

**PONTIFÍCIA UNIVERSIDADE CATÓLICA DE CAMPINAS**

**ESCOLA POLITÉCNICA**

**CARLOS HEITOR DE CAMPOS VALLIM**

**DETECÇÃO E CONTROLE DE  
CONGESTIONAMENTO VEICULAR EM AMBIENTE  
URBANO**

**CAMPINAS**

**2023**

**PONTIFÍCIA UNIVERSIDADE CATÓLICA DE CAMPINAS  
ESCOLA POLITÉCNICA  
PROGRAMA DE PÓS-GRADUAÇÃO *STRICTO SENSU* EM  
SISTEMAS DE INFRAESTRUTURA URBANA**

**CARLOS HEITOR DE CAMPOS VALLIM**

**DETECÇÃO E CONTROLE DE  
CONGESTIONAMENTO VEICULAR EM AMBIENTE  
URBANO**

Dissertação realizada no Programa de Pós-Graduação *Stricto Sensu* em Sistemas de Infraestrutura Urbana da Pontifícia Universidade Católica de Campinas, como parte dos requisitos para a obtenção do título de Mestre em Sistemas de Infraestrutura Urbana.

Orientador: Prof. Dr. ADEMAR TAKEO  
AKABANE

**CAMPINAS**

**2023**

Ficha catalográfica elaborada por Adriane Elane Borges de Carvalho CRB 8/9313  
Sistema de Bibliotecas e Informação - SBI - PUC-Campinas

388.4 Vallim, Carlos Heitor de Campos  
V188d

Detecção e controle de congestionamento veicular em ambiente urbano / Carlos Heitor de Campos Vallim. - Campinas: PUC-Campinas, 2023.

60 f.: il.

Orientador: Ademar Takeo Akabane.

Dissertação (Mestrado em Sistemas de Infraestrutura Urbana) - Programa de Pós-Graduação Stricto Sensu em Sistemas de Infraestrutura Urbana, Escola Politécnica, Pontifícia Universidade Católica de Campinas, Campinas, 2023.

Inclui bibliografia.

1. Transporte urbano. 2. Tráfego - Urbano. 3. Trânsito - Congestionamento. I. Akabane, Ademar Takeo. II. Pontifícia Universidade Católica de Campinas. Escola Politécnica. Programa de Pós-Graduação Stricto Sensu em Sistemas de Infraestrutura Urbana. III. Título.


23. ed. CDD 388.4


**CARLOS HEITOR DE CAMPOS VALLIM**

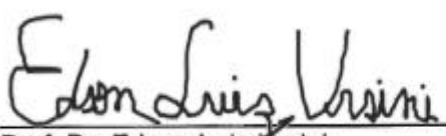
**DETECÇÃO E CONTROLE DE CONGESTIONAMENTO  
VEICULAR EM AMBIENTE URBANO**

Dissertação apresentada ao Curso de Mestrado em Sistemas de Infraestrutura Urbana da Escola Politécnica da Pontifícia Universidade Católica de Campinas, como requisito parcial para obtenção do título de Mestre em Sistemas de Infraestrutura Urbana.  
Área de Concentração: Sistemas de Infraestrutura Urbana.  
Orientador (a): Prof. (a). Dr. (a). Ademar Takeo Akabane.

Dissertação defendida e aprovada em 27 de junho de 2023 pela Comissão Examinadora constituída dos seguintes professores:

  
\_\_\_\_\_  
Prof. Dr. Ademar Takeo Akabane  
Orientador da Dissertação e Presidente da Comissão Examinadora  
Pontifícia Universidade Católica de Campinas

  
\_\_\_\_\_  
Profa. Dra. Lia Lorena Pimentel  
Pontifícia Universidade Católica de Campinas

  
\_\_\_\_\_  
Prof. Dr. Edson Luiz Ursini  
Universidade Estadual de Campinas - UNICAMP

## **AGRADECIMENTOS**

Quero agradecer a minha família e aos meus colegas de curso, que me ajudaram com ideias e sugestões que contribuíram para o desenvolvimento dessa pesquisa.

Meus sinceros agradecimentos também aos professores do Programa de Mestrado em Sistemas de Infraestrutura Urbana da Pontifícia Universidade Católica de Campinas pelo incentivo e apoio, em especial ao Prof. Dr. Ademar Takeo Akabane pela dedicação e atenção dispensada ao longo do curso.

## RESUMO

VALLIM, Carlos Heitor de Campos. **Detecção e controle de congestionamento veicular em ambiente urbano**. 2023. 60f. Dissertação (Mestrado em Sistemas de Infraestrutura Urbana) – Programa de Pós-Graduação em Sistemas de Infraestrutura Urbana, Pontifícia Universidade Católica de Campinas, Campinas, 2023.

O congestionamento do tráfego urbano é um problema recorrente na maioria das grandes cidades do mundo. Normalmente, é decorrente do aumento repentino do número de veículos nas ruas e avenidas durante os horários de pico. Mesmo com a melhoria contínua do sistema de transporte urbano, o número de veículos tende a aumentar com o desenvolvimento da economia, portanto, o congestionamento do tráfego urbano se torna um problema recorrente. O congestionamento urbano causa impactos negativos na sociedade, podendo ser destacados, a perdas econômicas, a redução da produtividade e o aumento das emissões de dióxido de carbono (CO<sub>2</sub>), deixando os motoristas presos no trânsito. A demanda por uma solução para evitar o congestionamento do tráfego é muito clara. Com base nesse contexto, nesta dissertação são propostos algoritmos para detecção e controle de congestionamento. Para isso, o algoritmo deve identificar áreas de congestionamento e propor rotas alternativas de tráfego a partir de informações coletadas em tempo de simulação realística. Ressalta-se que, a importância deste trabalho está em minimizar os problemas de congestionamento que afeta uma parcela considerável da população dos grandes centros urbanos. Os resultados mostram, que em média e alta densidade, o algoritmo *K Nearest Neighbors* usando classificador Pareto II (KNNP) reduz o tempo médio de viagem, o tempo parado em congestionamento, o tempo perdido por deslocamento do veículo abaixo do limite permitido na via, o consumo médio de combustível e a redução na emissão de CO<sub>2</sub> em até 55%, 79%, 68%, 28%, e 28% respectivamente.

**Palavras-chave:** Transporte urbano. Tráfego-urbano. Trânsito - Congestionamento.

## ABSTRACT

VALLIM, Carlos Heitor de Campos. **Detection and control of traffic jams in urban environment.** 2023. 60p. Qualification document (Master in Urban Infrastructure Systems) – Postgraduate Program in Urban Infrastructure Systems, Pontifícia Universidade Católica de Campinas, Campinas, 2023.

Urban traffic congestion is a recurring problem in most large worldwide cities. It usually arises from the sudden increase in the totality of vehicles on streets and avenues during peak hours. Even with continuous improvement of the urban transportation system, the number of automobiles tends to increase with the development of the economy, therefore, urban traffic congestion becomes a recurring problem. Urban congestion causes negative impacts on society, which can be highlighted, such as economic losses, reduced productivity, and increased carbon dioxide (CO<sub>2</sub>) emissions, leaving the drivers stuck in transit. The demand for a solution to avoid traffic jams is crystalline. In addition, this dissertation proposed an algorithm for traffic congestion detection and minimization. The algorithm would find congestion areas and recommend alternative traffic routes from information collected in workable simulation time. The dissertation brings a solution to minimizing the congestion problems that affect a considerable part of the population in large urban centers. The obtained results, in medium and high density, the K Nearest Neighbors algorithm using Pareto II classifier (KNNP), reduces the average travel time, the stopped in traffic jams time, the time lost due to vehicle movement below the limit allowed on the road, the average fuel consumption, and reduction of CO<sub>2</sub> emission by towards 55%, 79%, 68%, 28%, and 28% respectively.

**Keywords:** Urban transport. Traffic-Urban. Traffic Jam.

## LISTA DE FIGURAS

<b>Figura 1.</b> Arquiteturas de rede possíveis para VANETs. ....	23
<b>Figura 2.</b> Algoritmo 1 com a classificação do nível de congestionamento local. ....	28
<b>Figura 3.</b> Gráfico de distribuição de Pareto II. ....	30
<b>Figura 4.</b> Algoritmo 2 para cálculo do K-Nearest Neighbors.....	32
<b>Figura 5.</b> Cenário realístico de Manhattan.....	34
<b>Figura 6.</b> Polígono do distrito de Manhattan 3km x 2km.....	35
<b>Figura 7.</b> Polígono do distrito de Manhattan após retificação no Netedit.....	37
<b>Figura 8.</b> Sugestão de rota Google Maps <sup>2</sup> com mapa de calor. ....	39
<b>Figura 9.</b> Duração média da viagem na densidade de 2000 veículos por km <sup>2</sup> . ....	43
<b>Figura 10.</b> Duração média da viagem na densidade de 4000 veículos por km <sup>2</sup> . ....	44
<b>Figura 11.</b> Distância média percorrida na densidade de 2000 veículos por km <sup>2</sup> . ....	45
<b>Figura 12.</b> Distância média percorrida na densidade de 4000 veículos por km <sup>2</sup> . ....	45
<b>Figura 13.</b> Tempo médio de espera na densidade de 2000 veículos por km <sup>2</sup> . ....	46
<b>Figura 14.</b> Tempo médio de espera na densidade de 4000 veículos por km <sup>2</sup> . ....	47
<b>Figura 15.</b> Gasto médio de combustível na densidade de 2000 veículos por km <sup>2</sup> . ..	47
<b>Figura 16.</b> Gasto médio de combustível na densidade de 4000 veículos por km <sup>2</sup> . ..	48
<b>Figura 17.</b> Tempo médio perdido por lentidão na densidade de 2000 veículos por km <sup>2</sup> . .....	48
<b>Figura 18.</b> Tempo médio perdido por lentidão na densidade de 4000 veículos por km <sup>2</sup> . .....	49
<b>Figura 19.</b> Emissão média de gás carbônico (CO <sub>2</sub> ) em ppm em 2000 veículos por km <sup>2</sup> . .....	50
<b>Figura 20.</b> Emissão média de gás CO <sub>2</sub> em ppm em 4000 veículos por km <sup>2</sup> . ....	50
<b>Figura 21.</b> Duração média da viagem por KNN em 2000 veículos por km <sup>2</sup> .....	51
<b>Figura 22.</b> Tempo médio de espera por KNN em 2000 veículos por km <sup>2</sup> .....	52



<b>Figura 23.</b> Distância média percorrida por KNN em 2000 veículos por km <sup>2</sup> .....	52
<b>Figura 24.</b> Duração média da viagem por intervalo em 2000 veículos por km <sup>2</sup> .....	53
<b>Figura 25.</b> Tempo médio de espera por intervalo em 2000 veículos por km <sup>2</sup> .....	53
<b>Figura 26.</b> Distância média percorrida por intervalo em 2000 veículos por km <sup>2</sup> .....	54

## LISTA DE TABELAS

<b>Tabela 1.</b> As 25 cidades mais congestionadas do mundo. ....	15
<b>Tabela 2.</b> Classificação dos níveis de serviço.....	29
<b>Tabela 3.</b> Indicadores de desempenho na densidade de 4000 veículos por km <sup>2</sup> . ....	40
<b>Tabela 4.</b> Indicadores de desempenho na densidade de 2000 veículos por km <sup>2</sup> . ....	41
<b>Tabela 5.</b> Variação % base algoritmo OVMT na densidade de 4000 veículos por km <sup>2</sup> . .....	41
<b>Tabela 6.</b> Variação % base algoritmo OVMT na densidade de 2000 veículos por km <sup>2</sup> . .....	42

## LISTA DE ABREVIATURAS E SIGLAS

CAM	<i>Cooperative Awareness Messages</i>
Cartim	<i>Cooperative vehicular traffic identification and minimization</i>
CoTEC	<i>Cooperative Traffic Detecting Congestion</i>
EcoTrec	Sistemas de Transporte Ecológico e Inteligente
HCM	Highway Capacity Manual
ITS	Sistemas de transporte inteligente
KNN	<i>K Nearest Neighbors</i>
OEM	<i>Original equipment manufacturer</i>
OVMT	<i>Original Vehicular Mobility Trace</i>
PPM	Partes por milhão
SUMO	Simulador de mobilidade urbana
TCI	<i>Traffic Congestion Index</i>
TMS	Sistemas de Gerenciamento de Trânsito
TRACI	Interface de controle de tráfego
V2I	Comunicação Veículo para Infraestrutura
V2V	Redes veiculares
VANET	<i>Vehicular Ad hoc Network</i>
WAVE	Ambiente Veicular de Acesso Sem Fio
WLAN	<i>Wireless Local Area Network</i>

# SUMÁRIO

1. INTRODUÇÃO .....	14
1.1. Objetivos .....	16
1.2. Metodologia da Pesquisa .....	16
1.3. Organização do Documento.....	17
2. FUNDAMENTAÇÃO TEÓRICA.....	18
2.1. Sistemas de Transporte Inteligentes - ITS .....	18
2.1.1. Sistemas de Gerenciamento de Trânsito .....	20
2.1.2. Sistema de Localização.....	20
2.2. Redes Veiculares .....	21
3. TRABALHOS RELACIONADOS .....	24
4. DETECÇÃO E CONTROLE DE CONGESTIONAMENTO .....	26
4.1. Detecção de Congestionamento .....	26
4.2. Cálculo da Rota Alternativa.....	28
5. METODOLOGIA.....	33
5.1. Considerações sobre o cenário de simulação alvo .....	33
5.2. Ferramentas de Simulação .....	35
5.2.1. TraCI .....	35
5.2.2. OpenStreetMap .....	36
5.2.3. Netedit.....	36
5.2.4. Simulador de Mobilidade Urbana .....	37
5.3. Métricas de avaliação dos dados da simulação .....	38
5.4. Extensão do Cenário de Simulação .....	38
5.4.1. Etapa de Diagnóstico e Validação dos Resultados .....	39

6. RESULTADOS E DISCUSSÃO.....	43
6.1. Diagnóstico.....	43
6.2. Execução.....	49
7. CONCLUSÃO.....	55
7.1. Da Aplicabilidade do Algoritmo.....	55
7.2. Proposta de Trabalhos Futuros .....	56
8. REFERÊNCIAS.....	57

## 1. INTRODUÇÃO

Os grandes centros urbanos estão enfrentando, cada vez mais, um aumento significativo no número de veículos, conseqüentemente resultando em congestionamentos que representam um grande desafio para as autoridades públicas. Sabe-se que esses congestionamentos geram diversos problemas para a sociedade e o meio ambiente, incluindo desde acidentes de trânsito, a problemas provocados pelo aumento da poluição. Além disso, os congestionamentos causam prejuízos econômicos, diminuem a eficiência geral do fluxo de veículos, bloqueiam o acesso de veículos de emergência como: ambulâncias e carros de polícia, e ainda aumentam a emissão de gases prejudiciais à atmosfera, como o CO<sub>2</sub>.

