

FACULDADE DE TECNOLOGIA
UNIVERSIDADE DE BRASÍLIA

**UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA CIVIL E AMBIENTAL**

**MODELO INTELIGENTE DE CONTROLE ADAPTATIVO
DE TRÁFEGO URBANO**

FÁBIO DE SOUZA PEREIRA BORGES

ORIENTADOR: REINALDO CRISPINIANO GARCIA

TESE DE DOUTORADO EM TRANSPORTES

**PUBLICAÇÃO T.TD-01/2022
BRASÍLIA/DF: JANEIRO – 2022**

**UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA CIVIL E AMBIENTAL**

**MODELO INTELIGENTE DE CONTROLE ADAPTATIVO DE
TRÁFEGO URBANO**

FÁBIO DE SOUZA PEREIRA BORGES

TESE DE DOUTORADO SUBMETIDA AO DEPARTAMENTO DE ENGENHARIA CIVIL E AMBIENTAL DA FACULDADE DE TECNOLOGIA DA UNIVERSIDADE DE BRASÍLIA COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE DOUTOR EM TRANSPORTES

APROVADA POR:

**Prof. Reinaldo Crispiniano Garcia, Ph.D. (UnB)
(orientador)**

**Prof. Sérgio Ronaldo Granemann, D.Sc. (UnB)
(examinador interno)**

**Prof. Li Weigang, D.Sc. (UnB)
(examinador externo)**

**Prof. Werner Kraus Jr. Ph.D. (UFSC)
(examinador externo)**

**Prof. Claudio Luiz Marte Ph.D. (USP)
(examinador externo)**

BRASÍLIA/DF, 27 DE JANEIRO DE 2022.

FICHA CATALOGRÁFICA

BORGES, FÁBIO S. P.

Modelo inteligente de controle adaptativo de tráfego urbano. Brasília, 2022
xix, 172 p., 210 x 297 mm (ENC/FT/UnB, Doutor, Transportes, 2022).

Tese de Doutorado – Universidade de Brasília. Faculdade de Tecnologia.

Departamento de Engenharia Civil e Ambiental.

1. Controle de Tráfego Urbano 2. Otimização de Planos Semafóricos

3. Previsão de Fluxos de Tráfego 4. Técnicas de Inteligência Artificial

I. ENC/FT/UnB

II. Título (série)

REFERÊNCIA BIBLIOGRÁFICA

BORGES, FÁBIO S. P. (2022) Modelo inteligente de controle adaptativo de tráfego urbano.

Tese de Doutorado em Transportes Publicação T.TD-001/2022, Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, DF 172 p.

CESSÃO DE DIREITOS

AUTOR: Fábio de Souza Pereira Borges

TÍTULO: Modelo inteligente de controle adaptativo de tráfego urbano.

Tese de Doutorado em Transportes.

GRAU: Doutor ANO: 2022.

É concedida à Universidade de Brasília permissão para reproduzir cópias desta tese de doutorado e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte dessa Tese de Doutorado pode ser reproduzida sem autorização por escrito do autor.

Fábio de Souza Pereira Borges

Endereço: SHTQ, Qd. 2, Cj. 4, Casa 1, Lago Norte

CEP 71.551-216, Brasília, DF, Brasil.

fabiospb@gmail.com

DEDICATÓRIA

Todo trabalho exaustivo e extenso como este requer incentivo, inspiração e entusiasmo.

Por isso, dedico este trabalho aos meus pais pelo incentivo incondicional desde a minha infância, quando eles envidaram todos os esforços para que eu pudesse estudar e alcançar degraus cada vez mais elevados na minha formação acadêmica.

Também, preciso dedicar este trabalho aos meus filhos Pedro e Yasmin Ferreira Borges. Acima de tudo, eles me inspiraram a começar e, depois, a superar todos os desafios que surgiram. A esperança de legar para eles um senso de compromisso e dedicação com os estudos e bons resultados foi o que mais me impulsionou a frente.

Ainda, preciso dedicar este trabalho à minha esposa que esteve ao meu lado durante todo o percurso desde o início. O seu entusiasmo com cada conquista me contagiou e fortaleceu.

Por fim, dedico este trabalho ao princípio de tudo, à Deus!

AGRADECIMENTOS

Este trabalho não resultou de alguns anos de curso apenas, mas sim de um histórico longo de influências, oportunidades, contribuições e aprendizados. Por isso, como sempre, eu agradeço primeiro à Deus pelo conjunto de variáveis e atributos que me permitiram chegar aqui. Depois, agradeço muito aos meus Pais: Waldyr e Marias das Neves, por toda a dedicação e o esforço incomensurável que empreenderam para me formar desde a minha infância.

Por óbvio, eu preciso agradecer ao Exército Brasileiro – a instituição fantástica que me proporcionou o amadurecimento pessoal e o aperfeiçoamento profissional por quase 30 anos. Aproveito esta oportunidade para agradecer especialmente aos *Senhores Gerais* Rogério Cetrim de *Siqueira*, Lauro Luis Pires da Silva e Daniel de Almeida *Dantas*, que, em momentos distintos, contribuíram pessoal e decisivamente para o meu êxito neste trabalho.

Além dos meus pais e do Exército, eu tive a sorte de ser assistido e influenciado por pessoas fantásticas no curso da minha vida: familiares, amigos, colegas, professores, chefes, pares e subordinados. Muitos me ajudaram a progredir e, por isso, nominar cada um deles seria uma tarefa hercúlea e, talvez, injusta na medida em que eu poderia valorar desproporcionalmente a contribuição de um deles por qualquer deficiência nas minhas referências.

Irmã, sobrinhos, afilhados, amigos de infância, amigos da caserna, avós, tios, primos e professores sintam-se prestigiados pelo meu reconhecimento e agradecimento. No coletivo dessas pessoas, eu devo nominar e agradecer à professora Adelaida Pallavicini Fonseca e ao professor Reinaldo Crispiniano Garcia que se revessaram sucessiva e dedicadamente como meus orientadores ao longo de todo o processo de pesquisa até a conclusão desta tese, a despeito de todos os desafios que os melhores professores como eles superam todos os dias.

Ainda, é imprescindível agradecer à minha esposa – Annebelle Ferreira Borges – pela parceria amorosa que me permitiu tranquilidade durante os meus momentos de ausência e, principalmente, pelo incentivo diante dos obstáculos e entusiasmo nos casos de êxitos.

Na pessoa de seu ex-Diretor-Geral, Silvain Barbosa F. Filho, agradeço ao DETRAN-DF e sua equipe pela seção dos dados e por toda a assistência proporcionada nas visitas e reuniões.

Preciso destacar que eu fui muito feliz durante essa pesquisa e que o seu resultado me satisfaz plenamente. No âmbito dessa felicidade e satisfação com o trabalho ora apresentado, assim como já fiz na dedicatória, eu preciso ressaltar a importância dos meus filhos – Pedro e Yasmin – e agradecer aos dois por me inspirarem e manterem o meu entusiasmo elevado.

RESUMO

MODELO INTELIGENTE DE CONTROLE ADAPTATIVO DE TRÁFEGO URBANO

Autor: Fábio de Souza Pereira Borges.

Orientador: Prof. Reinaldo Crispiniano Garcia, Ph.D.

Programa de Pós-graduação em Transportes – Universidade de Brasília.

Brasília, 27 de janeiro de 2022.

A infraestrutura viária urbana não pode crescer na mesma taxa de crescimento da frota de veículos a fim de reduzir os congestionamentos nas cidades porque existem limitações físicas e financeiras. Além disso, é preciso mitigar os prejuízos que os seus impactos provocam ao meio ambiente, à saúde pública e à economia com um custo elevado para toda a sociedade. Apenas na cidade de São Paulo, o custo total atribuído exclusivamente aos congestionamentos foi de US\$ 20,5 bilhões em 2012.

Muitas cidades brasileiras com congestionamentos urbanos ainda usam abordagens de controle de tráfego clássicas, que apresentam bons resultados em ambientes cujos fluxos variam de forma bem definida ao longo do dia, mas esse não é mais caso na maioria dos centros urbanos. Essas abordagens são inflexíveis porque não conseguem lidar com o dinamismo do fluxo de tráfego e determinar quais planos semaforicos são mais apropriados para cada instante do dia, o que é uma tarefa complexa com contagens e estudos dos fluxos de tráfego em diferentes pontos da rede, modelos de tráfego e uma equipe grande de profissionais.

Outras abordagens surgiram. Entre elas, ainda dependentes de modelos de tráfego, os sistemas comerciais de controle adaptativo de tráfego mais conhecidos, a partir dos anos 1980, podem reduzir os tempos de viagens em 29% ou acrescê-los até 10% e reduzir os atrasos entre 3% e 38%. Porém, os custos iniciais de implantação desses sistemas variam entre US\$ 6.000 e US\$ 60.000 por interseção, o que pode ser inviável para muitas cidades brasileiras.

Portanto, considerando que muitas cidades brasileiras têm ou terão a necessidade de um sistema moderno de controle adaptativo de tráfego que se ajuste facilmente às características de suas redes de trânsito e, preferencialmente, aproveite a malha de equipamentos eletrônicos de fiscalização veicular já instalados, conciliando necessidades operacionais e condições

financeiras, têm-se a oportunidade de desenvolver um sistema adaptativo e interativo como descrito para gerar decisões de controle ótimas empregando tecnologias disponíveis e atuais.

Nesse sentido, o presente trabalho propõe um modelo inteligente de controle adaptativo de tráfego urbano capaz de realizar previsões de tráfego de curta duração e otimizar planos semafóricos em tempo real, aplicando técnicas de inteligência artificial para controlar uma rede de tráfego. O modelo proposto acopla *Reinforcement Learning* para prever os fluxos de veículos e *Deep Reinforcement Learning* para otimizar os planos semafóricos.

Os resultados alcançados são bastante promissores. Na primeira etapa do modelo, o comportamento da rede de tráfego está muito bem representado em todos os dias e horários para todas as aproximações da rede, abrangendo um espectro bastante amplo e elástico desde as menores medidas de fluxo até as mais altas de forma aderente às sucessivas variações do tráfego. Os intervalos das previsões foram variados (1, 5 e 15 minutos) e os erros médios absoluto (MAE), relativo (MRE) e quadrático (RMSE) demonstram a consistência das respectivas previsões, afastando a possibilidade de *underfitting* e *overfitting*.

