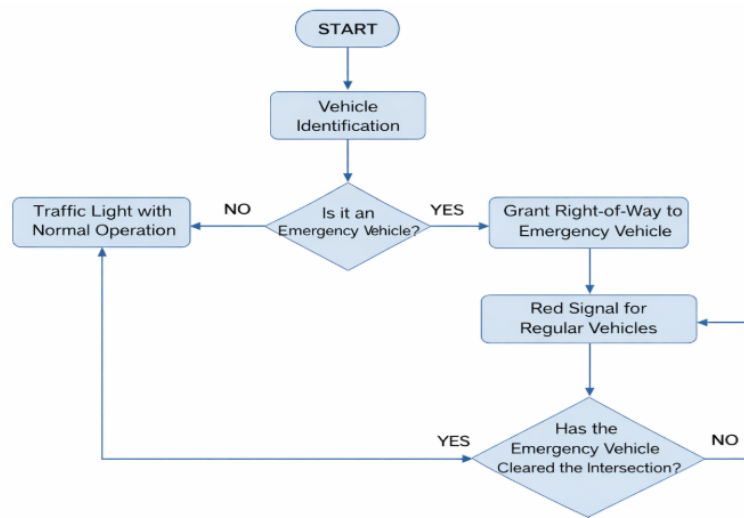



Figura 1. Abstração do funcionamento e operações do semáforo inteligente.

### 3.3.1. Ambiente urbano realístico e rede viária

Foi utilizado um recorte realístico do ambiente urbano, conforme Figura 2 (a) visão real do cruzamento (Google Maps: 21°08'26.0"S 48°58'34.4"W) e (b) mapa extraído do OpenStreetMap [OpenStreetMap 2026], convertido para rede SUMO. O cruzamento analisado (cidade Catanduva, SP, Brasil) corresponde à interseção da Rua Belém (corredor principal e hospital logo à frente na direita) × Rua Treze de Maio (via transversal).



(a) Visão realística do cruzamento até hospital. (b) Cruzamento entre as ruas Belém (corredor principal) e rua Treze de Maio (transversal) OpenStreetMap.


Figura 2. Mapa realístico Google Maps e trecho extraído do OpenStreetMap.

Duas rotas principais constituem o cruzamento: (i) rota do corredor para o hospital e (ii) rota transversal. A demanda veicular é composta por: (i) fluxos de veículos comuns no corredor e na transversal e (ii) dois veículos prioritários (ambulâncias = amb\_0 e amb\_1) por execução, inseridos na rota corredor em instantes aleatórios e controlados (janela de tempo) para simular eventos de resgate.

### 3.3.2. Dois cenários de controle semafórico

Foram estabelecidos dois cenários para simulação e validação da análise comparativa: (i) Cenário A - Tradicional (tempos fixos): o semáforo opera com ciclo fixo  $C = 90s$ , al-

ternando fases para dois conjuntos de movimentos. O programa contém *verde* de 42s + *amarelo* de 3s para um conjunto e *verde* de 42s + *amarelo* de 3s para o conjunto oposto. Assim, para cada conjunto por ciclo: *verde* = 42s, *amarelo* = 3s e *vermelho* = 45s e (ii) Cenário B - Inteligente (prioridade via detecção): implementa-se um mecanismo operacional de preempção, visualizado na Figura 3 (a).



(a) Simulação SUMO: veículo prioritário antes da detecção.

(b) SUMO: veículo prioritário detectado e semáforo liberado na via.

**Figura 3. Cenários simulador SUMO: antes e durante a detecção da ambulância.**

Ao detectar uma ambulância a até 15 metros antes da linha de retenção (aproximação do corredor ao hospital), conforme Figura 3 (b), o controlador força o estado semafórico para *verde* na via corredor e *vermelho* na via transversal, mantendo a condição até a ambulância cruzar a região do cruzamento. Em seguida, o sistema retorna ao programa de ciclo tradicional.