Líder global em serviços de carros conectados e análise de mobilidade, INRIX<sup>1</sup> publicou o documento *Global Traffic Scorecard 2018* que identificou e classificou os congestionamentos de tráfegos veiculares e as tendências de mobilidade em mais de 200 cidades em 38 países (INRIX, 2022). A Tabela 1 apresenta as 25 cidades mais congestionadas do mundo. Mostra ainda que London, Chicago, Paris, Boston e New York City que incorpora o Distrito de Manhattan, ocupam os 5 primeiros lugares no ranking Global de Impacto de Congestionamento (INRIX, 2022).

No âmbito das cidades inteligentes, a comunidade profissional e acadêmica vem trabalhando há anos na questão dos problemas de mobilidade urbana. Essa questão vem sendo afetada pela falta de investimentos por parte dos órgãos públicos, em transportes públicos de massa. Sabe-se que a mobilidade sofre uma acentuada piora, devido ao número de habitantes vivendo em ambientes urbanos, com alta concentração do uso de transportes durante os horários de pico, o que contribui para aumentar a emissão de gases de efeito estufa e poluição sonora, perdas de tempo para os cidadãos, e de ordem econômica para as cidades e entidades governamentais (NAM; PARDO, 2011).

---

<sup>1</sup> <http://inrix.com/>

**Tabela 1.** As 25 cidades mais congestionadas do mundo.

Classificação 2022 (Classificação 2021)	Área Urbana	País	2022 Atraso por Motorista (horas)	Mudança desde 2021	Mudança desde Pré CO-VID	Down-town Speed (mph)	Mudança na Down-town Speed
1 (1)	Londres	UK	156	5%	5%	10	-9%
2 (6)	Chicago	USA	155	49%	7%	11	-27%
3 (2)	Paris	FRA	138	-1%	-16%	11	0%
4 (18)	Boston	USA	134	72%	-10%	11	-27%
5 (5)	Nova York	USA	117	15%	-16%	11	-15%
6 (8)	Bogotá	COL	122	30%	-36%	11	-15%
7 (22)	Toronto	CAN	118	59%	-13%	10	-29%
8 (13)	Filadelfia	USA	114	27%	-20%	11	-15%
9 (32)	Miami FL	USA	105	59%	30%	15	-21%
10 (9)	Palermo	ITA	121	11%	-12%	9	0%
11 (36)	Monterrey	MEX	116	66%	108%	19	-17%
12 (16)	Dublin	IRL	114	28%	-26%	12	-8%
13 (7)	Roma	ITA	107	0%	-36%	13	-7%
14 (33)	Los Angeles	USA	95	53%	-8%	19	-17%
15 (34)	São Francisco	USA	97	52%	0%	12	-14%
16 (10)	Istanbul	TUR	89	1%	-42%	14	0%
17 (3)	Bruxelas	BEL	98	-27%	-30%	10	0%
18 (68)	Medellin	COL	91	72%	32%	12	-14%
19 (11)	Bucareste	ROU	91	-7%	*	15	7%
20 (99)	Washington DC	USA	83	89%	-33%	11	-21%
21 (12)	Lion	FRA	92	-10%	-12%	10	-9%
22 (23)	Mexico City	MEX	74	10%	-53%	12	-14%
23 (15)	Budapest	HUN	86	-7%	-7%	16	7%
24 (43)	Cape Town	ZAF	80	36%	-35%	12	-20%
25 (50)	Bristol	UK	91	38%	-12%	14	-13%

Fonte: Adaptada de INRIX (2022).

Uma maneira de minimizar o congestionamento do tráfego veicular é usar tecnologias de informação e comunicação (TIC) por meio de *Intelligent Transportation Systems* (ITS). ITS são comumente utilizados para gerenciamento de tráfego veicular e o ITS mais empregado é o sistema de navegação veicular. Este tipo de sistema coleta informações de trânsito por meio de dispositivos móveis do usuário, sendo os mais conhecidos: Google Maps<sup>2</sup>, TomTom<sup>3</sup> e Waze<sup>4</sup>. Assim, os usuários desses sistemas podem monitorar facilmente as condições atuais do tráfego para planejar

<sup>2</sup><https://maps.google.com>

<sup>3</sup><https://www.tomtom.com>

<sup>4</sup><https://www.waze.com>

suas rotas de viagem. No entanto, tais sistemas estão longe de atingir os objetivos, uma vez que eles dependem muito de informações inseridas pelos usuários com seus *smartphones* (RODRIGUES *et al.*, 2017).

Uma forma de amenizar os problemas de congestionamentos, a qual é a hipótese explorada, em que utiliza um algoritmo de cálculo que permita encontrar uma rota confiável, segura e com menor gasto de tempo ou combustível para o motorista, visando aumentar a eficácia na gestão do trânsito e reduzir perdas econômicas e de produtividade no âmbito das cidades inteligentes (CODECA; FRANK; ENGEL, 2015).

Para Doolan e Muntean (2017, p. 612): “Cada vez que um veículo recebe novas informações via mensagens *Vehicular Ad hoc Network* (VANET), a utilidade da função é revista, atualizando a rota. Cada veículo envia e encaminha mensagens sobre o itinerário que está percorrendo com frequência  $\phi$ . O envio frequente das mensagens é necessário para ter tempo real ou quase real das informações de tráfego”.

## 1.1. Objetivos

O objetivo geral deste trabalho é propor e avaliar algoritmos de roteamento cooperativo visando melhorar a fluidez no tráfego veicular urbano.

Para atingir o objetivo geral deste trabalho, os seguintes objetivos específicos são estabelecidos:

- Detectar áreas de congestionamento veicular com base no contexto;
- Propor rotas alternativas, minimizando as áreas congestionadas;
- Avaliar as soluções propostas.

## 1.2. Metodologia da Pesquisa

Após a identificação do problema, foi proposta uma metodologia para alcançar o objetivo deste trabalho, o qual respeitou as seguintes etapas de execução:

Revisão Sistemática da Literatura: nesta etapa, realizou-se pesquisas bibliográficas de temas referentes ao assunto: Cidades inteligentes; Sistemas Inteligentes de Transporte; Mobilidade urbana e Sistema de gerenciamento veicular;

Estudo das ferramentas: nesta etapa, estudou-se ferramentas necessárias para a execução das simulações: SUMO (Simulador de Mobilidade Urbana), TraCI (Interface de controle de tráfego) e *OpenStreetMap* (banco de dados geográfico aberto atualizado e mantido por uma comunidade de voluntários);



Extração do cenário de simulação: nesta etapa, devido a diversas publicações acadêmicas, extraiu-se uma área urbana do distrito de Manhattan com o apoio do *OpenStreetMap*;

Implementação dos algoritmos: nesta etapa, iniciou-se a implementação dos algoritmos de detecção e controle de congestionamentos utilizados neste trabalho;

1. Execução das simulações: nesta etapa, realizou-se a execução dos experimentos de simulação;

2. Validação e ajuste dos algoritmos: nesta etapa, realizou-se a validação e os ajustes dos algoritmos implementados;

3. Análise dos resultados: nesta etapa, realizou-se as análises dos resultados alcançados e comparação com os algoritmos da literatura.

### **1.3. Organização do Documento**

O restante desta proposta está organizado como: O Capítulo 2 contém a fundamentação teórica, descrevendo os principais conceitos necessários para o desenvolvimento deste projeto. O Capítulo 3 apresenta os principais trabalhos existentes na literatura que abordam o mesmo tema. O Capítulo 4 apresenta a detecção e controle de congestionamento. O Capítulo 5 apresenta a metodologia usada para abordar o problema, já o Capítulo 6 apresenta os resultados e discussão, com a utilização do algoritmo desenvolvido neste projeto e por fim o Capítulo 7 apresenta a conclusão do trabalho.

## 2. FUNDAMENTAÇÃO TEÓRICA

Neste capítulo são detalhados o embasamento teórico e a sustentação deste trabalho, descrevendo os principais conceitos de Sistema de Transporte Inteligentes (Seção 2.1) e Redes Veiculares (Seção 2.2).

### 2.1. Sistemas de Transporte Inteligentes - ITS

Os Sistemas de Transporte Inteligentes são aplicações tecnológicas avançadas que têm como objetivo oferecer serviços inovadores relacionados a diferentes modos de transporte e gerenciamento de tráfego. Tais sistemas possibilitam que os usuários sejam melhor informados e utilizem as redes de transporte de maneira mais coordenada, segura e inteligente (DIMITRAKOPOULOS; DEMESTICHAS, 2010).

Uma das principais tecnologias utilizadas nos ITS é a comunicação veicular (INRIX, 2022; DIMITRAKOPOULOS; DEMESTICHAS, 2010). Para isso, os veículos são equipados com dispositivos de comunicação sem fio e podem trocar informações em tempo real com veículos que trafegam nas imediações, bem como com a infraestrutura de transporte, como semáforos e sinais de trânsito (INRIX, 2022; AKABANE; VILLAS; MADEIRA, 2015). Essas informações podem ser usadas para melhorar o fluxo de tráfego, reduzir acidentes e economizar combustível. Além dessas tecnologias mencionadas, os ITS também incluem outras tecnologias avançadas de navegação, como sistemas de navegação por satélite (GPS) e mapas digitais, que podem fornecer informações em tempo real sobre as situações das rodovias, rotas alternativas, e pontos de congestionamentos (AKABANE *et al.*, 2020; AKABANE *et al.*, 2018a; AKABANE *et al.*, 2018b). Todas as tecnologias mencionadas podem ser utilizadas isoladas ou de forma conjunta para auxiliar os motoristas a evitarem congestionamentos, economizar tempo e reduzir o estresse durante a condução. Ademais, os ITS podem ajudar a reduzir as emissões de gases de efeito estufa e a poluição do ar, integrando veículos elétricos e híbridos, bem como tecnologias de gerenciamento de tráfego que otimizam a eficiência do combustível (AKABANE; VILLAS; MADEIRA, 2015).

Outro ponto importante nos ITS é a coleta e análise de dados. Os dados coletados por sensores espalhados no ambiente urbano e sistemas de monitoramento, por exemplo: câmera de vigilância, podem ser usados para identificar padrões de tráfego, detectar congestionamentos, além de prever tendências e melhorar a eficiência da operação de transporte (RODRIGUES *et al.*, 2017; DIMITRAKOPOULOS; DEMESTICHAS, 2010; AKABANE; VILLAS; MADEIRA, 2015; AKABANE *et al.*, 2020; AKABANE *et al.*, 2018a; AKABANE *et al.*, 2018b). Esses dados também podem ser usados para melhorar a segurança rodoviária, monitorando as condições da estrada, detectando veículos quebrados e alertando os motoristas sobre riscos potenciais (INRIX, 2022; AKABANE; VILLAS; MADEIRA, 2015).

Existem várias aplicações viáveis para ITS que se pode destacar:

- Gestão do tráfego: controle de tráfego em tempo real, gerenciamento de incidentes, previsão de congestionamentos e tempos de viagem (INRIX, 2022; DIMITRAKOPOULOS; DEMESTICHAS, 2010; AKABANE; VILLAS; MADEIRA, 2015);
- Sistemas de informação ao usuário: informações em tempo real sobre horários de ônibus, trem e metrô, alertas de atrasos e cancelamentos, rotas alternativas, preços e opções de transporte (SILVA, 2000);
- Sistemas de navegação: navegação por satélite, mapas digitais e guias de rotas (QURESHI; ABDULLAH, 2013);
- Cobrança eletrônica de pedágios: pagamento de pedágios eletrônicos, sem parada obrigatória em cabines de pedágio (AKABANE *et al.*, 2020; SILVA, 2000);
- Monitoramento de veículos: rastreamento de frota, monitoramento de veículos, gerenciamento de manutenção (QURESHI; ABDULLAH, 2013);
- Segurança no trânsito: alertas de colisão, assistência ao motorista, controle de velocidade, prevenção de acidentes (DIMITRAKOPOULOS; UDEN; VARLAMIS, 2020);
- Transporte público: gerenciamento de horários, monitoramento de veículos, informações em tempo real (AKABANE *et al.*, 2020; SILVA, 2000);
- Gerenciamento de estacionamento: gerenciamento das vagas de estacionamento em tempo real, reservas e pagamento eletrônico (AKABANE *et al.*, 2020; SILVA, 2000).

### **2.1.1. Sistemas de Gerenciamento de Trânsito**

Outra aplicabilidade do ITS é na utilização do *Traffic Management Systems* (TMS), por meio do monitoramento extensivo por câmeras de vídeos e a programação de semáforos, bem como a alteração de pistas nas vias com auxílio da engenharia de tráfego para reorganizar o fluxo dos veículos, visando reduzir o impacto do congestionamento na geração de gases de efeito estufa, e de gastos adicionais de combustível, além da significativa perda de horas produtivas de trabalho para os motoristas, que ficam parados no trânsito devido ao tráfego intenso (SOUZA *et al.*, 2017).

Os TMS podem ser classificados em três etapas: Obtenção de informações, processamento das informações obtidas e serviço de entrega de dados (SOUZA *et al.*, 2017).