Na segunda etapa do modelo, os resultados obtidos são muito bons também seja para a dimensão da rede, interseção ou aproximação. Todos os parâmetros da rede de trânsito sofreram reduções expressivas em relação à condição original dada pelos planos semafóricos do Departamento de Trânsito Local. Os resultados alcançados foram compatíveis com os sistemas de controles adaptativos de tráfego comerciais, superando inclusive alguns resultados da literatura. Por exemplo, os atrasos reduziram entre 19% e 37%. As decisões tomadas para privilegiar sentidos mais demandados não prejudicaram os demais sentidos e garantiram um aumento do desempenho das aproximações, isoladamente ou não, demonstrando a capacidade do modelo de perceber e decidir em níveis de fluxos de tráfego elevados ou baixos.

Este trabalho utiliza dados brutos para gerir o estado do tráfego em tempo real, sem um modelo de tráfego e integra duas interseções em rede de forma centralizada. Contudo, se reduz os congestionamentos e maximiza o uso da infraestrutura atual postergando novas intervenções, as principais contribuições deste trabalho são a redução de impedâncias na movimentação de pessoas e cargas em centros urbanos e a flexibilização de investimentos e cronogramas de obras para adequação de capacidade das vias urbanas, além da simplicidade de operacionalizar o método que propõe a partir de tecnologias já disponíveis ou daquelas que estarão no ambiente viário inteligente das cidades do futuro.

ABSTRACT

SMART URBAN TRAFFIC ADAPTIVE CONTROL MODEL

Author: Fábio de Souza Pereira Borges.

Advisor: Prof. Reinaldo Crispiniano Garcia, Ph.D.

Graduate Program in Transportation - University of Brasilia

Brasilia, January 27th, 2022

Urban road infrastructure cannot grow at the same rate as the vehicle fleet in order to reduce congestion in cities because there are physical and financial limitations. In addition, it is necessary to mitigate the damage that its impacts cause to the environment, public health and the economy at a high cost to society as a whole. In the city of São Paulo alone, the total cost attributed exclusively to congestion was \$20.5 billion in 2012.

Many Brazilian cities with urban congestion still use classical traffic control approaches, which show good results in environments where flows vary well throughout the day, but this is no longer the case in most urban centers. These approaches are inflexible because they cannot cope with the dynamism of traffic flow and determine which traffic signal plans are most appropriate for each instant of the day, which is a complex task with counts and studies of traffic flows at different points in the network, traffic models, and a large team of professionals.

Other approaches have emerged. Among them, still dependent on traffic models, the best-known commercial adaptive traffic control systems, from the 1980s on, can reduce travel times by 29% or increase them by up to 10% and reduce delays by between 3% and 38%. However, the initial implementation costs of these systems range from US\$ 6,000 to US\$ 60,000 per intersection, which may be unfeasible for many Brazilian cities.

Therefore, considering that many Brazilian cities have or will have the need for a modern adaptive traffic control system that easily adjusts to the characteristics of their traffic networks and, preferably, takes advantage of the electronic vehicle inspection equipment already installed, reconciling operational needs and financial conditions, we have the oppor-

tunity to develop an adaptive and interactive system as described to generate optimal control decisions using available and current technologies.

In this sense, the present work proposes an intelligent model of urban adaptive traffic control capable of performing short-term traffic forecasts and optimizing traffic signal plans in real time, applying artificial intelligence techniques to control a traffic network. The proposed model combines Reinforcement Learning to predict vehicle flows and Deep Reinforcement Learning to optimize traffic signal plans.

The results achieved are quite promising. In the first stage of the model, the behavior of the traffic network is very well represented on all days and times for all network approaches, covering a very wide and elastic spectrum from the lowest to the highest flow measurements in an adherent way to successive traffic variations. The prediction intervals were varied (1, 5 and 15 minutes) and the mean absolute (MAE), relative (RSM) and root mean square (RMSE) errors demonstrate the consistency of the respective predictions, ruling out the possibility of underfitting and overfitting.

In the second stage of the model, the results obtained are also very good whether for network size, intersection or approach. All traffic network parameters were significantly reduced from the original condition given by the Local Traffic Department's traffic signal plans. The results achieved were compatible with commercial adaptive traffic control systems, even surpassing some results in the literature. For example, delays were reduced by between 19% and 37%. The decisions made to privilege the most demanded directions did not harm the other directions and guaranteed an increase in the performance of the approaches, alone or not, demonstrating the model's ability to perceive and decide at high or low traffic flow levels.

This work uses raw data to manage the state of traffic in real time, without a traffic model and integrates two intersections in a network centrally. However, if it reduces congestion and maximizes the use of the current infrastructure postponing new interventions, the main contributions of this work are the reduction of impedances in the movement of people and cargo in urban centers and the flexibility of investments and schedules of works to adapt the capacity of urban roads, besides the simplicity of its implementation from technologies already available or those that will be in the intelligent road environment of the cities of the future.

LISTA DE TABELAS

Tabela 1.1: Comparação entre os benefícios e custos dos principais sistemas de controle adaptativo de tráfego em tempo real usados nos EUA (ZHAO e TIAN, 2012).....	29
Tabela 5.1: Comparativo entre os erros associados às previsões da literatura e deste trabalho	123
Tabela 5.2: Comparativo entre os erros associados às previsões de tráfego deste trabalho para outros intervalos de previsão	123
Tabela 5.3: Extrato do plano semaforizado otimizado para toda a rede no sentido da via arterial.....	125
Tabela 5.4: Parâmetros de desempenho da rede obtidos por controle de tráfego com o plano semafórico inteligente, conforme micro simulações	125
Tabela 5.5: Melhorias obtidas pelos planos semafóricos adaptados em relação aos planos pré-existentes, conforme os resultados das simulações realizadas entre as 06:00 e 07:00h.	126
Tabela 5.6: Melhorias obtidas pelos planos semafóricos adaptados em relação aos planos pré-existentes, conforme os resultados das simulações realizadas entre as 07:00 e 08:00h	126
Tabela 5.7: Comparações entre os desempenhos do modelo proposto e dos principais sistemas de controle de tráfego adaptativo em uso nos EUA.....	128
Tabela 7.1: Medidas de Fluxo de Saturação feitas a partir dos dados disponíveis.	159
Tabela 7.2: Fluxos de saturação medidos em veículos por faixa por hora.....	161
Tabela 7.3: Coeficientes <i>Silhouette</i> para cada combinação entre as variáveis de classificação	166
Tabela 7.4: Parâmetros fundamentais de tráfego calibrados automaticamente em função das variáveis de classificação	167

LISTA DE QUADROS

Quadro 2.1: Resultados da pesquisa realizada na base de dados <i>Web of Science</i>	39
Quadro 2.2: Panorama internacional das pesquisas conforme as consultas #1, #2 e #3.	40
Quadro 2.3: Panorama internacional das pesquisas conforme as combinações entre as consultas #1, #2 e #3.	40
Quadro 2.4: Publicações classificadas por áreas de pesquisa conforme a combinação das consultas #2 e #3.	41

LISTA DE FIGURAS

Figura 1.1: Estrutura analítica resumida da metodologia	31
Figura 1.2: Expansão da etapa 1 da metodologia proposta	32
Figura 1.3: Expansão da etapa 2 da metodologia proposta	33
Figura 1.4: Expansão da etapa 3 da metodologia proposta	34
Figura 1.5: Fluxograma da Metodologia	35
Figura 3.1: Área de estudo na avenida Hélio Prates.....	101
Figura 3.2: Detalhes das condições de tráfego reais nas aproximações das interseções A e B as 18:00h do dia 15 de março de 2017.	102
Figura 3.3: Condição de tráfego típica com detalhe da interseção A nas quartas-feiras as 8:30h, de acordo com a plataforma Google Maps	102
Figura 3.4: Condição de tráfego típica da interseção B nas quartas-feiras as 18:00h, de acordo com a plataforma Google Maps.....	102
Figura 3.5: Identificação e localização dos sensores no trecho da área de estudo	103
Figura 3.6: comparativo entre o banco de dado utilizado e o outro descartado	104
Figura 3.7: Exemplo da série temporal de velocidade coletada pelo equipamento RSI033.	105
Figura 3.8: Exemplo de comportamento do fluxo e do tráfego em uma semana para o equipamento RSI033	106
Figura 3.9: exemplo de comportamento do tráfego em um dia útil registrado pelo sensor do equipamento RSI033	107
Figura 4.1: Etapas do trabalho, produtos e relacionamentos.....	108
Figura 4.2: Diagrama da rede neural desenvolvida nesse trabalho para realizar a previsão.	109
Figura 4.3: Representação dos dados usados no treinamento, previsão e validação dos fluxos	110
Figura 4.4: Geometria das interseções.....	111
Figura 4.5: Arquitetura da rede neural profunda utilizada para aproximar a função Q	113
Figura 4.6: Diagrama do processo de controle	114
Figura 5.1: Sobreposição dos fluxos de tráfego observados e previstos ao longo de uma semana, começando numa 2ª feira, para o sensor RSI033	115