### 3.3.3. Planejamento experimental das execuções no SUMO

A etapa de simulação foi conduzida por meio de 30 execuções independentes, cada uma associada a uma semente (*seed*) pseudoaleatória distinta, numerada de 1 a 30. No SUMO, a pseudoaleatoriedade é controlada por um gerador do tipo *Mersenne Twister*. Para uma mesma configuração de rede, rotas e parâmetros, a execução permanece determinística quando a *seed* é mantida fixa, ou seja, a variabilidade experimental entre os *runs* foi introduzida exclusivamente pela alteração sistemática da *seed* em cada réplica. Assim, o simulador SUMO assegura simultaneamente variabilidade controlada e reprodutibilidade computacional, uma vez que qualquer execução pode ser regenerada a partir da mesma *seed* e do mesmo conjunto de arquivos de entrada [Lopez et al. 2018].

Esse procedimento segue a lógica clássica de análise de saída de simulação baseada em replicações e intervalos de confiança, bem como a estratégia de executar pares de simulações independentes para construir inferência sobre a resposta média [Law 2015, Köksalan 1991].

### 3.3.4. Algoritmo do controlador inteligente (pseudocódigo)

O controlador (Algoritmo 1), identifica veículos prioritários no corredor monitorado a uma distância de até 15 metros do semáforo. Quando uma ambulância é detectada, o estado do semáforo é alterado para priorizar sua passagem e após a travessia do cruzamento, o sistema retorna ao programa de ciclos fixos.

**Algorithm 1** Controlador inteligente via TraCI

---

**Require:** TLS\_ID, CORRIDOR\_WAY\_ID, DETECT\_DIST  
**Ensure:** Controle do semáforo

```

1: emergency_active ← False
2: while simulação ativa do
3:   SIMULATIONSTEP
4:   trigger ← detecção de ambulância no corredor
5:   if trigger then
6:     SETPRIORITYSTATE(TLS_ID)
7:     emergency_active ← True
8:   else
9:     if emergency_active then
10:      SETPROGRAM(TLS_ID, PROG_FIXO)
11:      emergency_active ← False
12:     end if
13:   end if
14: end while

```

---

**3.3.5. Parâmetros de simulação**

Na Tabela 2 são descritos os parâmetros e configurações utilizados nos experimentos no SUMO/TraCI, incluindo rede viária, rotas, demanda, controle semafórico e aspectos de reprodutibilidade (*seeds*).

**Tabela 2. Parâmetros e configurações da Simulação**

Parâmetro	Valor	Observação
Fonte da rede	OpenStreetMap	Convertida via <code>netconvert</code>
Rota corredor	<code>r_corr</code>	Correspondente à Rua Belém
Rota transversal	<code>r_cross</code>	Correspondente à Rua Treze de Maio
Comprimento da rota	530,52 m	Obtido a partir do arquivo <code>tripinfo</code>
Fluxo corredor	600 veh/h	Fluxo ativo no intervalo de 0 a 1800 s
Fluxo transversal	300 veh/h	Fluxo ativo no intervalo de 0 a 1800 s
Ambulâncias/run	2	Veículos configurados como <code>amb_0</code> e <code>amb_1</code>
Semáforo tradicional	Ciclo de 90 s	Verde de 42 s e amarelo de 3 s
Semáforo inteligente	Detecção de 15 m	Controle implementado via TraCI
Horizonte simulação	0 a 1800 s	Intervalo de geração dos veículos
Condição de parada	<code>--quit-on-end</code>	Execução mantida até o esvaziamento da rede
Número de execuções	30	Sementes pseudoaleatórias de 1 a 30
Ferramentas	SUMO + TraCI	Execução por meio de scripts em Python
Hardware Laptop	16.0 GB RAM	Intel Core(TM) i7-8550U CPU @1.80 GHz

**3.3.6. Geração dos dados, coleta e métricas analisadas**

Após as 30 execuções da simulação, os dados foram extraídos do arquivo `tripinfo-output`, que registra, para cada veículo as seguintes métricas: (a) *duration*, utilizada como indicador direto do tempo total de viagem no trecho entre o corredor analisado e o hospital; (b) *waitingTime*, é o tempo acumulado em parada involuntária, associado à retenção em filas e sinais semafóricos; (c) *timeLoss*, empregado como medida da diferença acumulada em relação ao deslocamento ideal, refletindo desacelerações, interferências operacionais e restrições impostas pela circulação [Lopez et al. 2018].