Obtenção: Os dados são coletados de diversas fontes como câmeras de vídeo, sensores instalados em semáforos ou pontos estratégicos no trânsito (RODRIGUES *et al.*, 2017).

Processamento: Os dados recebidos são processados, com o objetivo de identificar as informações do tráfego, emergências, congestionamentos, alagamentos ou outros eventos que contribuem para a degradação do trânsito em determinado momento.

Entrega de Informações: Nesta etapa são realizadas intervenções no meio, utilizando os sistemas disponíveis, como o temporizador para efetuar o sincronismo entre os semáforos, permitindo assim, uma melhora na eficiência do tráfego.

Outros trabalhos relacionados com TMS publicados, geralmente atuam na segurança, na diminuição de tráfego, na melhoria da eficiência do trânsito e na redução dos impactos negativos ao meio ambiente (SOUZA *et al.*, 2017).

### **2.1.2. Sistema de Localização**

Dentre os sistemas de localização o aplicativo Waze<sup>4</sup>, indica uma rota com menor congestionamento entre dois pontos, a partir dos dados de origem e destino, pesquisando os dados de velocidade média em vias e eventual ocorrência de acidentes. A solução consolida os eventos e oferece uma informação única a todos

os veículos, fazendo com que todos os motoristas se desloquem para a mesma rota, expandindo os pontos de congestionamento para vias adjacentes.

*TomTom Navigation for Automotive* é o sistema de navegação *in-dash* líder para OEMs. Oferece uma experiência de alta qualidade para o usuário final e pode ser implementado em uma ampla gama de marcas, linhas de carros e regiões. Foi desenvolvido para rodar exclusivamente na nuvem, o TomTom<sup>3</sup> aproveita o roteamento hiper-rápido, pesquisando mapas atualizados. Quando não há uma conexão de dados disponível, a solução muda para o software de bordo para obter a máxima confiabilidade.

Google Maps<sup>2</sup> é um sistema de localização baseado no sistema geodésico com coordenadas de latitude e longitude, oferece imagens obtidas de satélite, fotografia aérea, mapas de rua, vistas panorâmicas de ruas, faixas de pedestres, condições de tráfego em tempo real e planejamento de rotas para viagens a pé, de carro, por via aérea e por transporte público.

## **2.2. Redes Veiculares**

Nas redes VANET os veículos são equipados com unidades de processamento, armazenamento e interface de comunicação, onde o principal objetivo é fornecer conexão constante e eficiente tanto para comunicação veículo-a-veículo (V2V) como entre veículos e infraestrutura de rede (V2I) (DONATO *et al.*, 2015).

VANET compreende veículos com sinal de rádio habilitado, que atuam como um nó móvel, assim como um roteador para outros nós. Em outras palavras há similaridade com redes ad hoc, como largura de transmissão e ondas curtas de rádio, auto-organizada e autogerida, com baixa largura de banda. As VANETs podem se distinguir de outras redes ad hoc pelos seguintes aspectos a serem entendidos (BEDOGNI *et al.*, 2015):

- Alto dinamismo da topologia;
- Frequência de desconexão da rede;
- Suficiência de energia e armazenamento;
- Tipo de comunicação geográfica;
- Modelagem e predição de mobilidade;
- Ambiente com variada comunicação;

- Restrições rígidas de atraso;
- Interação com sensores GPS.

Como as VANETs são extensões das *Mobile Ad hoc Network* (MANET), elas têm como características em comum: baixa largura de banda, transmissão de curto alcance e *omnidirecional broadcast*. Além dessas características, possuem particularidades que as tornam ainda mais desafiantes (DONATO *et al.*, 2015).

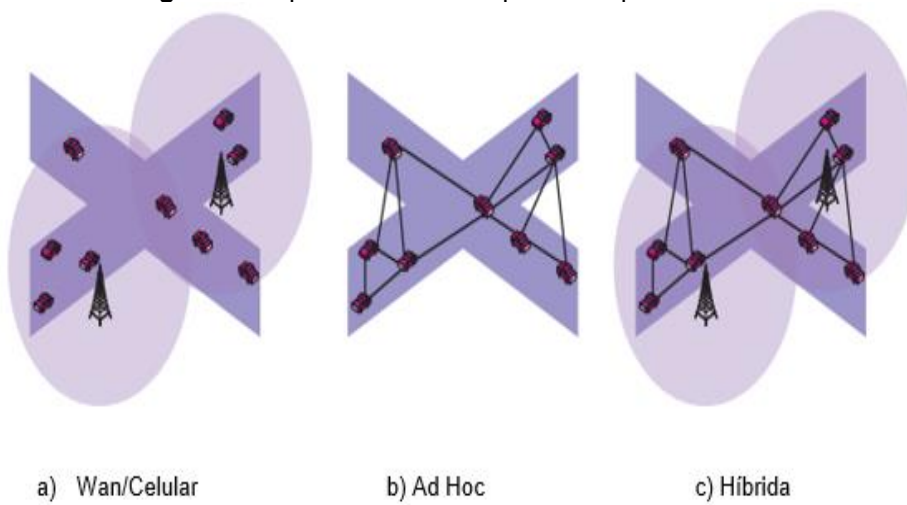
Uma das principais características que torna este cenário tão desafiador é a constante mudança na topologia da rede, devido à alta mobilidade dos veículos somado a diversidade de padrões de redes, além das diferenças de frequência de banda, aplicabilidade e os padrões de mercado (KARAGIANNIS *et al.*, 2011). Tais dados contribuem para que as VANETs tenham um baixo alcance, portanto os veículos precisam estar próximos para que os dados possam ser disseminados. Para que um dado seja corretamente transmitido, os veículos devem permanecer dentro da área de comunicação durante um determinado período (VILLAS *et al.*, 2014).

A comunicação V2V caracteriza-se pela comunicação exclusiva entre veículos. Os protocolos existentes nesta categoria têm que lidar com situações complexas, devido à constante mudança da densidade e topologia da rede. Existem técnicas específicas para tratar com alta densidade de veículos, baixa densidade, redes tolerantes a atraso e outras (VILLAS *et al.*, 2014). Cada uma das técnicas existentes apresenta vantagens e desvantagens, dependendo do cenário, sendo difícil eleger a melhor técnica para todos os cenários.

Na comunicação V2I os veículos se comunicam apenas com a infraestrutura disponível, dependendo exclusivamente deste equipamento para se comunicar, porém VANETs podem usar gateways celulares fixos e *Wireless Local Area Network* (WLAN) pontos de acesso em cruzamentos de tráfego para se conectar à Internet, coletar informações de tráfego ou para fins de roteamento, conforme Figura1 (LI; WANG, 2007).

O conjunto distinto de aplicações candidatas (por exemplo, alerta de colisão e informações de tráfego local para motoristas), recursos (espectro licenciado, fonte de energia recarregável) e o ambiente (por exemplo, padrões de fluxo de tráfego de veículos, questões de privacidade) tornam a VANET uma área única de telecomunicações sem fio (HARTENSTEIN; LABERTEAUX, 2008).

**Figura 1.** Arquiteturas de rede possíveis para VANETs.



Fonte: Adaptado de Li e Wang (2007).

### 3. TRABALHOS RELACIONADOS

Dentre os trabalhos relacionados, o estudo de Doolan e Muntean (2017), propõe um sistemas de transporte ecológico e inteligente (EcoTrec), que é uma solução de roteamento veicular baseada em VANET para redução das emissões de carbono. O EcoTrec foi avaliado em diversos cenários, variando a taxa de penetração e a taxa de conformidade, em diferentes tipos de mapa, incluindo mapas de dimensões urbanos e rurais, e simulações de tráfego, abordando situações em dias e horários diferentes.

O algoritmo EcoTrec proposto, se implementado, poderia melhorar muito o meio ambiente, reduzindo as emissões de gases e aumentando o bem-estar geral da sociedade, diminuindo o tempo perdido devido ao congestionamento do tráfego (DOOLAN; MUNTEAN, 2017).

Entretanto, a proposta do *Cooperative Traffic Detection (CoTEC)* (BAUZA; GOZALVEZ; SANCHEZ-SORIANO, 2010), apresenta uma nova técnica cooperativa baseada em V2V e lógica difusa para detectar o congestionamento do trânsito sem a necessidade de implantar sensores de infraestrutura nas vias públicas.

A técnica proposta, também é capaz de detectar com precisão a intensidade e a extensão do congestionamento de tráfego. Contribui para uma melhor gestão do tráfego veicular urbano, utilizando sistema geodésico de localização, com o envio de pacotes para os veículos que se encontram na adjacência do tráfego explorando o envio de pacotes entre veículos adjacentes, detectando os pontos de congestionamento de tráfego para propor rotas alternativas utilizando *Wireless Local Area Network (WLAN)* e contribuindo para redução de poluição.

Os roteadores de rede móvel para os veículos, que apenas possuam capacidade de alcance na WLAN, comunicam-se por meio de links de vários saltos para permanecer conectado externamente com o uso de *beacons*, que permitem por intermédio de um algoritmo inteligente gerenciar a distribuição dos veículos, de forma a impedir que em um dado evento, todos os veículos sejam direcionados para a via mais rápida, ocasionando a migração do congestionamento da via que o sistema detectou para as demais vias adjacentes (ARAÚJO *et al.*, 2014).

Nesse contexto Araújo *et al.* (2014) propõe a identificação colaborativa de congestionamentos, coletando V2V, ou se existente, comunicação V2I, para realizar



de forma heurística a classificação e a seleção de rotas, variando o intervalo de frequência e o número de K Vizinhos mais próximos, aplicando um tratamento qualitativo das informações por densidade de veículos, por meio da aplicação de uma lógica difusa, objetivando reduzir o impacto dos congestionamentos (ARAÚJO *et al.*, 2014).

Outro trabalho apresentado na literatura é o INCIDEnTE, que é baseado em uma rede neural artificial (ANN), empregada para detectar e classificar os níveis de congestionamento, os resultados obtiveram uma taxa de sucesso significativa ao detectar o nível do congestionamento, e conseguindo reduzir as emissões de CO<sub>2</sub>, o consumo de combustível e o tempo de viagem (MENEGUETTE *et al.*, 2016). Entretanto o algoritmo não utiliza método de classificação com sistema de autoaprendizagem, o que sugere que os congestionamentos em níveis elevados podem migrar de uma via para outra (MENEGUETTE *et al.*, 2016).

O cálculo para classificação de congestionamento de um determinado segmento é relativamente baixo e não tem impacto direto no desempenho do INCIDEnTE, porém possui alta dependência da comunicação entre os *beacons*, sendo sensível à paisagem, à densidade, e à proximidade dos veículos que estão se deslocando para a obtenção de informações de aprendizagem, além de obter baixo resultado em cenários rodoviários (MENEGUETTE *et al.*, 2016).

Outra proposta disponível na literatura trata do Método Baseado em V2V. Em primeiro lugar, um controlador difuso é construído com base na velocidade do veículo e na densidade do tráfego, como informação de entrada e o nível de congestionamento local como informação de saída, que é usado para julgar o nível de congestionamento do tráfego local, baseado exclusivamente na comunicação V2V. O congestionamento de veículos vizinhos é coletado, e o nível de congestionamento do tráfego regional é obtido com base no teste de hipótese de uma grande sub amostra (WANG *et al.*, 2019).

Depois que as informações do congestionamento foram obtidas, elas devem ser enviadas oportunamente aos veículos para disseminar a informação de tráfego veicular, melhorar a detecção e fluidez no trânsito, com base na transmissão de dados de vários saltos dos veículos conectados (WANG *et al.*, 2019).

## 4. DETECÇÃO E CONTROLE DE CONGESTIONAMENTO

Este capítulo está dividido em duas partes: Detecção de congestionamento e Cálculo de uma rota alternativa.

### 4.1. Detecção de Congestionamento

A detecção de congestionamento é de fundamental importância na gestão de tráfego urbano, pois ela pode evitar que mais veículos possam adentrar na região congestionada, e possa prover mecanismos para melhorar a situação, medida esta que pode salvar vidas, pela informação a ser enviada aos veículos de transporte de emergência, como ambulância, viaturas de salvamento, e do corpo de bombeiros.

Formas de mensurar os congestionamentos não são totalmente padronizadas, porém Lomax *et al.* (1997), propõe que o índice ideal, para definir uma área de congestionamento, teria que cumprir com os seguintes requisitos:

- (i) Claro, compreensível, inequívoco e crível;
- (ii) Capacidade descritiva e preditiva de descrever as condições existentes, prever mudanças e ser replicável;
- (iii) Capacidade na aplicação de técnicas estatísticas, com o objetivo de fornecer um retrato do congestionamento e a replicação do resultado com um menor esforço de coleta e conversão nos dados;
- (iv) Aplicabilidade em dias da semana, período do dia e região (LOMAX *et al.*, 1997).

A detecção de áreas de congestionamento, correntemente utilizado na literatura se dá por meio da identificação do *Traffic Congestion Index* (TCI).

O cálculo da Taxa de Intensidade de Congestionamento (TCI), ou Índice de Congestionamento de Tráfego, mostra uma comparação entre a densidade de veículos numa determinada área ou polígono, elegendo um período base de comparação contra o período em questão, atribuído naquele dia da semana de acordo com o horário avaliado em comparação com um horário base, conforme a equação a seguir.

$$\Delta TCI_{pdt1} = \left( \frac{TCI_{pdt1}}{TCI_{pdt0}} - 1 \right) \times 100$$

Onde os seguintes símbolos representam, respectivamente:

TCI = Intensidade de congestionamento;

p = Polígono da área metropolitana;

d = Dia da Semana;

t1 = Período de avaliação;

t0 = Período base.

Quanto menor o índice, melhor é a situação de tráfego, sendo que uma área de congestionamento é detectada de acordo com o índice de TCI, portanto esta pode ser informação enviada aos veículos da adjacência, e desta forma, os motoristas, terão uma nova sugestão de rota para alcançar o destino, evitando a área congestionada (MENEQUETTE *et al.*, 2016).