Figura 5.2: Sobreposição dos fluxos de tráfego observados e previstos ao longo de uma semana, começando numa 2ª feira, para o sensor RSI132	116
Figura 5.3: Sobreposição dos fluxos de tráfego observados e previstos ao longo de três dias, 3ª, 4ª e 5ª feiras, para o sensor RSI033	116
Figura 5.4: Sobreposição dos fluxos de tráfego observados e previstos ao longo de três dias, 3ª, 4ª e 5ª feiras, para o sensor RSI132	117
Figura 5.5: Exemplo de resultado mensal para a previsão de fluxo de tráfego obtido em intervalos de 5 minutos.....	117
Figura 5.6: Exemplo de resultado mensal para a previsão de fluxo de tráfego obtido em intervalos de 1 minuto.	117
Figura 5.7: Exemplo de resultado semanal para a previsão de fluxo de tráfego obtido em intervalos de 5 minutos.....	118
Figura 5.8: Exemplo de resultado semanal para a previsão de fluxo de tráfego obtido em intervalos de 1 minuto.	118
Figura 5.9: Exemplos de resultados diários para as previsões de fluxos de tráfego em intervalos de 1 minuto para a aproximação do sensor RSI017 na interseção 289.....	118
Figura 5.10: Exemplos de resultados diários para as previsões de fluxos de tráfego em intervalos de 1 minuto para a aproximação do sensor RSI018 na interseção 289.....	119
Figura 5.11: Exemplos de resultados diários para as previsões de fluxos de tráfego em intervalos de 1 minuto para a aproximação do sensor RSI128 na interseção 289.....	119
Figura 5.12: Exemplos de resultados diários para as previsões de fluxos de tráfego em intervalos de 1 minuto para a aproximação do sensor RSI129 na interseção 289.....	119
Figura 5.13: Exemplos de resultados diários para as previsões de fluxos de tráfego em intervalos de 1 minuto para a aproximação do sensor RSI032 na interseção 353.....	120
Figura 5.14: Exemplos de resultados diários para as previsões de fluxos de tráfego em intervalos de 1 minuto para a aproximação do sensor RSI033 na interseção 353.....	120
Figura 5.15: Exemplos de resultados diários para as previsões de fluxos de tráfego em intervalos de 1 minuto para a aproximação do sensor RSI131 na interseção 353.....	120
Figura 5.16: Exemplos de resultados diários para as previsões de fluxos de tráfego em intervalos de 1 minuto para a aproximação do sensor RSI132 na interseção 353.....	121
Figura 5.17: Erros absolutos e erros relativos das previsões de fluxos de 15 minutos (RSI033).	121

Figura 5.18: Erros absolutos e erros relativos das previsões de fluxos de 5 minutos (RSI033).	122
Figura 5.19: Erros absolutos e erros relativos das previsões de fluxos de 1 minuto (RSI033).	122
Figura 5.20: Comparação entre os atrasos médios na rede resultantes dos planos semafóricos definidos pelo DETRAN/DF e os planos baseados em inteligência artificial propostos nesta tese.....	127
Figura 5.21: Comparação entre as quantidades de veículos e os ciclos dos planos semafóricos propostos e do DETRAN para a via arterial nas duas interseções.	129
Figura 5.22: Comparação entre as quantidades de veículos e os ciclos dos planos semafóricos propostos e do DETRAN para as vias arterial e coletora de uma mesma interseção.....	129
Figura 5.23: Correlações entre os fluxos de tráfego e as variações dos comprimentos de filas (QLEN) e comprimentos de filas máximos (QLENMAX) resultantes do modelo, considerando toda a rede de trânsito.....	131
Figura 5.24: Correlações entre os fluxos de tráfego e as variações dos comprimentos de filas (QLEN) e comprimentos de filas máximos (QLENMAX) resultantes do modelo, considerando os resultados obtidos para toda a rede de trânsito.	132
Figura 5.25: Correlações entre os fluxos de tráfego e as variações dos comprimentos de filas (QLEN) a partir dos resultados do modelo para as aproximações da interseção 289.	132
Figura 5.26: Correlações entre os fluxos de tráfego e as variações dos comprimentos de filas (QLEN) a partir dos resultados do modelo para as aproximações da interseção 353.	133
Figura 7.1: Exemplos gráficos de descargas de filas de veículos acumulados representadas em segmentos retilíneos	159
Figura 7.2: Histograma de medidas de fluxo de saturação <i>versus</i> distribuição normal ajustada para uma amostra de dados dos equipamentos de fiscalização eletrônica	160
Figura 7.3: Equipe de pesquisa sendo instruída	161
Figura 7.4: Pesquisadores em campo	161
Figura 7.5: Histograma de medidas de fluxo de saturação <i>versus</i> distribuição normal ajustada para a amostra de dados coletados pelos pesquisadores de campo	162
Figura 7.6: Raciocínio de cálculo da densidade de tráfego	163
Figura 7.7: Comparação entre os gráficos Densidade x Fluxo sem (a) e com agrupamentos (b).	164
Figura 7.8: Regressões lineares ajustadas aos <i>clusters</i> de fluxos livre e congestionado...	165

Figura 7.9: Determinação da reta velocidade crítica (a) e do ponto crítico (b).....	165
Figura 7.10: parâmetros de tráfego calibrados com a indicação da transição entre os regimes de fluxo livre e congestionado.....	166

LISTA DE ABREVIATURAS E SÍMBOLOS

- ALLONS-D – *Adaptive Limited Look-Ahead Optimization of Network Signals*–Decentralized – Sistema Descentralizado de Otimização Limitada Adaptativa de Semáforos em Rede
- ANFIS – *Adaptive Neuro-Fuzzy Inference System* – Sistema de Inferência Adaptativo Neuro-Fuzzy
- ARIMA – *Auto Regressive Integrated Moving Average* – Modelo Auto Regressivo Integrado de Média Móvel
- ATCS – *Adaptive Traffic Control Systems* – Sistemas de Controle Adaptativo de Tráfego
- AUT – *Automatic Updating of TRANSYT* – Módulo de Atualização Automática
- AUTCS – *Adaptive Urban Traffic Control System* – Sistema de Controle de Tráfego Urbano Adaptativo
- CBDP – *Current Best Decision Path* – Melhor Caminho Atual de Decisão
- CERT – *Centre d'Études et de Recherches de Toulouse* – Centro de Estudos e de Pesquisas de Toulouse
- CET/SP – Companhia de Engenharia de Tráfego do Município de São Paulo
- CFTV – Circuito Fechado de Televisão
- COP – *Controlled Optimization of Phases* – Otimização Controlada de Fases
- CTA – Sistema de Controle de Tráfego por Área
- CTAFOR – Sistema de controle de tráfego em área de Fortaleza
- CTA-RIO – Sistema de Controle de Tráfego em Área do Rio de Janeiro
- DYPIC – Controle de Interseção Dinamicamente Programado
- FDP – *Forward Dynamic Programming* – Método de programação dinâmica
- FHWA – Administração Federal de Rodovias dos EUA
- IPT/SP – Instituto de Pesquisas Tecnológicas do Estado de São Paulo
- ITACA – *Intelligent Traffic Adaptive Control Agent* – Agente Inteligente de Controle Adaptativo de tráfego
- ITS – Sistemas de Transportes Inteligentes
- MARL – Aprendizado por Reforço Multiagente
- OPAC – Sistema de Controle Adaptativo para Políticas de Otimização
- OSCO – *Optimal Sequential Constrained*

OSTRAC – *Optimized Strategy for Integrated Traffic and Transit Signal Control* – Estratégia Otimizada para Tráfego Integrado e Controle de Semáforos

PMV – Painéis de Mensagens Variáveis

PSSs – *Progressive Signal System* – Sistemas Semafóricos Progressivos

PRODYN – *Programmation Dynamique* – Sistema de Programação Dinâmica

RHODES – *Real-Time Hierarchical Optimized Distributed Effective System* – Sistema Efetivo Distribuído Otimizado Hierárquico em Tempo Real

RNA – Rede Neural Artificial

RSSF – Redes de Sensores Sem Fio

RTA – Autoridade de Tráfego e Rodovias de Nova Gales do Sul

SCATS – *Sydney Co-Ordinated Adaptative Traffic System* – Sistema de Tráfego Adaptativo Coordenado de Sydney

SCOOT – *Split, Cycle and Offset Optimization Technique* – Técnica de Otimização da Porcentagem de Verde, Ciclo e defasagem

SEMCO – Semáforos Coordenados

SICT – Sistemas Inteligentes de Controle de Tráfego

SIF – Sistemas Inteligentes *Fuzzy*

SIHTD – Sistema Inteligente Híbrido de Tomada de Decisão para Aplicações de Controle de Tráfego Urbano

STLC – *Serve the Largest Cost*

SURTRAC – *Scalable Urban Traffic Control* – Controle de Tráfego Urbano Escalável

TAP – Problema de Alocação do Tráfego

TRANSYT – *Traffic Network Study Tool*

TRPM – *Traffic Rolling Prediction Model* – Modelo de Previsão de Rolamento de Tráfego

TRRL – Laboratório de Pesquisa Rodoviária e Transporte

TSP – *Transport Signal Priority*. – Prioridade de Semáforos para os Transportes Públicos

TUC – *Traffic-responsive Urban Control* – Controle de Tráfego Urbano

UTCS – Sistema de Controle de Tráfego Urbano

UTOPIA – *Urban Traffic Optimization by Integrated Automation* – Sistema de Automação Integrada pela Otimização de Tráfego Urbano

VANT – Veículo Aéreo não Tripulado

ZELT – *Zone Expérimentale et Laboratoire de Traffic de Toulouse* – Sistema da Zona Experimental e Laboratório de Tráfego de Toulouse

SUMÁRIO

1	INTRODUÇÃO.....	20
1.1	OPORTUNIDADE GERENCIAL OFERECIDA PELOS DADOS DE FLUXOS DE TRÁFEGO.....	21
1.2	O PROBLEMA DO CONTROLE DE TRÂNSITO	24
1.3	CARACTERIZAÇÃO DO PROBLEMA	26
1.4	FORMULAÇÃO DO PROBLEMA.....	28
1.5	HIPÓTESE	28
1.6	OBJETIVOS	28
1.7	JUSTIFICATIVA	29
1.8	METODOLOGIA DA PESQUISA.....	31
1.9	CONTEÚDO	35
2	REFERENCIAL BIBLIOGRÁFICO E TEÓRICO.....	37
2.1	REVISÃO SISTEMÁTICA.....	37
2.2	CONTROLE DE TRÁFEGO COM SEMÁFOROS	45
2.3	OS SISTEMAS DE CONTROLE DE TRÁFEGO NO BRASIL	47
2.4	SISTEMAS DE CONTROLE DE TRÁFEGO.....	49
2.4.1	Controle de tempo fixo.....	49
2.4.2	Controle atuado pelo tráfego	50
2.4.3	Controle em tempo real	50
2.4.4	Sistema de controle isolado.....	51
2.4.5	Sistema de controle coordenado.....	51
2.4.6	Sistema de controle centralizado.....	52
2.4.7	Sistemas de controles adaptativos em rede	55