Além da análise individual das ambulâncias, foram calculadas métricas agregadas

para os veículos comuns por via de origem, distinguindo-se o corredor principal e a via transversal. Essa métrica permitiu avaliar não apenas o benefício operacional ao veículo prioritário, mas também eventuais impactos (*trade-offs*) sobre os movimentos conflitantes, especialmente em termos de atraso e perda de desempenho médio.

### 3.4. Estudo de caso experimental: Protótipo de Maquete da Arquitetura de Semáforo Inteligente

Como complemento à modelagem analítica e à avaliação por simulação, a pesquisa apresenta um estudo de caso experimental independente, implementado por meio de um protótipo físico (maquete). O objetivo foi reproduzir, em escala reduzida, o cenário urbano investigado e a lógica de operação do semáforo inteligente proposta, oferecendo uma validação prática e visual da arquitetura desenvolvida. Independente em relação à modelagem e à simulação, o protótipo preserva os elementos centrais do cenário avaliado: (a) a detecção do veículo prioritário na aproximação do cruzamento; (b) alteração dos estados semafóricos; (c) liberação temporária da via de urgência com bloqueio do fluxo conflitante. A maquete não substitui os resultados quantitativos obtidos no SUMO, mas os complementa ao evidenciar a viabilidade de implementação da lógica de prioridade em uma arquitetura embarcada de baixo custo.

Na Tabela 3 são descritos os principais componentes utilizados na construção do protótipo físico. Na implementação, o Raspberry Pi 3 Model B foi utilizado como plataforma embarcada para execução dos algoritmos de controle em Python 3.12, enquanto o leitor RFID RC522 foi responsável pela identificação dos veículos por meio de *tags*. Os semáforos em LED representaram os estados de sinalização no cruzamento, permitindo observar visualmente a comutação do sistema durante a operação.

**Tabela 3. Componentes IoT de baixo custo do protótipo (maquete)**

Componente	Descrição resumida
Raspberry Pi 3 Model B	Quad Core 1.2 GHz (64 bits), 1 GB RAM, Wi-Fi 802.11n, LAN 100 Base-T, 4 USB 2.0 e GPIO de 40 pinos.
Leitor RFID RC522 + 2 tags Mifare	Opera em 13.56 MHz e 3.3 V. Realiza a identificação do veículo prioritário.
2 semáforos LED de 8 mm	Representam os semáforos, com operação entre 3.3 V e 5 V.
6 jumpers GPIO	Realizam a interligação entre Raspberry Pi, RFID e semáforos.

Quando a *tag* associada ao veículo de emergência é detectada, o controlador aciona o modo de prioridade e altera o estado do semáforo para favorecer a travessia segura do cruzamento, conforme o Algoritmo 2, que apresenta uma lógica simplificada. Na ausência dessa condição, o sistema mantém o ciclo fixo semafórico normal.

---

#### Algorithm 2 Lógica de controle do STL baseado em RFID

---

```

1: while sistema ativo do
2:   tag ← READRFID
3:   if tag = EMERGENCY_ID then
4:     ACTIVATEEMERGENCYMODE
5:     SETSIGNALPRIORITY(corredor)
6:   else
7:     FOLLOWNORMALSIGNALCYCLE
8:   end if
9: end while

```

---

Na Figura 4 ilustra a visão geral da maquete e a representação do cenário experimental. Desse modo, o protótipo físico cumpre o papel de evidenciar, em ambiente con-

trolado, a aplicabilidade prática da arquitetura proposta para o gerenciamento de veículos urbanos de urgência. Além de reproduzir o cenário investigado, a maquete reforça que a priorização semafórica pode ser implementada com dispositivos IoT, preservando a lógica operacional validada na modelagem e na simulação.





Figura 4. Visão geral da maquete e representação do cenário experimental.