Devido às limitações para processamento de dados, não foi considerado nesse modelo o dia da semana, porém uma vez identificado o congestionamento, a rota e os pesos calculados, são armazenados em uma base de dados para fornecer informações para as próximas simulações, que basicamente devem buscar as velocidades atuais, e assim reiniciar um novo ciclo de cálculo, atribuindo novamente os pesos, de acordo com a velocidade, conforme Figura 2.

Nas Linhas 1 e 2 do Algoritmo 1 (Figura 2) são recebidos os parâmetros de cálculo do índice de congestionamento, nas Linhas 6 a 23 são atribuídos os pesos para cada aresta de acordo com as velocidades permitidas e armazenadas para a efetuar a classificação. Entre as Linhas 24 e 32 é efetuada a classificação do índice de congestionamento.

O modelo resgata o índice corrente do Delta TCI passando as coordenadas da aresta, caso uma conexão com Google Maps<sup>2</sup> esteja disponível uma chamada Java Script Object Notation (*Json*), que é um formato de baixa complexidade, que pode transportar e armazenar o índice de congestionamento corrente, e este pode ser utilizado no algoritmo por meio da Linha 4. No caso de algum erro de conexão, devido

à inexistência de uma chave Google ou a aresta não ter sido encontrada, na Linha 6 é atribuída o TCI 50 para não impactar na classificação posterior.

**Figura 2.** Algoritmo 1 com a classificação do nível de congestionamento local.

---

**Algorithm 1** Classifica o nível de congestionamento local

---

```

1: function CLASSIFICAÇÃOCONGESTIONAMENTO(Graph)
2:   dArestas ← getEdges(Graph)                                ▷ Recupera as arestas do polígono
3:   for i from 1 to len(dArestas) do
4:     dTCI ← getLastTCI(dArestas[i])                          ▷ Resgata o ultimo TCI da rota
5:     if ConnectionError or dTCI = 0 then
6:       dTCI ← 50                                             ▷ Atribui TCI 50 em caso de não disponibilidade da rota ou erro de conexão
7:     end if
8:     dArestas[i, fVelocidade] ← getSpeedy(dArestas[i])
9:     if dArestas[i, fVelocidade] >= 107.8 then                ▷ Atribui os pesos as arestas
10:      lPeso[i] ← 1
11:    end if
12:    if 107.0 >= dArestas[i, fVelocidade] < 107.8 then
13:      lPeso[i] ← 2
14:    end if
15:    if 106.2 >= dArestas[i, fVelocidade] < 107.0 then
16:      lPeso[i] ← 3
17:    end if
18:    if 74.0 >= dArestas[i, fVelocidade] < 106.2 then
19:      lPeso[i] ← 4
20:    end if
21:    if 56.3 >= dArestas[i, fVelocidade] < 74.0 then
22:      lPeso[i] ← 5
23:    end if
24:    if dArestas[i, fVelocidade] < 56.0 then
25:      lPeso[i] ← 6
26:    end if
27:    if lPeso[i] <= 4 or dTCI <= 10 then                       ▷ Avalia o fluxo do fráfego
28:      sPercepcao[i] ← 'Livre'
29:    end if
30:    if lPeso[i] = 5 or dTCI <= 30 then
31:      sPercepcao[i] ← 'Moderado'
32:    end if
33:    if lPeso[i] = 6 or dTCI < 50 then
34:      sPercepcao[i] ← 'Congestionado'
35:    end if
36:  end for
37:  Return True
38: end function

```

---

Fonte: Própria.

## 4.2. Cálculo da Rota Alternativa

O algoritmo *K Nearest Neighbors* (KNN) ou K (k-NN), também conhecido como k-Vizinhos mais próximos, utiliza o princípio de classificar e prever a proximidade dos vizinhos, de forma heurística e não paramétrica de aprendizado supervisionado, a partir de um ponto de dados individual. Para isso se utiliza os intervalos de frequência e o número de K Vizinhos mais próximos que são traduzidos para rotas com as melhores condições de alcançar o destino.

Para efetuar a classificação adota-se uma tabela com as densidades e velocidades estabelecidas pelo *Highway Capacity Manual* (HCM), que servirão como

dados de entrada para identificar o nível de serviço de uma determinada aresta, conforme podemos avaliar na Tabela 2 (HCM, 2000).

A distribuição de Pareto foi nomeada em homenagem ao economista Vilfredo Pareto, também conhecido como distribuição de Bradford. Trata-se de uma distribuição de probabilidade da lei da potência, utilizada primeiramente para descrever a distribuição da riqueza na área da economia e depois estendida para estudos da área de seguridade, na exploração de campos de petróleo, estatísticas de acesso à Internet, e outras aplicações de estatísticas de uso geral (REISS; THOMAS, 2001).

**Tabela 2.** Classificação dos níveis de serviço.

Peso	Nível de Serviço	Percepção	Velocidade (km/hora)	Limitação em Manhattan
1	A	Livre	Velocidade $\geq 107,8$	Acima do limite
2	B	Livre	$107,0 \geq$ Velocidade $< 107,8$	Acima do limite
3	C	Livre	$106,2 \geq$ Velocidade $< 107,0$	Acima do limite
4	D	Livre	$74,0 \geq$ Velocidade $< 106,2$	Acima do limite
5	E	Moderado	$56,3 \geq$ Velocidade $< 74,0$	Avenidas = 88 km/h
6	F	Congestionado	Velocidade $< 56,0$	Ruas = 48 km/h

Fonte: Adaptada de *Highway Capacity Manual* - HCM (2000).

A classificação e a distribuição das amostras de uma distribuição de Lomax ou Pareto II (REISS; THOMAS, 2001) podem ser aplicadas de forma específica, onde o próximo valor na lista de distribuição representa o K Vizinhos mais próximos, que define o cálculo da probabilidade para a distribuição de Pareto II necessita de dois parâmetros de entrada, onde  $a$  é o parâmetro de forma e o  $m$  de escala, em que  $x$  é o valor mínimo possível (necessariamente positivo) de  $X$ , conforme a equação a seguir (REISS; THOMAS, 2001).


$$p(x) = \frac{am^a}{x^{a+1}}$$

A distribuição de Lomax ou Pareto II (REISS; THOMAS, 2001) é uma variante da distribuição clássica de Pareto. Essa distribuição pode ser obtida a partir da distribuição Lomax adicionando 1 e multiplicando pelo parâmetro de escala  $m$ . O

menor valor da distribuição de Lomax é zero, enquanto para a distribuição clássica de Pareto tem uma localização  $m = 1$  (REISS; THOMAS, 2001).

Lomax também pode ser pensado como uma versão simplificada da distribuição generalizada de Pareto, com a escala  $m$  definida como 1 e uma localização definido como zero (REISS; THOMAS, 2001).

A distribuição de Pareto deve ser maior que zero e não possuir limite superior. Também é conhecida como a "regra 80-20". Nessa distribuição, 80% dos pesos estão na faixa superior, enquanto os outros 20% preenchem os 80% restantes da faixa, sendo que a distribuição muda a cada iteração, por se tratar de um modelo heurístico, o gráfico da esquerda apresenta a primeira iteração e o gráfico da direita a segunda iteração, com disposição diferente em termos de seleção de rotas candidatas, conforme Figura 3, onde o eixo X representa o K Vizinhos Mais Próximos Pareto (KNNP) e o eixo Y a quantidade de elementos a distribuir (REISS; THOMAS, 2001).



Fonte: Própria.

Devido ao caráter tempestivo da simulação, a distribuição de melhor aderência ao algoritmo KNNP foi a distribuição generalizada de Pareto, que atribui 80% das melhores rotas, que são selecionadas a partir dos pesos obtidos na fase de classificação, o algoritmo KNNR que apresenta o reverso da seleção de rotas candidatas pode ser uma solução alternativa (REISS; THOMAS, 2001).

A cada ciclo de iteração, conforme Figura 4 no Algoritmo 2 para cálculo do *K-Nearest Neighbors Pareto* (KNNP) apresenta a forma como são armazenados em uma base de dados, para as informações para as próximas simulações, e como se calcula os novos pesos, que são baseados na velocidade do veículo em comparação com os limites estabelecidos para cada faixa, buscando quais são os vértices do polígono a serem classificados, a solução é baseada em uma modificação do algoritmo de Yen (1971).

O Algoritmo 2 nas Linhas 2 e 3 (Figura 4) atribui os parâmetros de entrada, a um polígono (dPoligono), vértice origem (sOrigem), vértice de aprofundamento pela busca (sColetor), para efetuar uma pesquisa na abrangência do polígono por meio da função Astar (YEN, 1971).

Encontrado um vértice de aprofundamento, entre as Linhas 4 e 23, o algoritmo busca de acordo com o critério de classificação, uma rota alternativa, a qual nomeia com o apelido de "rota de estímulo". Nas Linhas 24 a 26 do algoritmo, são tratados os casos de inexistência de uma rota alternativa, ou rota de estímulo para aprofundar a busca (YEN, 1971).

Isso pode acontecer se as rotas de estímulo já tiverem sido esgotadas (portanto os vértices eleitos foram adicionados com sucesso ao vetor d Rota [kElem]), i.e., sobraram apenas vértices de origem e de aprofundamento que convergem em direção a "becos sem saída". Portanto na Linha 29, refere-se à Equação 2 de Lomax Pareto II, na Linha 30 é efetuada a ordenação de acordo com o critério de classificação do K Vizinhos mais próximos para o K Vizinhos subsequentes e atribui na Linha 31 as melhores rotas K, que são guardados no vetor dRota para posteriormente ser retornados para o programa que os invocou na Linha 34.

Na Linha 32 a função *pop* remove a Distribuição de Pareto, fazendo com que as sugestões de rotas sejam distribuídas uniformemente entre os veículos e permitindo permear o fluxo entre as ruas adjacentes, distribuindo o volume de veículos, portanto na Linha 33 retorna uma lista das rotas candidatas para que o motorista possa tomar a decisão de permanecer na rota habitual ou se dirigir a uma rota de estímulo que possa proporcionar uma chegada segura e com menor tempo de deslocamento para alcançar o destino, conforme Figura 4.

**Figura 4.** Algoritmo 2 para cálculo do K-Nearest Neighbors.

---

**Algorithm 2** Calculo do k-próximos vizinhos

---

```

1: function KNNPARETO(dPoligono, sOrigem, sColetor, K)
2:   dMenorRota ← Astar(dPoligono,sOrigem,sColetor) ▷ Determine a menor rota do vertice origem ao vertice
   do coletor.
3:   dRotaTemp ← ∅ ▷ Inicializa o conjunto para armazenar o k-ésimo caminho mais curto.
4:   for kElem from 1 to K do
5:     for iElem from 0 to tamanho(dMenorRota[kElem - 1]) - 2 do
6:       sEstimulo ← dMenorRota[kElem - 1].aresta(iElem) ▷ Recupera a aresta de estimulo da rota
       k-mais curto anterior
7:       dRotaEstimulo ← dMenorRota[kElem - 1].vertice(0, iElem) ▷ Recupera o vertice de estimulo da
       rota k-mais curto anterior
8:       dPoligonoOriginal ← dPoligono
9:       for dRota ∈ dMenorRota do
10:        if dRotaEstimulo ∈ dRota.vertice(0, iElem) then
11:          dPoligono.remove(dRota.vertice(iElem, iElem + 1)) ▷ Remove as ligações que compartilham
           parte da menor rota anterior
12:        end if
13:      end for
14:      for sAresta ∈ dMenorRota except sEstimulo do
15:        dPoligono.remove(sAresta)
16:      end for
17:      dRotaEstimulo ← Astar(dPoligono,sEstimulo,sColetor) ▷ Verifica se há Rota Estimulo
18:      dRotaCompleta ← dMenorRota + dRotaEstimulo
19:      if dRotaCompleta ∉ dRotaTemp then
20:        dRotaTemp.append(dRotaCompleta)
21:      end if
22:      dPoligono ← dPoligonoOriginal
23:    end for
24:    if dRotaTemp = ∅ then ▷ Verifica se há rotas de derivação
25:      break
26:    end if
27:    iForma ← 1
28:    iX ← tamanho(dRotaTemp)
29:    
$$dRotaTemp = \frac{iForma * iX^{iForma}}{iX^{iForma+1}}$$
 ▷ Equação Lomax ParetoII
30:    dRotaTemp.sort()
31:    dRotas[kElem] ← dRotaTemp[0]
32:    dRotaTemp.pop()
33:  end for
34:  return dRotas
35: end function

```

---

Fonte: Própria.



## 5. METODOLOGIA

O ITS – Sistema de Transporte Inteligente pode auxiliar a identificar e contribuir para a redução de congestionamentos de trânsito veicular, em conjunto com o *Wireless Access in Vehicular Environment (WAVE)* que pode assistir os motoristas a obterem um percurso rápido e seguro.

Sistemas de comunicação veicular cooperativos têm sido identificados como uma das tecnologias ITS que oferece um maior potencial para melhorar a segurança e a eficiência do tráfego por meio de troca contínua de informações entre V2V ou V2I (BAUZA; GOZALVEZ; SANCHEZ-SORIANO, 2010).