2.5	CONTRIBUIÇÃO DA CIÊNCIA DE INTELIGÊNCIA ARTIFICIAL NOS SISTEMAS DE CONTROLE DE TRÁFEGO.....	74
2.5.1	Sistemas Inteligentes de Controle de Tráfego.....	75
2.5.2	Sensoriamento e Inteligência Artificial.....	78
2.5.3	Aprendizado por Reforço	79
2.6	PREVISÃO DE FLUXOS DE TRÁFEGO	82
2.7	SINCRONIZAÇÃO DE TEMPOS SEMAFÓRICOS.....	84
2.8	APRENDIZADO POR REFORÇO PROFUNDO	89
2.8.1	<i>Deep Learning</i>	91
2.8.2	<i>Reinforcement Learning</i>	91
2.8.3	<i>Deep Reinforcement Learning</i>	95
3	ÁREA DE ESTUDO E LEVANTAMENTO DE DADOS.....	99
3.1	ESCOLHA DA ZONA DE ESTUDO	100
3.2	DADOS DISPONIBILIZADOS PELO DETRAN-DF	103
4	MODELAGEM DO CONTROLE ADAPTATIVO DE TRÁFEGO.....	108
4.1	PREVISÃO Dos FLUXOS DE TRÁFEGO	108
4.2	OTIMIZAÇÃO DOS PLANOS SEMAFÓRICOS	110
5	RESULTADOS ALCANÇADOS	115
6	CONCLUSÕES E RECOMENDAÇÕES	134
	REFERÊNCIAS BIBLIOGRÁFICAS	139
7	APÊNDICE A.....	154
7.1	REVISÃO DA LITERATURA	154
7.2	LEVANTAMENTO DO FLUXO DE SATURAÇÃO EM CAMPO	157
7.3	CALIBRAÇÃO DE PARÂMETROS FUNDAMENTAIS DE TRÁFEGO.....	163
7.4	VALIDAÇÃO DOS RESULTADOS.....	166
8	APÊNDICE B.....	168

1 INTRODUÇÃO

Os volumes de tráfego estão crescendo no mesmo compasso que aumenta a população, devido à forte correlação entre pessoas e veículos individuais (MCKENNEY e WHITE, 2013). Fato que já é uma tendência nos principais centros urbanos ao redor do mundo e também uma tendência forte no Brasil (LEAL, 2016). Esse fenômeno experimentado mundialmente pelas cidades tem produzido condições de trânsito cada vez mais indesejáveis e problemas severos como, por exemplo, congestionamentos e poluição para todos os usuários dos sistemas urbano e de transporte (STATHOPOULOS e KARLAFTIS, 2003; WEN, 2008; GARCÍA-NIETO *et al.*, 2012; TAN *et al.*, 2016).

No Brasil, as capitais São Paulo, Rio de Janeiro, Fortaleza, Porto Alegre, Recife, Salvador, Brasília e Curitiba estão entre as 160 cidades com a maior população urbana do mundo (COX, 2017) e contam com a maior frota de veículos do país. Neste sentido, Dutra (2005) aponta que, especialmente nas regiões metropolitanas da maioria das cidades brasileiras de médio e grande portes, ocorrem congestionamentos diários de veículos, causando impactos na distribuição do tráfego, na frequência das viagens, no comportamento dos motoristas, na segurança, no uso do solo e na economia, implicando em prejuízos significativos à sociedade.

Cabe destacar que um estudo realizado por Cintra (2013, *apud* DE SOUZA E VILLAS, 2015) revela que os prejuízos causados pelos congestionamentos em São Paulo somaram R\$ 40 bilhões no ano de 2012. De acordo com García-Nieto *et al.* (2013) e Tan *et al.* (2016), não é possível aumentar a infraestrutura urbana no mesmo compasso do crescimento da frota de veículos tanto pela falta de espaço como pela escassez de recursos públicos para fazer esses tipos de intervenções. Por isso, têm-se buscado tecnologias estratégicas para melhorar a eficiência da infraestrutura existente e meios para minimizar tanto quanto possível os congestionamentos.

Neste contexto, vários pesquisadores costumam concordar que a sincronização de semáforos (GARCÍA-NIETO, 2013) e o desenvolvimento de tecnologias de sistemas de transportes inteligentes (ITS), baseados em informações em tempo real e previsões de curto prazo de parâmetros de tráfego, podem reduzir os problemas de trânsito, melhorando o fluxo de veículos nas cidades (STATHOPOULOS e KARLAFTIS, 2003, e WEN, 2008).

De certa forma, esse consenso é antigo e a muito tempo o seu objetivo é perseguido. Pesquisas realizadas na década de 70 por Gartner (1975) constataram que mais de 100 áreas urbanas nos Estados Unidos e no Canadá estavam em processo de planejamento, concepção e implementação de sistemas de controle de tráfego informatizado. Tais pesquisas previam que, em poucos anos, todas as cidades com mais de 100.000 habitantes teriam esses sistemas em operação para controlar o fluxo de tráfego.

Segundo Gartner (1975), esses sistemas teriam um impacto profundo no desempenho da rede de tráfego nessas áreas em termos de níveis de serviço e capacidade, pois os métodos usados para utilização dos semáforos como meios de controle do fluxo de tráfego em interseções seriam, talvez, a aplicação mais prática dos conceitos de equilíbrio de tráfego em uma rede de transporte.

Adicionalmente, os sistemas nos quais eles seriam implementados teriam a capacidade de rastrear o fluxo de tráfego, monitorando detalhadamente a sua dinâmica em função da variação do tempo mediante o emprego de detectores de veículos e respondendo rapidamente às mudanças na demanda através de um sistema de comunicação conectando sensores, computadores e semáforos de forma integrada. Desta forma, parece que essa visão de Gartner antecipou ou definiu o conceito que rege atualmente os sistemas de controle de tráfego em tempo real ou adaptativos.

1.1 OPORTUNIDADE GERENCIAL OFERECIDA PELOS DADOS DE FLUXOS DE TRÁFEGO

Segundo Chang *et al.* (2011), a implementação de sistemas de transporte inteligentes em todo o mundo já disponibilizavam grandes quantidades de dados históricos e em tempo real. Dunkel *et al.* (2011) ressaltaram que muitos sistemas de controle de tráfego naquela época já eram baseados em equipamentos de fiscalização eletrônica de veículos, que registravam um volume muito grande de eventos individuais bem detalhados que deveriam ser processados para analisar a situação atual do tráfego visando à adoção de ações de controle apropriadas.

De forma geral, ITF (2015) destacou que no contexto internacional jamais houve uma quantidade de dados e informações tão ampla e rapidamente disponível sobre eventos,

pessoas e objetos, como os que existiam naquele momento. O que tem demandado o desenvolvimento de ferramentas tecnológicas e métodos científicos para processar e analisar esses volumes de dados coletados.

Karlaftis e Vlahogianni (2011) corroboram a importância da análise dos dados indicando que, provavelmente, se trata da ferramenta de pesquisa mais importante e amplamente usada em transportes. A coleção e exploração desse conjunto enorme de dados é conhecido como Big Data (Grandes Dados), que pode ser visto tanto como uma oportunidade quanto um desafio, especialmente para o gerenciamento e a governança de dados de transportes (ITF, 2015).

Zeng (2015) ressalta que, com o rápido desenvolvimento da sociedade, a demanda por transportes criou a necessidade de monitoramento contínuo do tráfego. Fato que tem gerado um espectro de dados cada vez mais dinâmico, extenso e diversificado. Isto tem trazido desafios para armazenar, processar e gerenciar essa grande quantidade de dados produzidos pela vasta gama de equipamentos de monitoramento distribuídos nas redes de transportes e nos veículos, principalmente em tempo real.

No Brasil, o maior obstáculo tem sido os dados, seja pela falta deles, seja pela falta de métodos dinâmicos capazes de tratar oportunamente um volume muito grande de dados produzidos pelos equipamentos e sensores de fiscalização e monitoramento do trânsito de veículos, que possuem uma relevância extrema para produzir informações para o controle do tráfego urbano.

Nesse contexto, observa-se que os órgãos públicos de planejamento de transporte como os órgãos executivos de trânsito das cidades brasileiras apresentam situações diferentes quanto à capacidade de coletar, tratar e analisar os dados de fluxo de tráfego. Essas situações podem ser divididas em três casos:

- ✓ A cidade tem sistema de monitoramento e controle com estrutura para tratar e analisar os dados coletados;
- ✓ A cidade tem equipamentos de monitoramento ou controle e não tem estrutura para tratar e analisar os dados coletados;
- ✓ A cidade não tem equipamentos de monitoramento ou controle.

Como mencionado anteriormente, além da importância da análise dos dados, um sistema de controle de tráfego precisa adotar ações de controle para responder rapidamente às mudanças detectadas no tráfego. Isso pode passar ou não pela previsão dos fluxos de tráfego. Tan *et al.* (2009) afirmam que a previsão de fluxos de tráfego é uma parte essencial do planejamento de transportes, do controle de tráfego e dos sistemas de transportes inteligentes.

Em particular, a previsão dos volumes de tráfego de curta duração embasa o controle dinâmico proativo de tráfego. Ressalte-se que, embora os dados produzidos, principalmente aqueles em tempo real, tenham papel fundamental, maiores benefícios do ITS podem ser realizados de forma proativa com informações de tráfego de curto prazo e não com as informações em tempo real de uma maneira reativa (CHANG *et al.*, 2011). Por exemplo, as informações de curto prazo requerem menor poder computacional do que as informações em tempo real e permitem que os sistemas atuem com oportunidade em relação aos eventos no contexto de um Sistema Inteligente de Transportes, enquanto apenas a reação em tempo real poderia falhar nesse sentido, irremediavelmente.

Mais do que nunca, a capacidade das técnicas de previsão para estimar condições futuras de tráfego traz grandes vantagens, já que permite suportar sistemas avançados de gestão de tráfego e serviços avançados de informação para viajantes. Da mesma forma, a área de previsão dinâmica, baseada em tempo real, que é uma das principais áreas de ITS também permite isso (STATHOPOULOS *et al.*, 2003; JIANG e ADELI, 2005; VLAHO-GIANNI *et al.*, 2005; ZHENG *et al.*, 2006; MIN e WYNTER, 2011; CHANG *et al.*, 2012; JEONG *et al.*, 2013).