#### 4. Análise e Avaliação dos Resultados

Como as métricas adotadas neste estudo (*duration*, *waitingTime* e *timeLoss*) representam custos operacionais, menores valores indicam melhor desempenho. Assim, a efetividade do semáforo inteligente foi avaliada em termos de ganho absoluto, ganho relativo e ganho percentual.

Na Figura 5 (a) apresenta ganhos percentuais globais para a métrica *duration*. Observa-se que o efeito foi mais intenso para a *amb\_0*, correspondendo a um ganho absoluto de 5,70s e ganho percentual global de 9.91%. Para *amb\_1*, ganho absoluto de 4,33s e percentual global de 6.91%. No entanto, ambas as ambulâncias apresentaram reduções consistentes do tempo total de deslocamento sob o controle inteligente. Já na Figura 5 (b) mostra o *waitingTime* médio das ambulâncias com redução do tempo de espera no cenário STL para os dois veículos: de 12,67 s para 7,33 s na *amb\_0*, e de 17,20 s para 13,20 s na *amb\_1*, indicando a redução de tempo acumulado de parada involuntária, diretamente associado à retenção em fila e ao controle semafórico.



(a) Ganhos percentuais globais semáforo inteligente.

(b) *waitingTime*.

Figura 5. Ganhos de tempo do STL e tempo de espera: veículos de urgência.




Figura 6. Tempo total de viagem e perda de tempo: veículos de urgência.

Na Figura 6 (a) informa a duração média do total da viagem (*duration*) das ambulâncias nos dois cenários, onde o STL reduz o tempo total de deslocamento para chegar ao hospital. O veículo *amb\_0*, redução de 57,50 s para 51,80 s (ganho = 5,70 s) e para *amb\_1*, de 62,70 s para 58,37 s (ganho = 4,33 s). A métrica *timeLoss* média para as ambulâncias, visualizada na Figura 6 (b), demonstrou redução de 18,79 s para 13,12 s na *amb\_0* e de 24,06 s para 19,78 s na *amb\_1*. Reflete a perda acumulada em relação ao deslocamento ideal, mostrando que o STL não apenas reduziu paradas, mas também mitigou desacelerações e interferências ao longo da rota.

Na Figura 7 (a) resume os  $\Delta$  médios calculados como (*smart* – *trad*) para os veículos comuns, juntamente com a faixa de variação entre os valores mínimo e máximo observados. Como as métricas analisadas representam custo, valores negativos indicam melhora sob o semáforo inteligente e valores positivos indicam piora. Os resultados médios permaneceram muito próximos de zero no corredor principal, com leve acréscimo residual em *waitingTime* e *timeLoss*. Na transversal, observaram-se pequenas reduções médias em ambas as métricas. As faixas min–max evidenciam que houve variabilidade entre execuções, mas sem caracterizar degradação sistemática dos movimentos não prioritários.

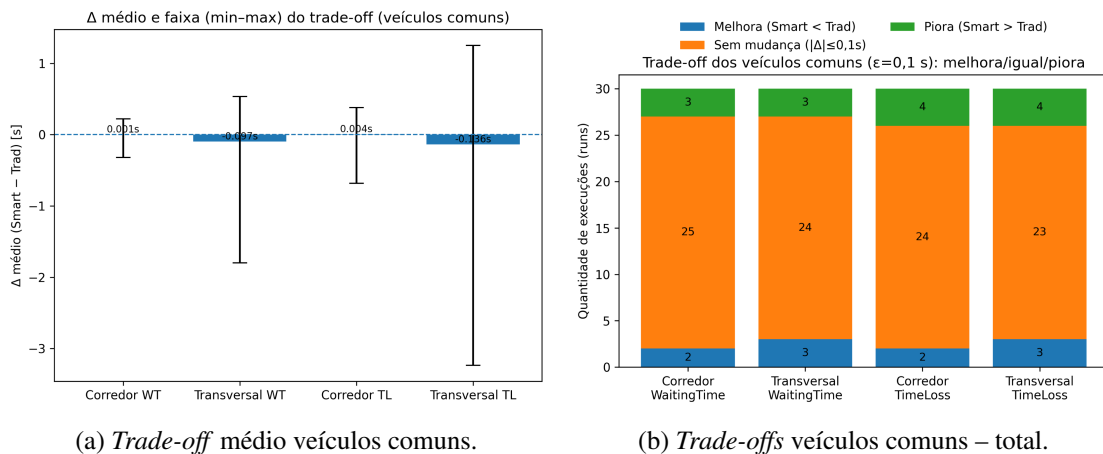


Figura 7. Trade-offs dos veículos comuns (médio e total).