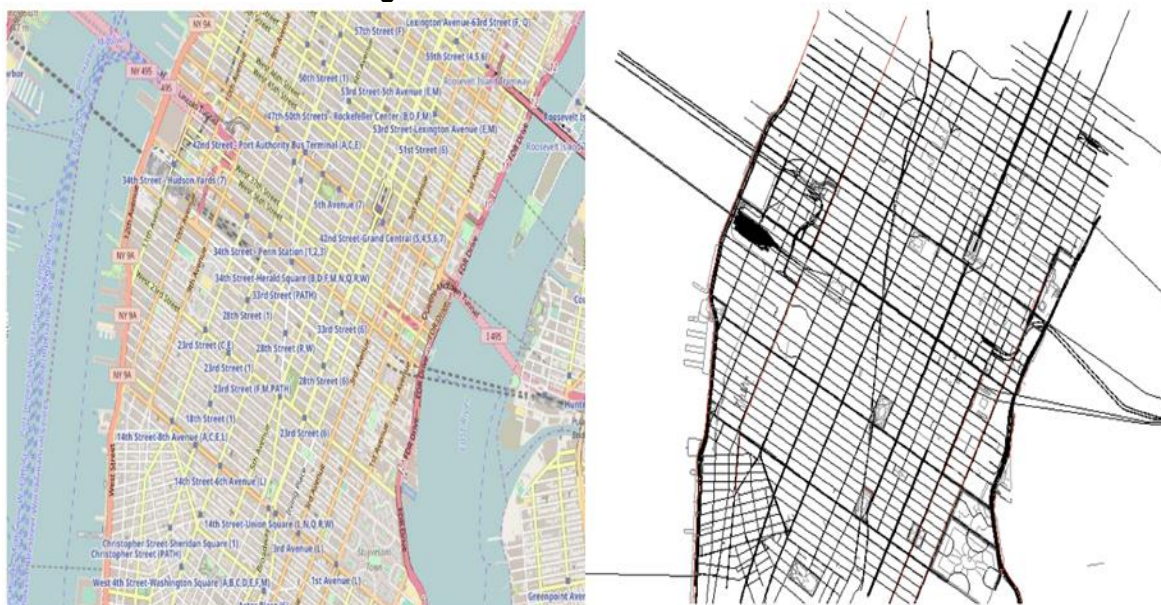
Para uma melhor organização, este capítulo foi dividido da seguinte forma: Consideração sobre o cenário de simulação alvo (Seção 5.1.), Ferramenta de simulação (Seção 5.2.) e Métricas de avaliação dos dados da simulação (Seção 5.3.).

### 5.1. Considerações sobre o cenário de simulação alvo

O estudo analisou a utilização do método de geoprocessamento para simulação de trânsito realístico, por meio da escolha do cenário microscópico do distrito de Manhattan em Nova York-EUA, obteve-se o mapa das ruas com as pistas, que após rigorosos testes de confiabilidade, pode ser apropriado e submetido ao programa *randomTrips* para a criação do polígono, que traduziu os cruzamentos em vértices e as ruas em arestas, coordenados por um sistema de localização baseado no plano cartesiano ou no sistema geodésico, pelas quais as rotas foram interligadas e utilizadas na simulação.

O cenário do distrito de Manhattan, Figura 5, é um cenário de simulação, conhecido pela comunidade acadêmica, extraído pelo *OpenStreetMap* que favorece a transposição da situação real de trânsito, em uma metrópole com horários de pico, extensos congestionamentos e capilaridade geométrica, a qual favorece a transposição de veículos de uma rota de difícil acesso para outra rota de melhor fluidez, que permite ao motorista conseguir alcançar o destino com: segurança, economia de tempo e menor gasto de combustível (MENEQUETTE *et al.*, 2016).

**Figura 5.** Cenário realístico de Manhattan.




Fonte: Retirada *OpenStreetMap* (2022).

O contexto desta pesquisa foi efetuar comparações do algoritmo alvo KNNP contra os algoritmos DSP, KNNB, KNNR e OVMT, para propor uma solução de roteamento que contribua para um melhor fluxo veicular urbano, detectando e evitando previamente congestionamento urbano, fazendo estimativas do tempo de deslocamento atual, contra o tempo de deslocamento fora do horário de pico, informando em tempo real a situação de tráfego e propondo rotas alternativas ao motorista (BEDOGNI *et al.*, 2015; SOUZA *et al.*, 2019).

Na Figura 6 é possível observar o cenário de simulação do distrito de Manhattan, após a conversão em um polígono, representado a partir da posição geodésica 40.7600°N 73.9800°W, extraída pelo programa *OsmWebWizard*. Então efetua-se uma chamada para o aplicativo *OpenStreetMap*, convertendo uma área geográfica em um polígono, submetido ao programa *randomTrips* para geração de um conjunto aleatório de viagens e posteriormente ao programa *Duarouter* que atribui um itinerário o qual converge para um estado de equilíbrio permitindo:

- a) Construir rotas de veículos a partir de definições de demanda;
- b) Computar uma nova rota durante uma atribuição de usuário;
- c) Reparar problemas de conectividade em arquivos de rota existentes.

**Figura 6.** Polígono do distrito de Manhattan 3km x 2km.



Fonte: Adaptado de *Netedit* (2022).

## 5.2. Ferramentas de Simulação

Como muitos outros simuladores microscópicos de tráfego, modelos SUMO, a topologia da rede viária é representada por um polígono composto por conjuntos de arestas (segmentos de ruas ou avenidas) e de vértices ou nós (os cruzamentos). Ambas as arestas e os vértices representam estruturas internas complexas. As arestas são estruturadas em pistas, enquanto os vértices definem todas as conexões possíveis entre as pistas que irão se interconectar, bem como semáforos que possivelmente possam existir.

A configuração manual de tais representações complexas é inviável em escalas maiores que alguns cruzamentos, o que exige a adoção de ferramentas que possam realizar uma configuração automatizada da rede viária. No caso do Sumo, a ferramenta de referência é *Netconvert*, que se baseia em dados de várias fontes cartográficas, dentre as quais o *OpenStreetMap* para construção do polígono, que representa a malha viária (BEDOGNI *et al.*, 2015; HAKLAY; WEBER, 2008).

### 5.2.1. TraCI

A Interface de controle de tráfego (TraCI) é um *software* desenvolvido por funcionários do Instituto de Sistemas de Transporte do Centro Aeroespacial Alemão

(DLR), que permite acesso à uma simulação de tráfego rodoviário em execução, bem como recuperar valores de objetos simulados e manipular seu comportamento *on-line*. É utilizado para configurar e alterar uma simulação de rotas exclusivas de transportes para: bicicletas, táxis, ônibus, veículos de emergência e pontos de parada usando o software SUMO, para obter um serviço de transporte responsivo à demanda.

### 5.2.2. OpenStreetMap

O aplicativo *OpenStreetMap* provê dados cartográficos para milhares de sites, aplicativos móveis e dispositivos de hardware, esses dados são abertos: qualquer pessoa tem a liberdade de usá-los para qualquer fim, desde que a autoria seja creditada ao *OpenStreetMap* e seus desenvolvedores, podendo ainda criar ou alterar tais dados que estão dispostos em arquivos padrão (HAKLAY; WEBER, 2008).


Preocupados com a disponibilidade de cenários de redes veiculares pela comunidade, a DLR provê o cenário *TAPAS Cologne* que inclui uma malha viária importada do *OpenStreetMap* e a demanda de tráfego para o período entre 6h00 e 8h00 da manhã. Infelizmente esse cenário é de difícil utilização e requer retrabalho para melhorar a qualidade da rede, além da verificação das rotas mapeadas, validação e o balanceamento da rede com a demanda de tráfego (CODECA; FRANK; ENGEL, 2015).

Devido à essas limitações, preferimos extrair o polígono do cenário de Manhattan, por intermédio do programa *OsmWebWizard* com as informações das coordenadas geodésicas, divulgadas pela comunidade acadêmica, isso dispensa a utilização do programa *Netconvert* para converter e retificar o polígono, gerando ganho de tempo, evitando assim erros durante a simulação.

### 5.2.3. Netedit

O programa *Netedit* é um editor gráfico de rede e está incluso no pacote do Sumo, permitindo uma validação e retificação dos vértices e arestas do arquivo gerado pelo *OpenStreetMap*. É recomendado que se elimine *deadlines* que possam gerar algum conflito na simulação, quando um vértice não pode convergir para um vértice adjacente. A Figura 7 mostra o mapa de Manhattan após essa retificação.

**Figura 7.** Polígono do distrito de Manhattan após retificação no Netedit.



Fonte: Adaptado de *Netedit* (2022).

#### 5.2.4. Simulador de Mobilidade Urbana

*Simulation of Urban Mobility* (SUMO) é um pacote de simulação de tráfego microscópico e contínuo de código aberto, altamente portátil, projetado para lidar com grandes redes viárias. Esse pacote permite a simulação intermodal incluindo pedestres e vem com um grande conjunto de ferramentas para a criação de cenários, corroborando para obtenção de estatísticas de utilização.

O Sumo é um conhecido software de simulação, com capacidade para geração, validação e avaliação de cenários realísticos de trânsito veicular microscópico.

Para submissão da rede viária, representada pelo polígono, a simulação das rotas do cenário de Manhattan, foram inspecionadas com o programa *Netedit*, aplicadas ao *randomTrips* para geração prévia da demanda de veículos e finalmente ao programa *Duarouter* para criação das rotas.

### 5.3. Métricas de avaliação dos dados da simulação

As métricas extraídas do aplicativo *SUMO*, foram processadas de forma estatística e apresentadas no formato gráfico *boxplot*, obtido pela biblioteca *Matplotlib*. Foram considerados os seguintes indicadores:

- Duração média da viagem: Tempo médio decorrido gasto do ponto origem ao ponto destino durante a simulação;
- Distância média percorrida: Distância média percorrida do ponto origem ao ponto destino durante a simulação;
- Tempo médio de espera: Tempo médio que o veículo ficou parado no trânsito, durante a simulação;
- Tempo médio perdido ocasionado por lentidão: Tempo médio que o veículo perdeu no trânsito, por deslocar-se abaixo do limite de velocidade permitido durante a simulação;
- Gasto médio de combustível: Quantidade média de combustível gasto durante a simulação, considerando a partida do ponto origem até alcançar o ponto de destino.
- Emissão média de monóxido de carbono: Quantidade média de CO<sub>2</sub> emitido durante o deslocamento.

Esses indicadores fazem parte do estudo do algoritmo e foram considerados como fatores chave para escolha da melhor rota a ser sugerida ao motorista.

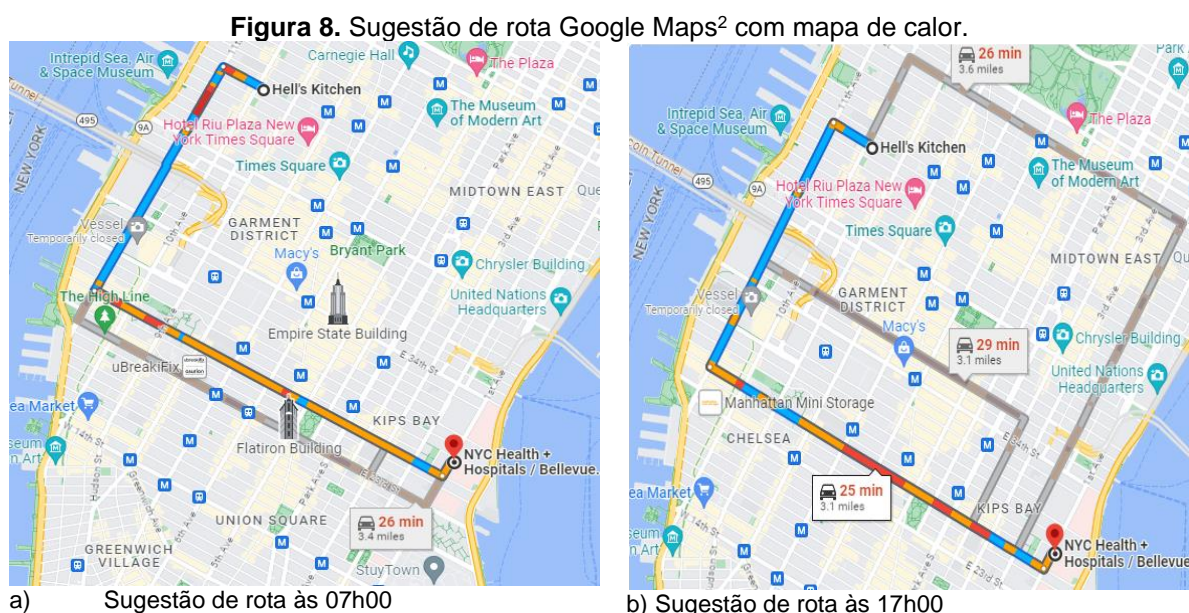
### 5.4. Extensão do Cenário de Simulação

A problematização está embasada no algoritmo para detectar o congestionamento, utilizando redes veiculares que parte das informações geradas por outros veículos, com a mensuração do tempo de resposta dos pacotes de dados recebidos das seguintes fontes: sinal de *beacons* equipados nos veículos para integração da comunicação intrarede veicular e sinal de celulares para veículos cujo motorista está no trânsito (BAUZA; GOZALVEZ; SANCHEZ-SORIANO, 2010).

### 5.4.1. Etapa de Diagnóstico e Validação dos Resultados

Na etapa de avaliação, constatou-se um grande problema com o traçado viário de mobilidade sintética, pois tratava-se do resultado de uma simulação e que, seria necessária a realização de uma validação dos resultados, como o apresentado nesse trabalho no cenário de Manhattan, ou no cenário de Bologna (BEDOGNI *et al.*, 2015), que foram realizados de forma robusta.

A ideia inicial foi comparar o polígono retificado com programa *Netedit* com o traçado real obtido pelo *Google Maps*<sup>2</sup>, bem como comparar os pontos de congestionamentos apresentados no modelo de simulação contra o mapa real, com os pontos críticos de congestionamento, obtidos pelas entidades de trânsito da região alvo da simulação, conforme Figura 6 que mostra o traçado original obtido de um itinerário, com pontos de congestionamento representados na forma de mapa de calor do ponto *Hell'sKitchen* até o *NYC Health Hospitals*, extraído no período da manhã conforme Figura 8a) contra a Figura 8b) avaliada no período da tarde. Percebe-se a alteração dos pontos de congestionamento representados pelas faixas em amarelo e vermelho.



Fonte: Retirada de *GoogleMaps* (2023).

A validação dos resultados é efetuada, pela comparação das estatísticas obtidas na simulação com os dados compilados na Tabela 3, tomando-se o algoritmo

*Original Vehicular Mobility Trace (OVMT)*, i.e., traçado veicular original sem roteamento define-se como *baseline*, portanto calculam-se as reduções obtidas no tempo de deslocamento, em comparação com os demais algoritmos, podendo destacar conforme Tabela 5, 53% para *Dynamic Shortest Path (DSP)*, o qual redireciona os veículos para a rota de menor caminho ou menor tempo, 54% para *K-Nearest Neighbors with Bellman Ford (KNNB)*, 54% para *K-Nearest Neighbors with Reverse Pareto (KNNR)* e 55% para o algoritmo *K-Nearest Neighbors with Pareto (KNNP)*.