De acordo com Yisheng *et al.* (2015), atualmente, informações precisas e oportunas sobre o fluxo de tráfego são extremamente necessárias para os viajantes, para os mercados de negócios e para as agências dos governos, dentre outros. Ou seja, essas informações têm um grande potencial, já que são fundamentais na tomada de decisão dos analistas de transporte de empresas operadoras e dos motoristas quanto à escolha dos melhores percursos para reduzir custos de transporte. Além disso, ajudam a criar estratégias para aliviar os congestionamentos nos horários de picos ou em casos de emergências, reduzir as emissões de carbono e melhorar, como um todo, a eficiência da operação do tráfego.

Neste sentido, a previsão do fluxo de tráfego consegue fornecer tais informações e, por isso, vem ganhando cada vez mais atenção e interesse, principalmente diante do desenvolvimento acelerado e da implantação de sistemas de transporte inteligentes. Assim, ele é considerado um elemento crítico para a implantação bem-sucedida de subsistemas ITS, particularmente para aqueles sistemas avançados de informação de passageiros, de gerenciamento de tráfego, de transporte público e de operações de veículos comerciais.

Para Chen e Sun (2016), o desempenho dos sistemas adaptativos de controle de tráfego depende fortemente dos algoritmos de previsão dos fluxos de tráfego e de otimização dos semáforos e a redução do atraso dos veículos é essencial para a gestão do tráfego urbano.

Segundo Gao *et al.* (2016), uma sincronização razoável de semáforos pode reduzir o atraso em um sistema de tráfego urbano e Heung *et al.* (2005) afirmam que o controle de uma interseção importa na organização do sincronismo dos semáforos de interseções adjacentes de tal forma que, quando um veículo chega em uma interseção vindo de outra, o usuário encontre uma sucessão de sinais verdes e não precise parar ou diminuir a velocidade.

Portanto, diante do exposto acima e do desenvolvimento constante de tecnologias de sistemas de transportes inteligentes, em especial daqueles referentes à sincronização de semáforos, é razoável imaginar que a evolução dos sistemas de controle de tráfego inteligentes passe pela introdução de ferramentas de análise mais adequadas ao grande volume de dados produzidos, principalmente nas aproximações das interseções.

É coerente pensar que tais parâmetros venham a alimentar um modelo de previsão de fluxo de tráfego que seja apto a aprender o seu comportamento, visando a estimar o desempenho futuro do sistema de trânsito para que outro modelo, inteligentemente apto, possa aprender como otimizar os planos semaforicos para melhorar tanto quanto possível o desempenho desses planos e, conseqüentemente, a eficiência do sistema de tráfego.

1.2 O PROBLEMA DO CONTROLE DE TRÂNSITO

Cidades como São Paulo, Rio de Janeiro, Salvador, Brasília, Fortaleza, Curitiba e Belo Horizonte seguem o mesmo viés de crescimento urbano mundial (COX, 2017), apresentando os mesmos problemas de trânsito das grandes metrópoles, assim como limitações para aumentar suas infraestruturas viárias para acomodar o crescimento da frota.

O problema do controle de trânsito relacionado com a redução dos congestionamentos passa pela coleta de informações suficientes e oportunas do fluxo de veículos e pelo desenvolvimento de um modelo que analise adequadamente esses dados para definir o estado atual do tráfego, bem como para prever as condições dos fluxos futuros, especialmente os críticos, e, finalmente, para otimizar os planos semaforicos de forma a gerar uma onda verde.

Nesse compasso, diversas pesquisas têm se ocupado da predição do fluxo de tráfego para atender à demanda crescente dos diversos usuários. Por exemplo, Jiang e Adeli (2005) introduziram um modelo novo de redes neurais não paramétricas de ondas de atrasos dinâmicos recorrentes para prever os fluxos de tráfego. Depois, Zheng *et al.* (2006), igualmente apoiados em uma abordagem de redes neurais, apresentaram um modelo de predição do fluxo de tráfego baseado em redes neurais combinadas com a teoria da probabilidade condicionada e a regra de Bayes.

Já Dimitriou *et al.* (2008), preocupados em abordar adequadamente tanto a imprecisão e incertezas dos dados quanto o conhecimento de especialista em tráfego urbano, desenvolveram um modelo de previsão de fluxo de tráfego baseado em um sistema adaptativo de regras *fuzzy* híbridas. Por sua vez, Tan *et al.* (2009) utilizaram as previsões baseadas em modelos de Médias Móveis, Suavização Exponencial e Média Móvel Autorregressiva para treinar um modelo de redes neurais como estratégia de agregação para melhorar a precisão do processo de predição.

Chang *et al.* (2011), objetivando equacionar a previsão de fluxos de tráfego com as flutuações ou alterações bruscas nas séries temporais de dados, propuseram o modelo de predição de volume de tráfego multi-intervalar dinâmico, baseado na regressão não paramétrica do k-ésimo vizinho mais próximo. No mesmo sentido, Min e Wynter (2011) propuseram um modelo estatístico de previsão da velocidade e do volume de tráfego em intervalos de 5 minutos até 1 hora. Para prever os mesmos parâmetros, Jeong *et al.* (2013) apresentam um novo modelo chamado regressão do vetor suporte ponderado pelo aprendizado *online*.

Assim, é patente a importância da predição do fluxo de tráfego. No entanto, essa predição não resulta por si só no controle adequado do tráfego, que continua sendo um problema

complexo para pesquisadores e engenheiros devido ao número de dificuldades, principalmente no que concerne à sua simulação e otimização. A determinação do melhor plano de semáforos se torna oneroso, tanto em relação ao consumo de tempo quanto de dinheiro, sendo precários algumas vezes (Li *et al.*, 2016) quando se considera o dinamismo, a espacialidade e a complexidade dos sistemas de transporte.

Finalmente, a simulação de planos semaforicos também faz parte do problema de controle de tráfego, seja pela sua complexidade seja por determinar uma política de sincronização de semáforos adequada.

1.3 CARACTERIZAÇÃO DO PROBLEMA

O crescimento dos congestionamentos nos diferentes horários do dia em muitos centros urbanos em nível internacional e nacional reforça a necessidade de adoção de sistemas de controle e gerenciamento de tráfego interativos, adaptativos e capazes de gerar decisões acertadas no menor intervalo de tempo possível. Para Oliveira e Bazzan (2006), as abordagens clássicas são inflexíveis porque não podem lidar com as mudanças dinâmicas do fluxo de tráfego.

As abordagens clássicas apresentam bons resultados em ambientes cujos fluxos de tráfego variam de forma bem definida ao longo do dia, o que não é o caso na maioria das cidades brasileiras de médio a grande porte. As redes viárias dessas cidades ficam congestionadas em diversos trechos e interseções em determinados horários do dia, em função das atividades econômicas e sociais desenvolvidas nessas cidades. Determinar quais planos são mais apropriados para cada hora do dia é uma tarefa complexa que requer contagens e estudos do fluxo de tráfego em diferentes pontos da rede (Oliveira e Bazzan, 2007).

Para aplicar sistemas mais flexíveis e robustos é necessário o uso de uma rede de equipamentos de fiscalização eletrônica de veículos, sensores WiFi, rastreadores GPS ou rastreadores de sinais de telefonia 4G/5G que colem e transmitam informações relevantes em tempo real, integrada a uma infraestrutura de processamento de dados baseada, por exemplo, em técnicas de inteligência artificial para fins de análise e modelagem dos padrões de fluxos de tráfego visando a otimização de planos semaforicos.

No entanto, a realidade do controle de tráfego em muitas cidades brasileiras é bastante parecida com a que Newell (1989) descreveu no seu trabalho. Resumidamente, ele apontou dois aspectos necessários para compreensão do comportamento do tráfego: treinamento inadequado dos engenheiros de tráfego e emprego de bases lógicas equivocadas para o controle de tráfego. Antes do trabalho dele, só havia uma vasta coleção de dados empíricos cuja maior parte era difícil de interpretar e não havia uma função objetivo bem definida para modelar o comportamento dinâmico dos veículos, pois a percepção da sociedade não era clara, principalmente em termos de como equilibrar o ganho ou custo de uma pessoa contra o de outra pessoa.

Observações exploratórias realizadas em várias cidades brasileiras, tais como: Rio de Janeiro, Salvador, São Paulo, Goiânia, Belo Horizonte, cidades do Distrito Federal, entre outras, apontam a ocorrência de congestionamentos nas proximidades de interseções entre vias arteriais e vias coletoras, bem como entre vias principais e secundárias. Tais observações e consultas com especialistas de engenharia de tráfego indicam que, em alguns casos, esses congestionamentos são provocados somente pela dessincronização dos semáforos. Além disso, pode ter ocorrido excesso de tráfego ou então uma associação entre a dessincronização dos semáforos e o excesso de tráfego.

Essas observações diretas no campo indicam que a fluidez nas interseções entre as vias principais e secundárias fica restrita, quiçá porque os fluxos das vias secundárias ficam reprimidos em detrimento de tempos de sinais verdes demasiadamente longos em relação aos fluxos das vias principais, ou porque os fluxos das vias principais requerem mais tempo de sinal verde a despeito da demanda das vias secundárias, em um contexto dinâmico e integrado.

Fazendo uma dedução a partir desses casos é possível que essas observações, assim como ocorre em diversas cidades do Distrito Federal, sejam relativas a interseções semaforizadas isoladas ou descentralizadas dos centros de controle de tráfego existentes nessas cidades. A referida dessincronização demonstra a incapacidade dos controladores semaforicos atualizarem os seus próprios planos de acordo com a demanda, requerendo a presença de um técnico no local para realizar os ajustes necessários, que geralmente são feitos visualmente e de forma empírica. Esta situação confirma a necessidade de uma abordagem flexível e robusta, tal como indicam Oliveira e Bazzan (2006) e outros autores, conforme o referencial bibliográfico e teórico apresentado no Capítulo 2 a seguir.

Diante desse problema, essa pesquisa se propõe a contribuir com o estudo de interseções semaforizadas de vias arteriais com vias coletoras utilizando abordagens de inteligência artificial. Dessa maneira, a pesquisa pretende oferecer um modelo não clássico de controle interativo, adaptativo e capaz de adotar ações para responder rapidamente às mudanças detectadas no tráfego.