Na Figura 7 (b) apresenta a classificação das 30 execuções em três categorias: (i) melhora, (ii) ausência de mudança relevante e (iii) piora, adotando-se  $\varepsilon = 0,1s$  como limiar de equivalência prática. Em todas as métricas dos veículos comuns, predominou amplamente a categoria “sem mudança”, com frequência entre 23 e 25 execuções. Os casos de melhora e piora foram minoritários e relativamente equilibrados, o que reforça

a interpretação de que a priorização semafórica produziu benefício expressivo para as ambulâncias sem impor impactos (*trade-offs*) médio relevante ao tráfego ordinário.

## 5. Conclusão

Esta pesquisa apresentou uma abordagem para priorização de veículos urbanos de urgência por meio de semáforo inteligente (STL), no contexto de Cidades Inteligentes, IoT e ITS. A pesquisa foi avaliada por modelagem analítica, simulação comparativa entre semáforo tradicional e inteligente no simulador SUMO em cenário urbano realístico. Um estudo de caso experimental independente produziu um protótipo em maquete para representar o cruzamento simulado. Resultados confirmaram que o gerenciamento realizado pelo semáforo inteligente atingiu o objetivo central do estudo, reduzindo o tempo total da prestação de socorro até a chegada no hospital pelo veículo de urgência. Impactos sobre os veículos comuns foram nulos ou discretamente favoráveis. **Limitações do Trabalho:** avaliação foi realizada em cenário específico, com uma única interseção e parâmetros controlados de fluxo, o que restringe a um cenário único, ou seja, somente um cruzamento. **Trabalhos Futuros:** ampliar a modelagem e as simulações para cenários com múltiplos cruzamentos e maior número de semáforos interconectados, possibilitando analisar coordenação semafórica em rede para veículos de urgência.

## Agradecimentos

A Deus. Universidade Estadual Paulista (UNESP), à Universidade de São Paulo (USP) e ao Instituto Federal de São Paulo (IFSP) – Campus Catanduva.

## Referências

- Choudhary, A. (2024). Internet of Things: a comprehensive overview, architectures, applications, simulation tools, challenges and future directions. *Discover Internet of Things*, 4(1):31.
- Divyesh, R., Vibusha, P., and Chitra, P. (2024). Dynamic Traffic Flow Optimization with YOLO-Based Object Detection. In *2024 International Conference on Smart Technologies for Sustainable Development Goals (ICSTSDG)*, pages 1–6. IEEE.
- Elassy, M., Al-Hattab, M., Takruri, M., and Badawi, S. (2024). Intelligent transportation systems for sustainable smart cities. *Transportation Engineering*, 16:100252.
- Forastieri Filho, H. L. A., Ferraz de Araujo, C. M., Mendonça Junior, A. d. S., and Forastieri, H. L. C. (2022). Tempo resposta no SAMU–192 e suas implicações. *Cadernos UniFOA*, 17(49):173–183.
- Gauss, T., Ageron, F.-X., Devaud, M.-L., Debaty, G., Travers, S., Garrigue, D., Raux, M., Harrois, A., Bouzat, P., and French Trauma Research Initiative (2019). Association of prehospital time to in-hospital trauma mortality in a physician-staffed emergency medicine system. *JAMA Surgery*, 154(12):1117–1124. PMC6764001.
- Hao, Z., Wang, Y., and Yang, X. (2024). Every second counts: A comprehensive review of route optimization and priority control for urban emergency vehicles. *Sustainability*, 16(7):2917.
- Khang, A. and Singh, K. (2025). *Internet of Things (IoT) Smart Sensing Traffic Lights for Revolutionizing Urban Traffic Management*, pages 105–118. Springer Nature Switzerland, Cham.
- Kleinrock, L. (1975). *Queueing Systems, Volume 1: Theory*. Wiley, New York, NY, USA.