**Tabela 3.** Indicadores de desempenho na densidade de 4000 veículos por km<sup>2</sup>.

<b>Indicadores de desempenho por veículo</b>	<b>DSP</b>	<b>KNN-B</b>	<b>KNN-P</b>	<b>KNN-R</b>	<b>OVMT</b>
Quantidade de veículos	4000	4000	4000	4000	4000
Data da simulação	25.05.23	25.05.23	25.05.23	25.05.23	25.05.23
Tempo de simulação	5400s	5400s	5400s	5400s	5400s
Algoritmo	Astar	Astar	Astar	Astar	Astar
Distância percorrida em m	2503,98	2499,36	2500,71	2499,36	2502,04
Tempo médio de viagem em s	507,28	499,54	483,73	499,54	1082,77
Tempo parado em congestionamento s	158,06	155,27	140,63	155,27	665,17
Tempo perdido em s	312,52	305,26	289,34	305,26	909,34
Atraso saída em s	1,67	2,87	0,90	2,87	1617,42
Gasto de combustível em l	0,374	0,369	0,376	0,363	0,524
Emissão CO <sub>2</sub> em M. ppm	1,174	1,158	1,180	1,137	1,643

Fonte: Própria.

Na Tabela 3, considerando o algoritmo OVMT como *baseline* para a densidade de 4000 veículos por km<sup>2</sup>, pode-se calcular as médias obtidas na simulação. Assim, podemos verificar o KNNP com o menor tempo parado em congestionamento com 140,63s e com o menor tempo perdido por deslocamento abaixo do limite permitido com 289,34s.

Na Tabela 4, considerando o mesmo algoritmo OVMT, porém com uma densidade de 2000 veículos por km<sup>2</sup>, as médias obtidas na simulação foram semelhantes, com o algoritmo KNNP, obtendo o menor tempo parado em congestionamento com 115,80s e com o menor tempo perdido por deslocamento abaixo do limite permitido com 258,45s.

Na Tabela 5, como a distância percorrida não apresenta variação na densidade de 4000 veículos por km<sup>2</sup>, podemos avaliar o tempo médio de viagem, tempo parado em congestionamento, tempo perdido e atraso na saída, que comparando com o



algoritmo OVMT, foi possível observar na coluna em verde que os indicadores representam uma ligeira vantagem para o algoritmo KNNP com os percentuais de -55%, -79%, -68% e -100%. Além dos indicadores de Gasto de combustível e Emissão CO<sub>2</sub> registrarem uma redução de 28%.

**Tabela 4.** Indicadores de desempenho na densidade de 2000 veículos por km<sup>2</sup>.

<b>Indicadores de Performance por Veículo</b>	<b>DSP</b>	<b>KNN-B</b>	<b>KNN-P</b>	<b>KNN-R</b>	<b>OVMT</b>
Quantidade de veículos	2000	2000	2000	2000	2000
Data da simulação	25.05.23	25.05.23	25.05.23	25.05.23	25.05.23
Tempo de simulação	5400s	5400s	5400s	5400s	5400s
Algoritmo	Astar	Astar	Astar	Astar	Astar
Distância percorrida em m	2514,44	2510,93	2511,53	2510,93	2510,88
Tempo médio de viagem em s	474,45	473,00	449,77	473,00	1038,93
Tempo parado em congestionamento s	137,34	132,56	115,80	132,56	610,66
Tempo perdido em s	283,59	281,37	258,45	281,37	865,20
Atraso saída em s	1,23	1,25	1,18	1,25	13,96
Gasto de combustível em l	0,374	0,369	0,376	0,363	0,524
Emissão CO <sub>2</sub> em M. ppm	1,174	1,158	1,180	1,137	1,643

Fonte: Própria.

**Tabela 5.** Variação % base algoritmo OVMT na densidade de 4000 veículos por km<sup>2</sup>.

<b>Indicadores de Performance por Veículo</b>	<b>% Variação DSP /OVMT</b>	<b>% Variação KNNB /OVMT</b>	<b>% Variação KNNP /OVMT</b>	<b>% Variação KNNR /OVMT</b>
Distância percorrida em m	0%	0%	0%	0%
Tempo médio de viagem em s	-53%	-54%	-55%	-54%
Tempo parado em congestionamento s	-76%	-77%	-79%	-77%
Tempo perdido em s	-66%	-66%	-68%	-66%
Atraso saída em s	-100%	-100%	-100%	-100%
Gasto de combustível em l	-29%	-30%	-28%	-31%
Emissão CO <sub>2</sub> em M. ppm	-29%	-30%	-28%	-31%

Fonte: Própria.

Na Tabela 6, como a distância percorrida não apresenta variação na densidade de 2000veículos por km<sup>2</sup>, podemos avaliar os tempos médios de viagem, tempo parado em congestionamento, tempo perdido e atraso na saída, que comparado com o algoritmo OVMT, é possível observar na coluna em verde que os indicadores representam uma ligeira vantagem para o algoritmo KNNP com os percentuais de -

57%, -81%, -70%, e -92%. Além dos indicadores de Gasto de combustível e Emissão CO<sub>2</sub> registrarem uma redução de 28%.

**Tabela 6.** Variação % base algoritmo OVMT na densidade de 2000 veículos por km<sup>2</sup>.

<b>Indicadores de Performance por Veículo</b>	<b>% Variação DSP /OVMT</b>	<b>% Variação KNNB /OVMT</b>	<b>% Variação KNNP /OVMT</b>	<b>% Variação KNNR /OVMT</b>
Distância percorrida em m	0%	0%	0%	0%
Tempo médio de viagem em s	-54%	-54%	-57%	-54%
Tempo parado em congestionamento s	-78%	-78%	-81%	-78%
Tempo perdido em s	-67%	-67%	-70%	-67%
Atraso saída em s	-91%	-91%	-92%	-91%
Gasto de combustível em l	-29%	-30%	-28%	-31%
Emissão CO <sub>2</sub> em M. ppm	-29%	-30%	-28%	-31%

Fonte: Própria.


## 6. RESULTADOS E DISCUSSÃO

### 6.1. Diagnóstico

Durante a fase de diagnóstico foi efetuada a comparação entre algoritmos utilizando o SUMO como simulador de mobilidade. O algoritmo de avaliação do congestionamento utiliza dados estatísticos, obtidos pelos principais algoritmos entregues e comumente aceitos pelo mercado, durante o período de simulação.


Para aplicação do algoritmo de avaliação foi considerada uma área urbana de 6 km<sup>2</sup> da cidade de Manhattan, para um cenário hipotético de 2000 e 4000 veículos por km<sup>2</sup>. Os resultados apresentados na forma de gráficos de linha e gráfico de caixa (*boxplot*), apresentam: a mediana, as quantias das métricas e estão divididas em: desempenho obtido pela redução do tempo de duração de viagem, diminuição do percurso, tempo médio de espera e finalmente por redução de emissão de gases de efeito estufa.

A Figura 9 mostra a duração da viagem por veículo, comparando as densidades de 2000 veículos por km<sup>2</sup>. O algoritmo KNNP apresentou o melhor tempo de 379,0s. O algoritmo KNNR, obteve também um bom desempenho, se comparado aos demais algoritmos com os seguintes tempos: 387,0s.



Fonte: Própria.

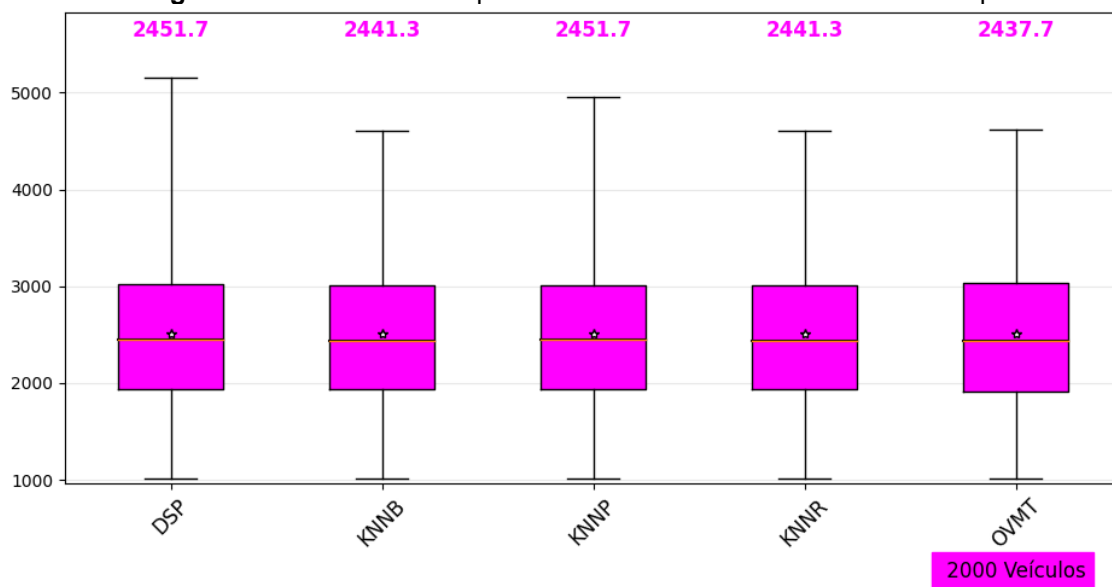
A Figura 10 mostra a duração média da viagem, comparando os algoritmos na densidade de 4000 veículos por km<sup>2</sup>. Embora o algoritmo KNNP, novamente tenha obtido o melhor desempenho se comparado com os demais algoritmos com o seguinte tempo: 393,0s, por percorrer uma distância maior. Essa métrica é inversamente proporcional à distância média percorrida, onde percebe-se na Figura 11 e na Figura 12, que o algoritmo KNNP por tomar uma rota alternativa de estímulo, teve um deslocamento maior, em relação aos demais algoritmos.



Fonte: Própria.

Na Figura 11, foram avaliados os resultados obtidos com as distâncias médias percorridas por algoritmo, onde o algoritmo OVMT esteve presente como *baseline*, na densidade de 2000 veículos por km<sup>2</sup> obtendo a distância de 2437,7m, para efeito de comparação com os algoritmos DSP, KNNB, KNNP, e KNNR, que distribuíram os veículos por outras rotas alternativas, deixando a rota habitual, para seguir uma sugestão de rota, objetivando economia de combustível e redução de tempo de deslocamento, pela distância percorrida ligeiramente superior para alcançar o destino.


**Figura 11.** Distância média percorrida na densidade de 2000 veículos por km<sup>2</sup>.



Fonte: Própria.


A Figura 12, mostra a distância média percorrida, na densidade de 4000veículos por km<sup>2</sup>, onde o algoritmo KNNR apresentou o melhor desempenho, obtendo 2431,1m. O algoritmo KNNP obteve uma boa *performance*, se comparado com os demais algoritmos, alcançando o tempo de 2438,6m, considerando um ligeiro aumento na distância para compensar um menor tempo médio de deslocamento, se comparado ao *baseline* OVMT.

**Figura 12.** Distância média percorrida na densidade de 4000 veículos por km<sup>2</sup>.



Fonte: Própria.

A Figura 13 mostra o tempo médio de espera na densidade de 2000 veículos por km<sup>2</sup>, o algoritmo KNNP e o algoritmo KNNR performaram respectivamente com o tempo de 67,0s e 70,0s, significativamente melhor se comparado com o algoritmo OVMT que obteve 150,0s.



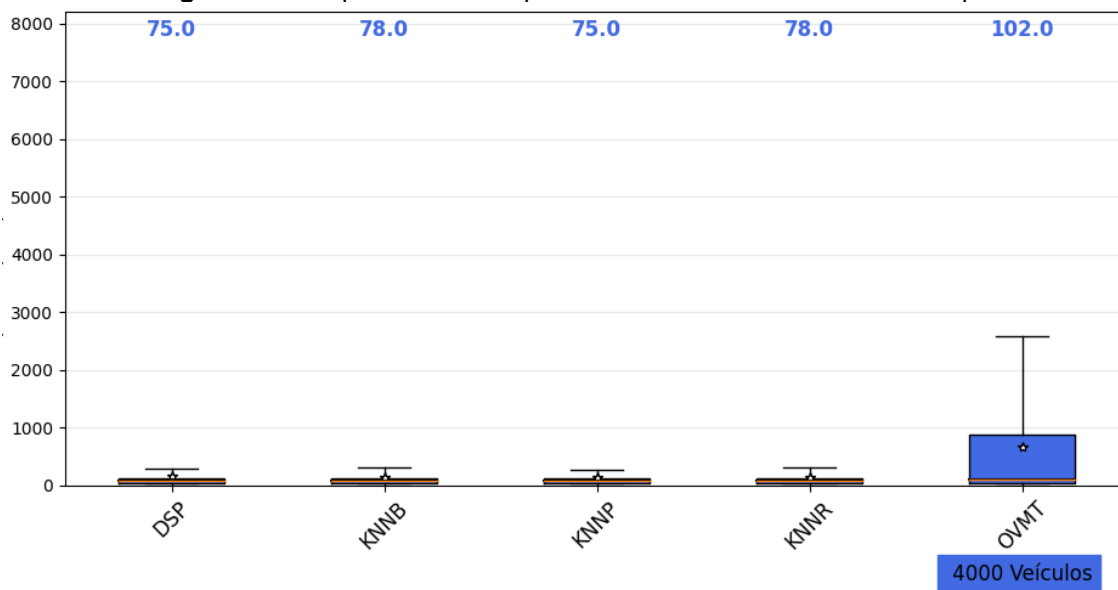
Fonte: Própria.

A Figura 14 está mostrado o tempo médio de espera para a densidade de 4000 veículos por km<sup>2</sup>, em que o algoritmo KNNP obteve o melhor desempenho no cenário de Manhattan, performando os tempos de 75,0s. O tempo o tempo médio que o veículo ficou parado no trânsito, considera todo o tempo que involuntariamente o veículo ficou retido no trânsito, durante o cálculo da simulação.