A pesquisa contribuirá também com o uso e técnicas de inteligência artificial para o tratamento e análise dos dados produzidos pelos equipamentos de fiscalização eletrônica de veículos, ressaltando a importância que esses dados trazem para o estudo do controle de tráfego. Desta forma, a ferramenta desenvolvida será de grande utilidade para os órgãos executivos de trânsito que não dispõem desse tipo de recurso.

O modelo, além do tratamento e da análise de dados, compreenderá duas etapas: previsão de tráfego e otimização de planos semaforicos. No entanto, a pesquisa não tem a pretensão de produzir um sistema consolidado que preencha as necessidades dos órgãos executivos de trânsito no que se refere a centralização do controle de tráfego.

1.4 FORMULAÇÃO DO PROBLEMA

É possível propor um modelo de controle adaptativo de tráfego que seja eficaz e eficiente na análise dos dados de fluxos coletados, na previsão de seus estados críticos e na otimização dos planos semaforicos em tempo real, empregando somente técnicas de inteligência artificial, a fim de auxiliar na melhoria do fluxo de trânsito em uma rede viária urbana?

1.5 HIPÓTESE

Utilizando-se informações de tráfego de curto prazo, o modelo proposto para o controle adaptativo de tráfego em tempo real, apoiado em *data mining*, aprendizado profundo e aprendizado profundo por reforço, garante planos semaforicos eficazes e mais eficientes do que os obtidos em operações de semáforos por tempo fixo.

1.6 OBJETIVOS

O principal objetivo da pesquisa é propor um modelo que otimize os diferentes fluxos veiculares a partir de planos semaforicos eficazes e eficientes, adaptados às demandas

críticas da rede viária, mediante o monitoramento realizado por equipamentos de fiscalização eletrônica de veículos instalados nas aproximações de interseções semaforizadas.

Como objetivos específicos tem-se:

- ✓ Fazer as previsões de tráfego usando aprendizado profundo;
- ✓ Otimizar planos semaforicos por aprendizado por reforço profundo.

1.7 JUSTIFICATIVA

Zhao e Tian (2012) pesquisaram o estado-da-arte e o estado-da-prática dos principais sistemas de controle adaptativo de tráfego (ATCS) usados nos Estados Unidos da América (EUA) para estabelecer um quadro geral que pudesse comparar os sistemas então existentes. Assim, esses autores descrevem que a partir desses sistemas (Tabela 1.1) os tempos de viagens podem ser reduzidos em 29% ou aumentar em até 10%, os atrasos podem ser reduzidos em 38% no máximo ou aumentar em 3% enquanto as quantidades de paradas podem diminuir em até 55% ou aumentar em 5% no máximo.

De acordo com a Tabela 1.1, esses autores também destacam os custos iniciais de implantação desses sistemas que variam entre \$ 6.000 e \$ 60.000 por interseção, com um custo médio de \$ 30.600 por interseção, o que pode ser inviável para muitas cidades brasileiras.

Tabela 1.1: Comparação entre os benefícios e custos dos principais sistemas de controle adaptativo de tráfego em tempo real usados nos EUA (ZHAO e TIAN, 2012)

ATCSs	Tempo de Viagem	Atrasos	Paradas	Custo de Implantação por interseção
SCOOTs	-29% a -5%	-28% a -2%	-32% a -17%	\$30.000 a \$60.000
SCATS	-20% a 0%	-19% a +3%	-24% a +5%	\$20.000 a \$30.000
OPAC	-26% a +10%	-	-55% a 0%	\$20.000 a \$50.000
RHODES	-7% a +4%	-19% a -2%	-	\$30.000 a \$50.000
ACS Lite	-12% a +7%	-38% a +2%	-35% a -28%	\$6.000 a \$10.000

Kumar e Kumari (2016) esclarecem que os sistemas de controle adaptativo de tráfego podem ser usados como um método para reduzir os atrasos dos usuários motorizados e estender a vida útil da infraestrutura viária atual, postergando a necessidade de aumentar

a capacidade de tráfego com a construção de novas faixas de rolamento. A redução de atrasos também aumenta a eficiência energética, reduzindo o consumo de combustíveis e a emissão de poluentes.

Sobre os benefícios dos sistemas de transportes inteligentes em áreas metropolitanas, em especial do sistema de gerenciamento das vias arteriais, a Administração de Rodovias Federais dos EUA (FHWA) relata que a melhoria provocada por sistemas de controle adaptativos de tráfego reduz os atrasos entre 14% e 44%, e o consumo de combustíveis entre 2 e 13% (PROPER *et al.*, 2001).

De acordo com a literatura estudada, a maioria das cidades brasileiras não têm um sistema de controle adaptativo de tráfego em tempo real (seja porque não precisam seja porque não dispõem dos recursos humanos ou financeiros necessários), tampouco existe qualquer contribuição nacional, contrariando as expectativas de Gartner (1975) e a tendência mundial desde aquela época. Além disso, a pequena quantidade de cidades que possuem esses sistemas estão a mercê de empresas internacionais e de tecnologias eventualmente ultrapassadas, que podem não atender às suas expectativas da maneira mais adequada.

No Brasil, observa-se que vários fatores influenciaram a adoção de sistemas comerciais, dentre eles destacam-se, as iniciativas frustradas, principalmente dos pesquisadores de São Paulo, e a introdução, manutenção e modernização de equipamentos importados. Dessa forma, foi gerado um ciclo vicioso de falta de conhecimento técnico, dependência estrangeira e defasagem tecnológica dos equipamentos nacionais (PIETRANTONIO e BONETTI, 2007).

Depois, uma vez que São Paulo foi a cidade precursora desse processo, as demais cidades como: Rio de Janeiro, Juiz de Fora, Campo Grande, Porto Alegre, Vitória, Campinas, Ribeirão Preto e Curitiba, foram induzidas a seguir a mesma solução para controlar o tráfego, ou seja, importar equipamentos e sistemas comerciais. Fato que desestimulou consideravelmente o fomento às pesquisas nessa área de conhecimento, assim como a aplicação de novas técnicas para a modernização das práticas de controle e dos modelos que constituem os referidos sistemas de acordo com as demandas das cidades brasileiras.

Portanto, entende-se que existem três justificativas principais para este trabalho. Primeiro, as cidades brasileiras com mais de 100.000 habitantes têm ou terão a necessidade de um sistema de controle adaptativo de tráfego, sendo esse sistema capaz de reduzir os tempos

de viagens, os atrasos veiculares, as quantidades de paradas, o consumo de combustíveis, a emissão de poluentes e o investimento público no aumento da capacidade viária. Segundo, tem-se a oportunidade de desenvolver um modelo para o controle adaptativo de tráfego considerando técnicas modernas de inteligência artificial.

A terceira justificativa que deve ser mencionada é a necessidade de que o sistema seja viável técnica e financeiramente para as cidades brasileiras. Tecnicamente, para que os profissionais de controle de tráfego possam adquirir conhecimentos e receber treinamentos adequados no Brasil, bem como que o sistema possa ser constantemente atualizado em relação aos avanços tecnológicos e, sobretudo, em relação as especificidades das cidades brasileiras, gerando novas pesquisas. Financeiramente, para que os custos de implantação, manutenção e desenvolvimento (frequente) sejam os menores possíveis.

1.8 METODOLOGIA DA PESQUISA

Diante do problema identificado, propôs-se uma metodologia para atingir os objetivos deste trabalho. A Figura 1.1 apresenta a estrutura analítica resumida da metodologia desta pesquisa que foi dividida em três etapas: preparação, desenvolvimento e estudo de caso. Na sequência, cada uma dessas etapas será expandida e descrita, bem como o fluxograma da metodologia abordada.

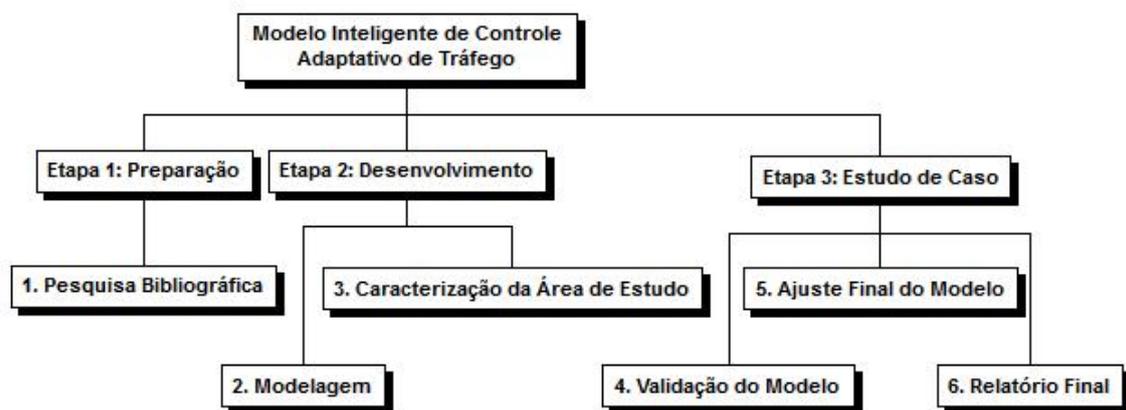


Figura 1.1: Estrutura analítica resumida da metodologia

A etapa 1 se caracterizou pela pesquisa bibliográfica e pelo conteúdo teórico necessário para uma abordagem consistente do assunto, visando à compreensão do tema e, principalmente, ao desenvolvimento teórico do problema e à definição das técnicas de inteligência artificial necessárias à construção do modelo proposto. Assim, além da introdução, da caracterização e formulação do problema, da descrição da hipótese e da definição dos

objetivos geral e específicos, a metodologia construiu obrigatoriamente um conteúdo bibliográfico e teórico mediante o desenvolvimento de um referencial abrangendo em especial os conhecimentos de controle de tráfego com semáforos, sistemas de controle de tráfego, sistemas inteligentes de controle tráfego, aprendizado pela inteligência artificial e sincronização de semáforos. Ainda, a metodologia buscou substanciar esse referencial por meio de uma revisão sistemática da bibliografia corrente a fim de levantar o estado-da-arte do assunto e garantir a inexistência de trabalhos iguais. Essa revisão sistemática está atualizada e descrita de forma mais apropriada no Capítulo 2 deste documento. A Figura 1.2 expande a etapa 1 da metodologia proposta.