- Köksalan, M. M. (1991). A replication approach to interval estimation in simulation. In *Proceedings of the 23rd conference on Winter Simulation*. ACM. Available in the ACM Digital Library.
- Law, A. M. (2015). Statistical analysis of simulation output data. In *Proceedings of the 2015 Winter Simulation Conference*. ACM / Winter Simulation Conference. Tutorial paper indexed in the ACM Digital Library.
- Little, J. D. (1961). A proof for the queuing formula:  $L = \lambda w$ . *Operations research*, 9(3):383–387.
- Lopez, P. A., Behrisch, M., Bieker-Walz, L., Erdmann, J., Flötteröd, Y.-P., Hilbrich, R., Lücken, L., Rummel, J., Wagner, P., and Wiessner, E. (2018). Microscopic traffic simulation using sumo. In *2018 21st International Conference on Intelligent Transportation Systems (ITSC)*, pages 2575–2582.
- Maschi, L. F. C., Pinto, A. S. R., Meneguette, R. I., and Baldassin, A. (2018). Data summarization in the node by parameters (dsn): Local data fusion in an iot environment. *Sensors*, 18(3).
- Meneguette, R., Grande, R. D., Ueyama, J., Filho, G. P. R., and Madeira, E. (2023). Vehicular Edge Computing: Architecture, Resource Management, Security, and Challenges. *ACM Computing Surveys*, 55(1):1–46.
- Oblakova, A., Al Hanbali, A., Boucherie, R., van Ommeren, J., and Zijm, W. (2022). An analytical model for a tandem of two traffic-light intersections under semi-actuated and fixed control. *Transportation Research Interdisciplinary Perspectives*, 16:100715.
- OpenStreetMap (2026). OpenStreetMap. <https://www.openstreetmap.org>. Dados cartográficos abertos sob a Open Database License (ODbL). Acesso em: 19 mar. 2026.
- Prabha, R., G., A. M., Safie, N., Hasan, M. K., Abdullah, N. H. S., and K.G., M. (2025). Modeling of Novel Ensemble Learning Method for Emergency Intelligent Transportation System Tracking and Mobility Management. In *2025 International Conference on Electrical Engineering and Informatics (ICEEI)*, pages 1–6. IEEE.
- SenthilPrabha, R., Sasikumar, D., Sriram, G., Nelson, K., and Harish, P. (2023). Smart Traffic Management System Through Optimized Network Architecture for the Smart City Paradigm Shift. In *International Conference on Intelligent Systems for Communication, IoT and Security (ICISCoIS)*.
- Shilpa, B., Mayank, M., and Fakruddin, S. M. (2025). Adaptive Urban Traffic Control Using Camera Vision and Emergency Vehicle Mobile Interface. In *2025 Second International Conference on Computing, Semiconductor, Mechatronics, Intelligent Systems and Communications (COSMIC)*, pages 48–53. IEEE.
- Tomar, I., Sreedevi, I., and Pandey, N. (2022). State-of-art review of traffic light synchronization for intelligent vehicles: Current status, challenges, and emerging trends. *Electronics*, 11(3).
- Valentini, E. P., Filho, G. P. R., De Grande, R. E., Ranieri, C. M., Júnior, L. A. P., and Meneguette, R. I. (2023). A novel mechanism for misbehavior detection in vehicular networks. *IEEE Access*, 11:68113–68126.
- Vandana, C., Sringeri, A. B., and Reddy, A. P. (2025). LifeLane: A Dual-Layer Emergency Vehicle Traffic Clearance System Using Embedded Communication and Machine Learning. In *2025 IEEE 5th International Conference on ICT in Business Industry & Government (ICTBIG)*, pages 1–6. IEEE.