A Figura 15 representa o gasto de combustível médio por veículo após roteamento, para a densidade de 2000 veículos por km<sup>2</sup>, a melhor média obtida, foi alcançada com o algoritmo KNNP com a cifra de 0,365l. O pior desempenho, dentre os algoritmos de roteamento foi obtido pelo algoritmo DSP, que alcançou a cifra de 0.374l se comparado com os demais algoritmos de roteamento. O gasto de combustível é proporcional ao tempo de duração do percurso, de forma que quanto menor o tempo, menor será o gasto de combustível.


Este mesmo indicador influencia a emissão de monóxido de carbono, pois a quantidade de queima de combustível fóssil é diretamente proporcional à quantidade de partes por milhão (ppm) e poluentes emitidos.

**Figura 14.** Tempo médio de espera na densidade de 4000 veículos por km<sup>2</sup>.



Fonte: Própria.


**Figura 15.** Gasto médio de combustível na densidade de 2000 veículos por km<sup>2</sup>.



Fonte: Própria.

A Figura 16 apresenta o gasto médio com combustível para a densidade de 4000 veículos por km<sup>2</sup>, novamente o algoritmo KNNP obteve o melhor desempenho no cenário de Manhattan, performando a quantidade de 0,376l, a justificativa é devido à obtenção do melhor tempo na duração média da viagem conforme Figura 10.


**Figura 16.** Gasto médio de combustível na densidade de 4000 veículos por km<sup>2</sup>.



Fonte: Própria.

A Figura 17, representa o tempo médio perdido por lentidão, esse indicador representa o tempo perdido, devido ao veículo estar se deslocando a uma velocidade inferior ao limite máximo permitido na via, a menor tempo médio obtido, foi com o algoritmo KNNP para a densidade de 2000 veículos por km<sup>2</sup>, com a cifra de 181,7s.

**Figura 17.** Tempo médio perdido por lentidão na densidade de 2000 veículos por km<sup>2</sup>.

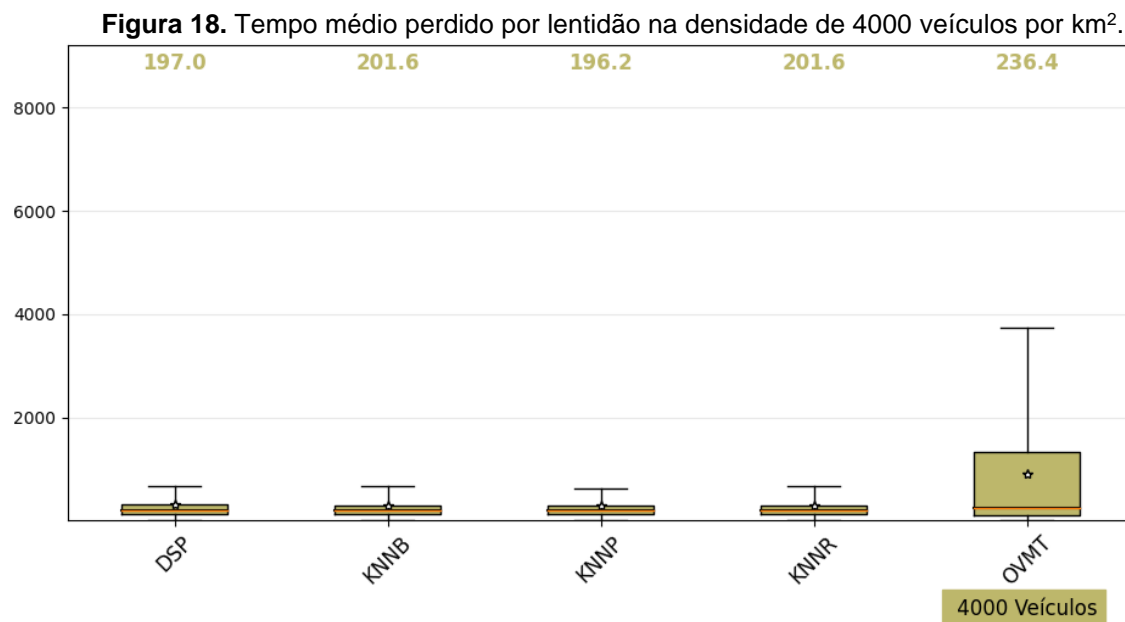


Fonte: Própria.

Na Figura 18, está mostrado o tempo médio perdido na densidade de 4000 veículos por km<sup>2</sup>, onde o algoritmo KNNP, novamente obteve um ótimo desempenho



no cenário de Manhattan, desempenhando o tempo de 196,2s. Essa marca foi obtida devido ao roteamento sugerido pelo algoritmo KNNP.



Fonte: Própria.

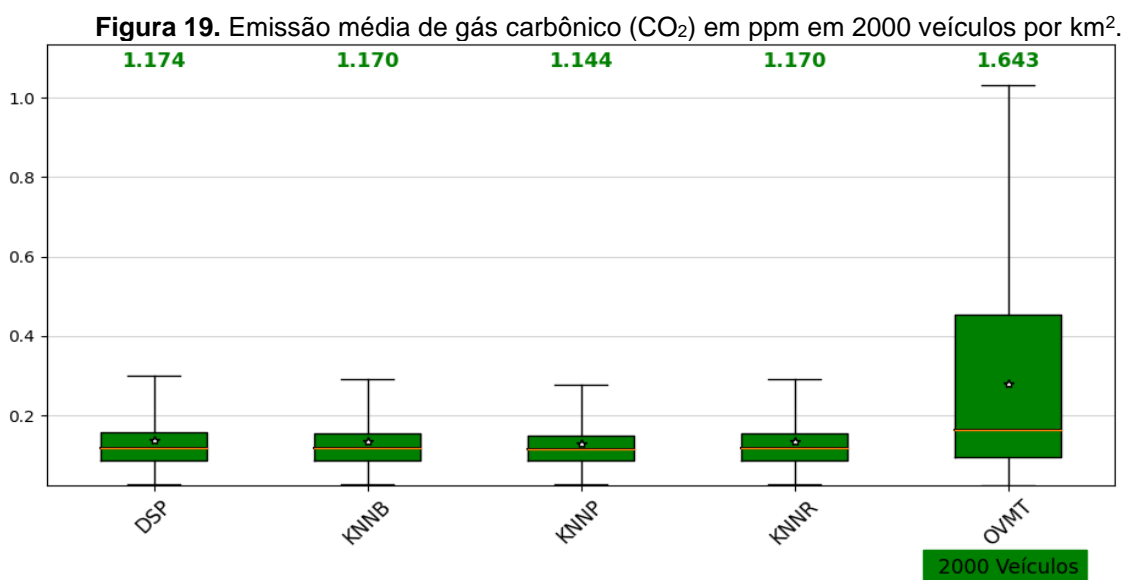
## 6.2. Execução

Neste capítulo está mostrado o resultado da execução do cenário de simulação, representado pelo cenário realístico de Manhattan, foram obtidos os padrões de consumo de combustível e emissão de poluentes na simulação, a partir da variação do K e do intervalo de cálculo das rotas.

No roteamento, tomando um cenário padrão, 70% dos veículos são equipados com algum dispositivo de roteamento, permitindo mudar a rota, se um congestionamento for encontrado. Nesta avaliação, as informações foram obtidas por intermédio de simulações no *software* Sumo, que utiliza do *Handbook Emission Factors for Road Transport* (HBEFA) para mensurar os fatores de emissão de poluentes à todas as categorias de veículos atuais (PC, LDV, HGV, ônibus urbanos, ônibus e motocicletas), sendo cada uma, dividida em diferentes categorias. Nesse cenário foram utilizados apenas veículos leves de passeio, apurados em partes por milhão (ppm).


Na Figura 19, pode-se analisar no cenário de 2000 veículos por km<sup>2</sup>, a média de emissões de CO<sub>2</sub> em 2000 partes por milhão (ppm), assumindo o algoritmo OVMT

como *baseline*, e efetuando comparação contra os algoritmos DSP, KNNB, KNNP e KNNR. O melhor resultado foi alcançado pelo algoritmo KNNP que obteve os seguintes resultados 1.144 ppm.



Fonte: Própria.


A Figura 20 apresenta a emissão média de gases CO<sub>2</sub>, para a densidade de 4000 veículos por km<sup>2</sup>, no qual o algoritmo KNNP, novamente obteve o melhor desempenho no cenário de Manhattan, obtendo à quantidade de 1180 milhares de partes por milhão (ppm). Esse indicador é calculado pelo consumo médio de combustível.



Fonte: Própria.

No cenário de simulação, foram efetuados vários ensaios para conseguir determinar o melhor K a ser adotado na simulação e o melhor intervalo de cálculo das rotas.


A Figura 21 apresenta um comparativo de qual o melhor K a ser adotado na simulação, para isso adotou-se o algoritmo KNNP como referência, o K=3 obteve o melhor desempenho no cenário de Manhattan, mantendo a menor duração de viagem em 379,0s quando comparado com os demais K para a densidade de 2000 veículos.




Fonte: Própria.

A Figura 22 apresenta um comparativo de qual o melhor K para a densidade de 2000 veículos por km<sup>2</sup>. E podemos observar que o K=3 obteve a menor duração média de viagem, marcando o tempo de 67,0s.

A Figura 23 apresenta a distância média percorrida para a densidade de 2000 veículos por km<sup>2</sup>, na perspectiva *K-Nearest Neighbors*, o K=3, foi o cenário que obteve o menor tempo de espera com 2441,6m quando comparado com os demais intervalos.


**Figura 22.** Tempo médio de espera por KNN em 2000 veículos por km<sup>2</sup>.

Fonte: Própria.

**Figura 23.** Distância média percorrida por KNN em 2000 veículos por km<sup>2</sup>.


Fonte: Própria.

A Figura 24 mostra um comparativo da duração média da viagem para a densidade de 2000 veículos por km<sup>2</sup>, comparando os seguintes intervalos de recálculo do nível de serviço: 120s, 180s e 240s. Para essa simulação adotou-se o algoritmo KNNP como referência, percebe-se que o intervalo de 120s obteve o melhor desempenho no cenário de Manhattan, obtendo a menor duração de viagem em 379,0s quando comparado com os demais intervalos.

**Figura 24.** Duração média da viagem por intervalo em 2000 veículos por km<sup>2</sup>.

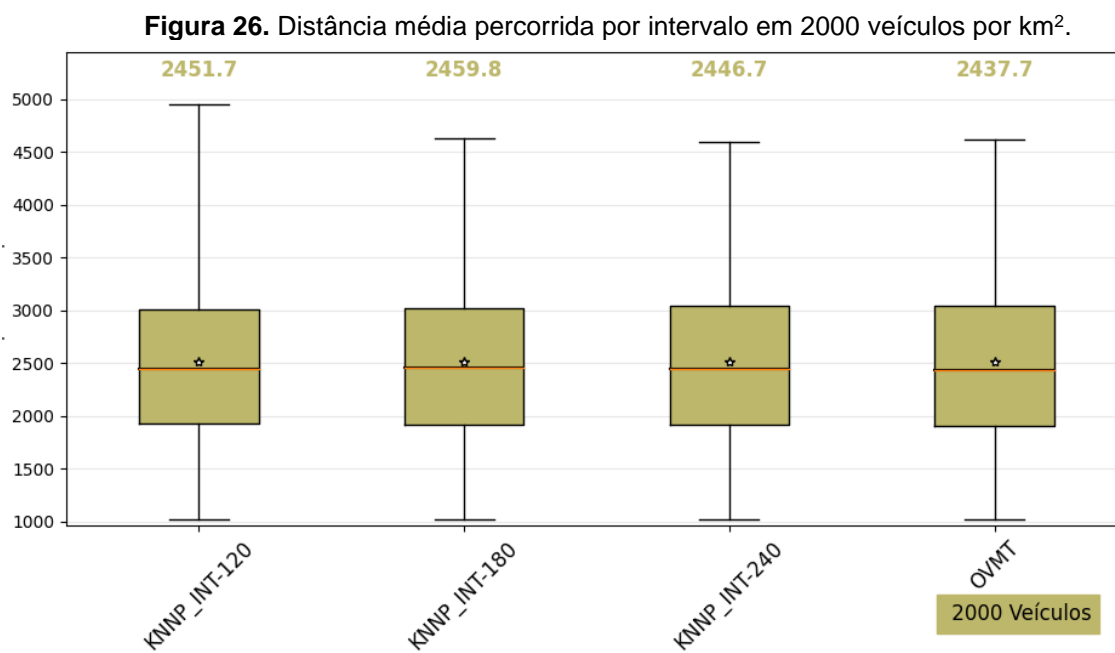
Fonte: Própria.

A Figura 25 apresenta um comparativo do tempo de espera médio na densidade de 2000 veículos por km<sup>2</sup>, para a perspectiva de intervalo de recálculo do nível de serviço, sendo o intervalo de 120s, o que obteve o menor tempo de espera com 67,0s quando comparado com os demais intervalos.

**Figura 25.** Tempo médio de espera por intervalo em 2000 veículos por km<sup>2</sup>.

Fonte: Própria.

A Figura 26 apresenta a distância percorrida média, na perspectiva de intervalo de recálculo do nível de serviço, levando em consideração a densidade de 2000 veículos por km<sup>2</sup>, avaliou-se que o intervalo de 240s, foi o que obteve a menor distância percorrida com 2446,7m quando comparado com os demais intervalos.



Fonte: Própria.

## 7. CONCLUSÃO

### 7.1. Da Aplicabilidade do Algoritmo

A proposta deste trabalho busca, com uma solução de algoritmo, detectar em um determinado cenário urbano realístico, com média e alta densidade de veículos, pontos de congestionamento e propor ao motorista dentro de um limite razoável de tempo, uma rota alternativa, calculada de forma determinística, para evitar que seu veículo adentre na área de congestionamento, reduzindo o tempo de espera e gasto com combustível para alcance do seu destino.