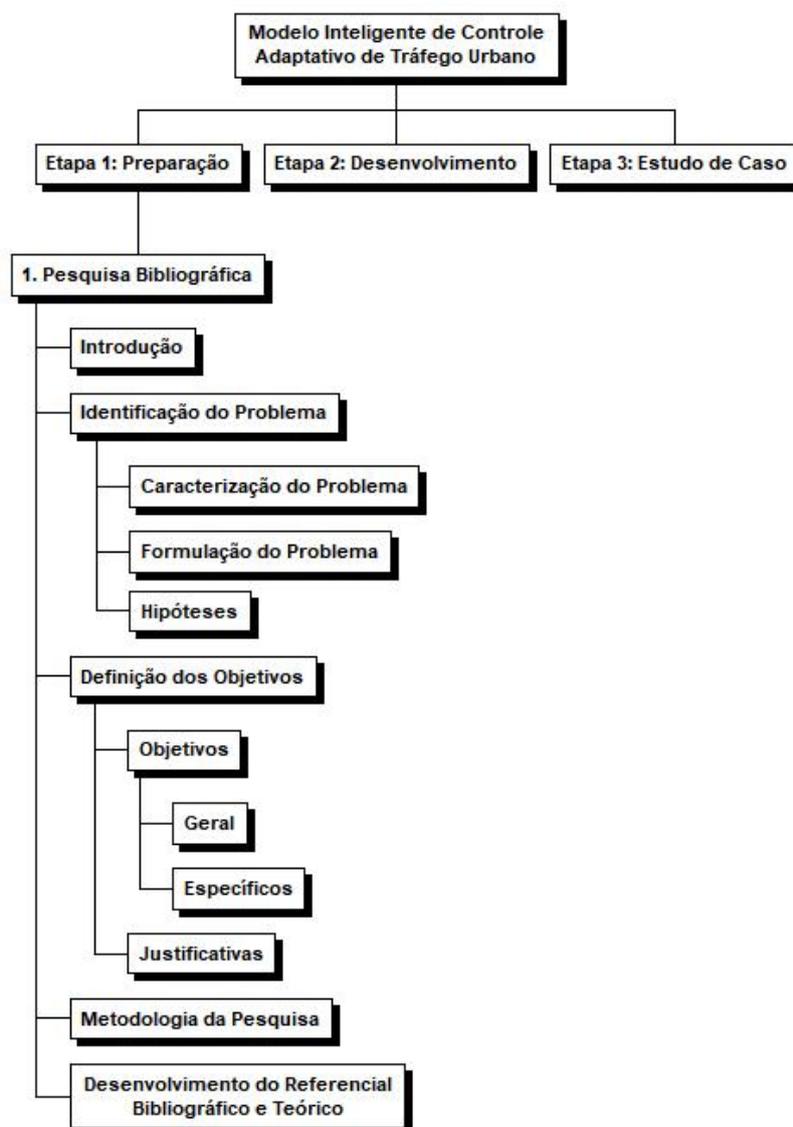


Figura 1.2: Expansão da etapa 1 da metodologia proposta

A etapa 2 se destacou como o cerne da metodologia e tratou do desenvolvimento do modelo, principalmente. A metodologia previu a modelagem teórica do problema mediante a análise dos dados coletados, a previsão dos fluxos e a otimização dos planos semafóricos. A Figura 1.3 apresenta a etapa 2 da metodologia.

Na estrutura apresentada, é possível identificar que a metodologia propôs o desenvolvimento de um modelo com base em técnicas de *machine learning*, que foi utilizada tanto para fazer a previsão de fluxos de tráfego quanto a otimização dos planos semafóricos. Nesta etapa, a área de estudo também foi analisada para garantir aderência entre as suas características e a estrutura do modelo.

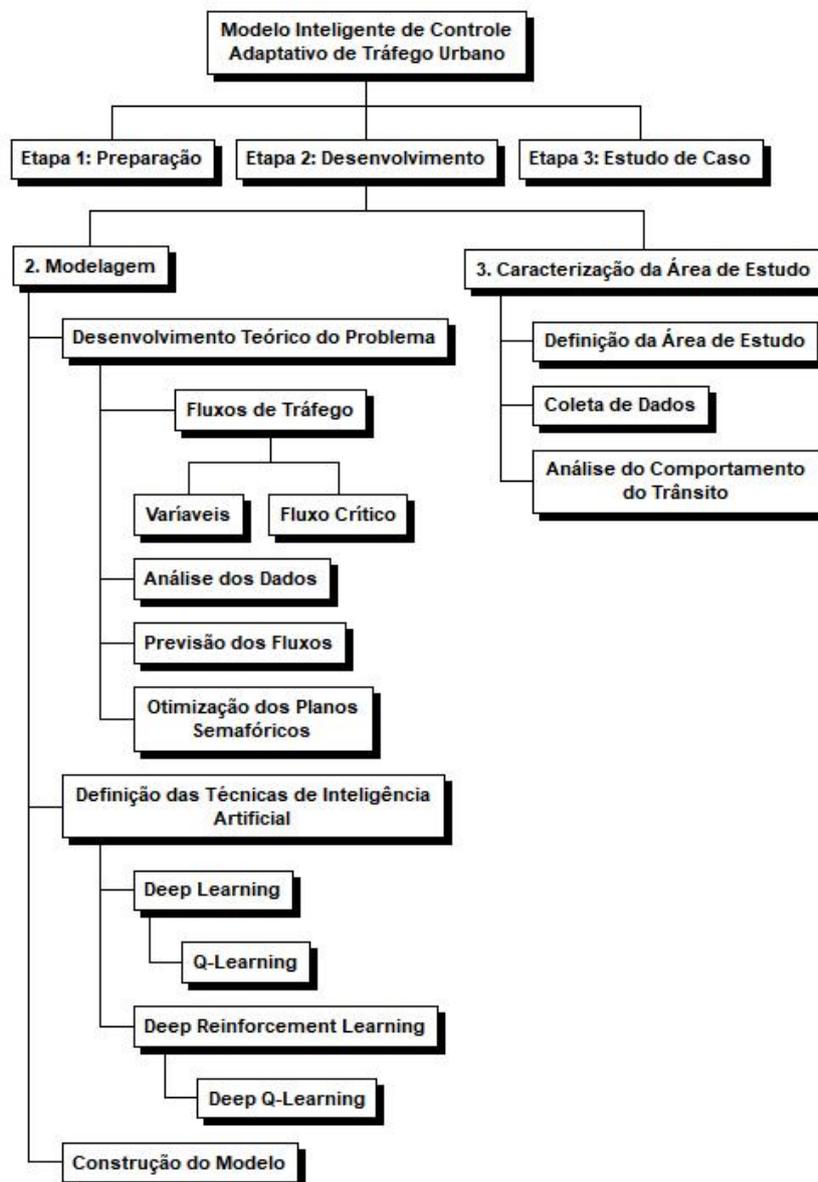


Figura 1.3: Expansão da etapa 2 da metodologia proposta

Finalmente, a etapa 3 se destinou principalmente a validar o modelo, aplicando-o aos dados coletados na área de estudo e analisando os resultados obtidos em relação às condições de tráfego pré-existentes e àquelas simuladas pelo modelo proposto. Nessa etapa, se propôs também os ajustes eventualmente requeridos pela modelagem caso a validação dos resultados obtidos pela aplicação do modelo em um ambiente de simulação não fosse consistente. Após essa validação por meio das simulações, não foram necessários ajustes e nessa etapa da metodologia surgiram as recomendações e conclusões do trabalho, conforme o destaque dado pela Figura 1.4 abaixo.

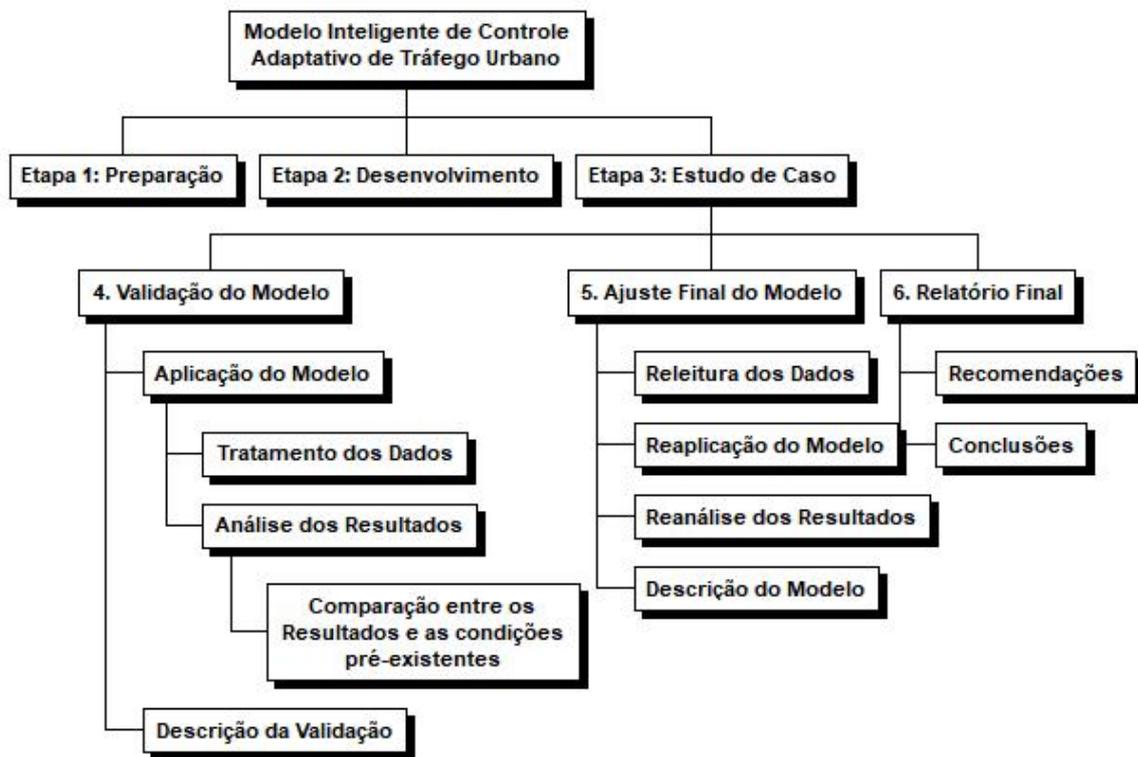


Figura 1.4: Expansão da etapa 3 da metodologia proposta

As etapas da metodologia proposta se encadeiam entre si gerando um fluxo de atividades visando à conclusão do trabalho com o relatório final. A Figura 1.5 descreve esse fluxo de atividades a partir do desenvolvimento do referencial bibliográfico e teórico, que se prolongou até o término da pesquisa. Depois, no desenvolvimento do trabalho, o fluxograma descrito na Figura 1.5 aponta o desenvolvimento teórico do problema e a definição das técnicas de inteligência artificial como pré-requisitos para a construção do modelo que, após concluído, determinou os dados de tráfego que foram coletados na área de estudo definida. Na sequência, os dados foram analisados para fins de descrição e organização, bem como de verificação da sua consistência com o modelo construído para avaliar

a necessidade de eventuais ajustes no modelo. Por fim, depois que os resultados foram validados, a metodologia continuou com o relatório final, condensando todas as informações resultantes da pesquisa realizada.