O objeto de estudo foram as vias no distrito de Manhattan-EUA representando um cenário ficcional na forma de um polígono, com a demanda de tráfego obtida a partir de artigos acadêmicos publicados, retificados, testados e disponibilizados pela comunidade acadêmica. As coordenadas geodésicas desse cenário foram importadas no SUMO por um arquivo padrão gerado no formato do *OpenStreetMap* OpenStreetMap (HAKLAY, 2008), representando a mão de direção, faixas de ciclista, pontes, viadutos, além de semáforos, e controladores de limites de velocidade estabelecidos.

O resultado esperado pelo trabalho é a obtenção de um algoritmo que possa oferecer a menor taxa de congestionamento, com o algoritmo KNN Pareto, que efetua uma rápida busca e encontrar a melhor solução com menor necessidade de processamento, sem a dependência de infraestrutura WAVE. Essa solução é comparada com outros algoritmos de roteamento como: OVMT, DSP, KNNB (*Bellman Ford*), KNNP (Pareto) e KNNR (Pareto Reverso), o resultado é armazenado para posteriormente ser disponibilizado aos motoristas que buscam uma solução alternativa de rota destino.

Outra aplicabilidade, senão a mais importante, seria para utilização de veículos de emergência, utilizando os dois algoritmos KNNP e KNNR, para buscar uma rota selecionável para ambulância e viaturas envolvidas no resgate de vítimas de acidentes de trânsito ou catástrofes provocados por fenômenos da natureza, onde um mínimo de tempo salvo no itinerário, pode significar o salvamento de vidas.

## 7.2. Proposta de Trabalhos Futuros

Como sugestão de trabalho futuro, com uma solução de algoritmo ganancioso, requer a adoção do algoritmo de Prims para *Minimum Spanning Tree*, que seria a busca pela aresta de menor peso na árvore estendida do grafo. O algoritmo é considerado ganancioso, quando a abordagem visa obter ganhos significativos em cada etapa de avaliação, de forma que nenhuma escolha bloqueia a outra.

Assim como no algoritmo de Kruskal, o algoritmo de Prims também possui uma abordagem de algoritmo ganancioso, porém com a vantagem de fazer consideração pela aresta de menor peso ponderado em cada etapa.

Esse algoritmo sempre começa por um único vértice e se move por meio dos vértices adjacentes, a fim de explorar todas as arestas conectadas no percurso de uma rota. Depois de escolher a aresta com menor peso ponderado, o algoritmo toma a extremidade oposta da aresta para formar a árvore estendida.

O algoritmo Prims apresenta vantagens sobre o algoritmo *Dynamic Shortest Path* (DSP), fazendo a escolha localmente da melhor rota candidata em cada estágio da simulação formando um sub grafo (T), que busca encontrar a melhor árvore dentro do grafo (G), sendo possível tomar um método de classificação mais agressivo que o algoritmo *K Nearest Neighbors* pois avalia a profundidade do Grafo.



## 8. REFERÊNCIAS

AKABANE, A. T. *et al.* Towards a distributed and infrastructure-less vehicular traffic management system. **Computer Communications**, v. 151, p.306-319, 2020. DOI: <https://doi.org/10.1016/j.comcom.2020.01.002>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S014036641930218X>. Acesso em: 07 set. 2021.

AKABANE, A. T. *et al.* iMOB: An intelligent urban mobility management system based on vehicular social networks. IEEE Vehicular Networking Conference (VNC), p. 1-8, 2018a. DOI: [10.1109/VNC.2018.8628436](https://doi.org/10.1109/VNC.2018.8628436). Disponível em: <https://ieeexplore.ieee.org/document/8628436>. Acesso em: 29 out. 2021.

AKABANE, A. T. *et al.* Distributed egocentric betweenness measure as a vehicle selection mechanism in vanets: A performance evaluation study. **Sensors**, v. 18, 2018b. DOI: <https://doi.org/10.3390/s18082731>. Disponível em: <https://www.mdpi.com/1424-8220/18/8/2730>. Acesso em: 02 jun. 2021.

AKABANE, A. T.; VILLAS, L. A.; MADEIRA, E. R. M. An adaptive solution for data dissemination under diverse road traffic conditions in urban scenarios. **IEEE Wireless Communications and Networking Conference (WCNC)**, p. 1654 – 1659, 2015. DOI: [10.1109/WCNC.2015.7127716](https://doi.org/10.1109/WCNC.2015.7127716). Disponível em: <https://ieeexplore.ieee.org/document/7127716>. Acesso em: 11 out. 2021.

ARAÚJO, G. B. *et al.* CARTIM: A proposal toward identification and minimization of vehicular traffic congestion for VANET. **IEEE Symposium on computers and communications (ISCC)**, p. 1-6, 2014. DOI: [10.1109/ISCC.2014.6912491](https://doi.org/10.1109/ISCC.2014.6912491). Disponível em: <https://ieeexplore.ieee.org/document/6912491>. Acesso em: 17 jul. 2022.

BAUZA, R.; GOZALVEZ, J.; SANCHEZ-SORIANO, J. Road traffic congestion detection through cooperative vehicle-to-vehicle communications. **IEEE Local Computer Network Conference**, p. 606–612, 2010. DOI: [10.1109/LCN.2010.5735780](https://doi.org/10.1109/LCN.2010.5735780). Disponível em: <https://ieeexplore.ieee.org/document/5735780>. Acesso em: 08 nov. 2022.

BEDOGNI, L. *et al.* The Bologna Ringway Dataset: Improving Road Network Conversion in SUMO and Validating Urban. **IEEE Transactions on Vehicular Technology**, v. 64, n. 12, p. 5464-5476, 2015. DOI: [10.1109/TVT.2015.2475608](https://doi.org/10.1109/TVT.2015.2475608). Disponível em: <https://ieeexplore.ieee.org/abstract/document/7234936>. Acesso em: 05 dez. 2022.

CODECA, L.; FRANK, R.; ENGEL, T. Luxembourg SUMO Traffic (LuST) Scenario: 24 hours of mobility for vehicular networking research. **IEEE Vehicular Networking Conference**, p. 1- 8, 2015. DOI: [10.1109/VNC.2015.7385539](https://doi.org/10.1109/VNC.2015.7385539). Disponível em: <https://ieeexplore.ieee.org/abstract/document/7385539>. Acesso em: 17 mai. 2023.

DIMITRAKOPOULOS, G. J.; UDEN, L.; VARLAMIS, I. **The future of intelligent transport systems**. Elsevier, p.199-246, 2020. DOI: <https://doi.org/10.1016/C2018-0-02715-2>. Acesso em: 15 set. 2021.

DIMITRAKOPOULOS, G.; DEMESTICHAS, P. Intelligent transportation systems. **IEEE Vehicular Technology Magazine**, v. 5, n. 1, p. 77 – 84, 2010. DOI: 10.1109/MVT.2009.935537. Disponível em: <https://ieeexplore.ieee.org/abstract/document/5430544>. Acesso em: 17 mai. 2023.

DONATO, E. A. *et al.* Impact of 802.11p channel hopping on VANET communication protocols. **IEEE Latin America Transactions**, v. 13, n. 1, p. 315 - 320, 2015. DOI: 10.1109/TLA.2015.7040664. Disponível em: <https://ieeexplore.ieee.org/abstract/document/7040664>. 02 ago. 2021. Acesso em: 18 maio 2023.

DOOLAN, R.; MUNTEAN, G. M. EcoTrec: A Novel VANET-Based Approach to Reducing Vehicle Emissions. **IEEE Transactions on Intelligent Transportation Systems**, v. 18, n. 3, p. 608 – 620, 2017. DOI:10.1109/TITS.2016.2585925. Disponível em: <https://ieeexplore.ieee.org/abstract/document/7534846>. Acesso em: 25 mar. 2021.

HAKLAY, M.; WEBER, P. Openstreetmap: User-generated Street maps. **IEEE Pervasive Computing**, v. 7, n. 4, p.12-18, 2008. DOI: 10.1109/MPRV.2008.80. Disponível em: <https://ieeexplore.ieee.org/document/4653466>. Acesso em: 08 out. 2022.

HARTENSTEIN, H.; LABERTEAUX, L. P. A tutorial survey on vehicular ad hoc networks. **IEEE Communications Magazine**, v. 46, n. 6, p.164-171, 2008. DOI: 10.1109/MCOM.2008.4539481. Disponível em: <https://ieeexplore.ieee.org/document/4539481>. Acesso em: 03 out. 2022.

HCM. **Highway Capacity Manual**. Transportation Research Board (TRB), National Research Council, Washington, DC, 2010. Disponível em: [https://epdfx.com/hcm-2010\\_5c9dc5b7e2b6f5d161fe4e59\\_pdf.html](https://epdfx.com/hcm-2010_5c9dc5b7e2b6f5d161fe4e59_pdf.html). Acesso em: 15 ago. 2021.

INRIX. **Global Traffic Scorecard**. City Ranking List, 2022. Disponível em: <https://inrix.com/scorecard/>. Acesso em: 21 abr. 2023.

KARAGIANNIS, G. *et al.* Vehicular networking: A survey and tutorial on requirements, architectures, challenges, standards and solutions. **IEEE Communications Surveys & Tutorials**, v. 13, n. 4, p. 584-616, 2011. DOI: 10.1109/SURV.2011.061411.00019. Disponível em: <https://ieeexplore.ieee.org/document/5948952>. Acesso em: 29 jun. 2022.

LI, F.; WANG, Y. Routing in Vehicular ad hoc networks: A Survey. **IEEE Vehicular Technology Magazine**, v. 2, n. 2, p.12-22, 2007. DOI: 10.1109/MVT.2007.912927. Disponível em: <https://ieeexplore.ieee.org/document/4450627>. Acesso em: 04 fev. 2022.

LOMAX, T. *et al.* **Quantifying congestion**. Washington, DC: Transportation Research Board, National Cooperative Highway Research program (NCHRP), Report 398, v. 1, 1997. Disponível em: [https://onlinepubs.trb.org/onlinepubs/nchrp/nchrp\\_rpt\\_398.pdf](https://onlinepubs.trb.org/onlinepubs/nchrp/nchrp_rpt_398.pdf). Acesso em: 24 jul. 2022.

MENEGUETTE, R. I. *et al.* Increasing Intelligence in Inter-Vehicle Communications to Reduce Traffic Congestions: Experiments in Urban and Highway Environments. **PLoS ONE**, v. 11, n. 8, 2016. DOI: <https://doi.org/10.1371/journal.pone.0159110>. Disponível em: <https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0159110>. Acesso em: 09 set. 2022.

NAM, T.; PARDO, T. A. Conceptualizing smart city with dimension of technology, people, and institutions. *In: Annual International Digital Government Research Conference on Digital Government Innovation in Challenging Times*, 12., 2011, New York-USA. **Anais Eletrônicos** [...]. New York: DL ACM, 2011. p. 282-291. Disponível em: <http://dx.doi.org/10.1145/2037556.2037602>. Acesso em: 17 mai. 2023.

QURESHI, K. N.; ABDULLAH, A. H. A survey on intelligent transportation systems. **Middle East Journal of Scientific Research**, v. 15, n. 5, p. 629-642, 2013. DOI: 10.5829/IDOSI.MEJSR.2013.15.5.11215. Disponível em: [https://www.idosi.org/mejsr/mejsr15\(5\)13/4.pdf](https://www.idosi.org/mejsr/mejsr15(5)13/4.pdf). Acesso em: 30 out. 2022.

REISS, R. D.; THOMAS, M. **Statistical Analysis of Extreme Values**. Birkhauser Verlag, Basel, Third Edition, pp. 23-30, 2001.

RODRIGUES, D. O. *et al.* SMAFramework: Urban data integration framework for mobility analysis in smart cities. *In: ACM International Conference on Modelling*, 20., 2017, Miami, Florida- USA. **Anais Eletrônicos** [...]. Miami: DL ACM, 2017. p. 227-236. Disponível em: <https://doi.org/10.1145/3127540.3127569>. Acesso em: 17 mai. 2023.

SILVA, D. M. da. **Sistemas inteligentes no transporte público coletivo por ônibus**. 2000. Dissertação (Mestrado em Engenharia de Produção), Escola de Engenharia - Universidade Federal do Rio Grande do Sul, Porto Alegre, p.14-23. 2000.

SOUZA, A. M. de. *et al.* Traffic management systems: A classification, review, challenges, and future perspectives. *International Journal of Distributed Sensor Networks*, v.13, n. 4, 2017. DOI: 10.1177/1550147716683612. Disponível em: <https://journals.sagepub.com/doi/full/10.1177/1550147716683612>. Acesso em: 18 mar. 2021.

SOUZA, A. M. *et al.* Better safe than sorry: a vehicular traffic re-routing based on traffic conditions and public safety issues. **Journal of Internet Services and Applications**, v. 10, n. 17, 2019. DOI: <https://doi.org/10.1186/s13174-019-0116-9>. Disponível em: <https://jisajournal.springeropen.com/articles/10.1186/s13174-019-0116-9>. Acesso em: 17 dez. 2022.

VILLAS, L. A. *et al.* DRIVE: An efficient and robust data dissemination protocol for highway and urban vehicular ad hoc networks. **Computer Networks**, v. 75, p. 381 - 394, 2014. DOI: <https://doi.org/10.1016/j.comnet.2014.10.012>. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1389128614003673>. Acesso em: 19 mai. 2021.

WANG, R. *et al.* V2V-based method for the detection of road traffic congestion. **IET Intelligent Transport Systems**, v. 13, p. 880-885, 2019. DOI: <https://doi.org/10.1049/iet-its.2018.5177>. Disponível em:

<https://ietresearch.onlinelibrary.wiley.com/doi/10.1049/iet-its.2018.5177>. Acesso em: 16 ago. 2022.

YEN, J. Y. Finding the K Shortest Loopless Paths in a Network. **Management Science**, v. 17, n. 11, p. 712 – 716, 1971. Disponível em: <http://www.jstor.org/stable/2629312>. Acesso em: 02 out. 2022.