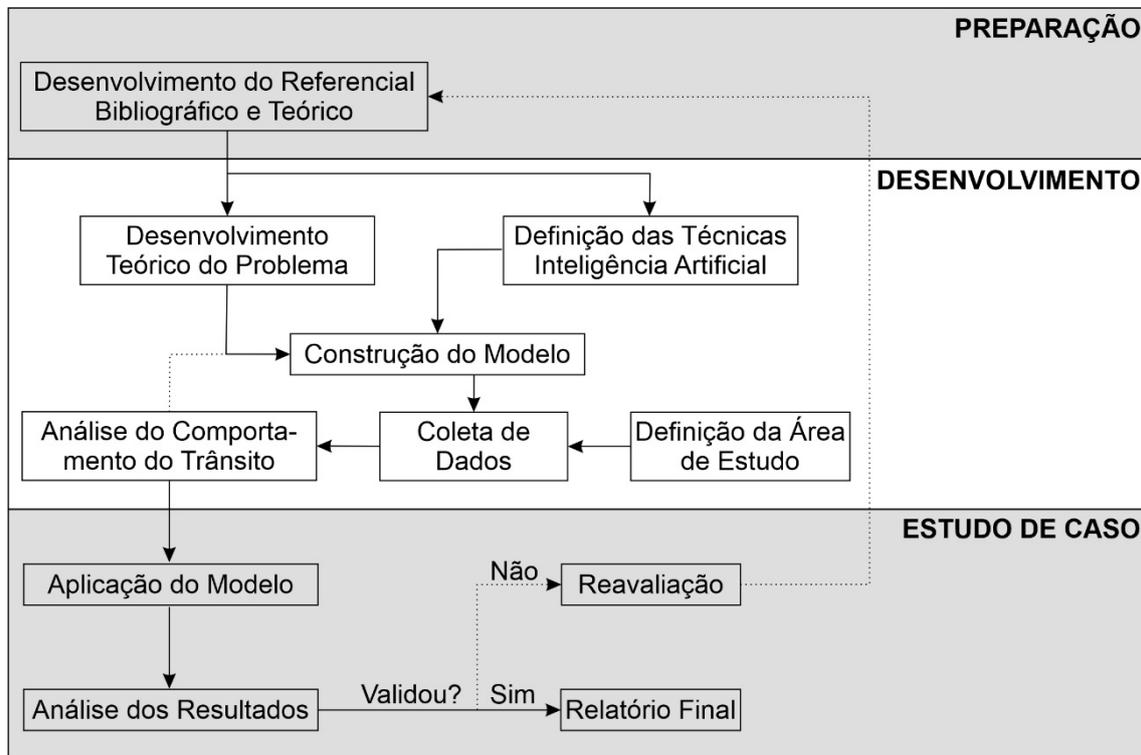


Figura 1.5: Fluxograma da Metodologia

1.9 CONTEÚDO

A tese compreende seis capítulos e um apêndice.

O Capítulo 1 compreende a apresentação do problema, dos objetivos, da justificativa, da metodologia, do cronograma e de outros tópicos do trabalho, além desse conteúdo.

O Capítulo 2 apresenta o referencial bibliográfico e teórico com uma revisão sistemática da literatura realizada por meio da plataforma *Web of Science*¹ e uma descrição histórica dos tipos, do desenvolvimento e da evolução dos sistemas de controle de tráfego no Brasil e no exterior, inclusive com o emprego de técnicas de inteligência artificial. Nesse contexto, a formulação básica do *Deep Reinforcement Learning* é descrita.

¹ www.webofknowledge.com

Depois, o Capítulo 3 aborda a área de estudo e o levantamento de dados para descrever a região até chegar especificamente nas interseções em que os dados foram coletados e, logicamente, a forma que eles foram empregados no desenvolvimento da pesquisa,

O Capítulo 4 descreve as etapas desenvolvidas para construir o modelo. Os resultados alcançados pela aplicação do modelo por meio das simulações são apresentados no Capítulo 5.

O Capítulo 6 faz as conclusões e recomendações de todo o trabalho realizado.

Finalmente, o Apêndice apresenta um esforço realizado na fase inicial desta pesquisa para determinar o fluxo de saturação mediante a calibração de parâmetros fundamentais de tráfego, considerando preliminarmente que este parâmetro seria essencial na modelagem pretendida, tal como tem sido historicamente para diversos modelos de controle de tráfego estudados.

Por oportuno, cabe salientar que, mediante o desenvolvimento do trabalho, constatou-se que este parâmetro se tornou irrelevante para o modelo inteligente de controle adaptativo de tráfego proposto, exatamente devido às características das técnicas de inteligência artificial introduzidas.

Por isso, esse esforço foi anexado ao final deste trabalho apenas como referência para estudos futuros que visem à determinação do momento de transição do tráfego do regime livre para o congestionado a fim de informar ao usuário essa transição e permitir que ele planeje uma nova rota.

2 REFERENCIAL BIBLIOGRÁFICO E TEÓRICO

Este capítulo apresenta inicialmente uma revisão sistemática sobre os principais assuntos abordados nessa pesquisa. Dessa revisão, pode-se extrair que existem diversas abordagens sobre esses assuntos envolvendo o conhecimento de várias disciplinas, ressaltando que várias ciências têm contribuído significativamente para o avanço científico nessa área de conhecimento. A tecnologia da informação, as inovações tecnológicas, novos conceitos e métodos associados a inteligência artificial, dentre outros, têm promovido um avanço expressivo e um novo olhar sobre os assuntos relacionados à engenharia de tráfego. Em resumo, se faz necessário um olhar sistêmico, dinâmico e transdisciplinar para estudar todos esses assuntos.

Na sequência, é apresentada uma breve descrição da evolução dos sistemas de controle de tráfego no Brasil e uma revisão teórica e bibliográfica sobre os principais conceitos utilizados no estudo de sistemas de controle de tráfego, tais como:

- ✓ motivação do controle de tráfego mediante a utilização de semáforos;
- ✓ descrição dos sistemas de controle de tráfego;
- ✓ importância da inteligência artificial no desenvolvimento tecnológico desses sistemas;
- ✓ diversidade de técnicas de inteligência artificial já empregadas no controle de tráfego;
- ✓ aderência das possibilidades de sensoriamento em relação às técnicas de inteligência artificial aplicadas nesse controle;
- ✓ ganho introduzido pelo *machine learning* na construção do conhecimento necessário às demandas de sistemas modernos e;
- ✓ dimensão da simulação de fluxos de tráfego e da sincronização de semáforos na eficácia e eficiência dos sistemas de controle adaptativo de semáforos em tempo real.

2.1 REVISÃO SISTEMÁTICA

Preliminarmente, foi realizada uma revisão sistemática da literatura por meio da base de pesquisa *Web of Science*. Esta revisão empregou a pesquisa avançada disponibilizada pela plataforma, usando as palavras-chaves: *intelligent transportation system, urban traffic*

control, intelligent system control, intelligent traffic light control, flow prediction, traffic prediction, traffic flow prediction, data mining, deep reinforcement learning, q-learning, traffic signal timing, traffic light scheduling e traffic signal control, conforme os comandos de consulta descritos abaixo, onde o símbolo “#” representa o número da consulta e “TS” é a variável *tópico* da base de dados.

#1 → TS = (“intelligent transportation system” OR “urban traffic control” OR “intelligent system control” OR “intelligent traffic light control”);

#2 → TS = (“flow prediction” OR “traffic prediction” OR “traffic flow prediction”);

#3 → TS = (“traffic signal timing” OR “traffic light scheduling” OR “traffic signal control” OR “traffic optimization”);

#4 → TS = (“data mining” AND “deep reinforcement learning” AND “q-learning”);

#5 → TS = (“data mining” AND “deep reinforcement learning”);

#6 → TS = (“deep reinforcement learning” AND “q-learning”);

#7 → TS = (“data mining” OR “deep reinforcement learning” OR “q-learning”);

#8 → TS = (#1 AND #2 AND #3);

#9 → TS = (#1 AND #2 AND #3 AND #7);

#10 → TS = (#1 AND #2 AND #3 AND #6);

#11 → TS = (#1 AND #2 AND #3 AND #5);

#12 → TS = (#1 AND #2 AND #3 AND #4).

A pesquisa retornou os resultados apresentados no Quadro 2.1, que discrimina o resultado parcial de cada consulta e o resultado de combinações dessas consultas entre si, sempre com o operador lógico “AND” para extrair apenas os registros comuns entre as consultas. Neste contexto, ressaltou-se especialmente as consultas #11 e #12 que pesquisaram a existência de estudos associados a qualquer uma das palavras-chaves das consultas #1, #2 e #3 com o emprego de *data mining*, *deep reinforcement learning* (#5) e *Q-learning* (#4).

Cabe destacar que, preliminarmente, a consulta #4 não encontrou registros e, por isso, foi realizada a consulta #5 sem o termo *Q-Learning*. Pelo mesmo motivo, foram testadas também consultas sem a palavra-chave *data mining* (#6) e para qualquer uma das palavras-chaves: *data mining*, *deep reinforcement learning* e *Q-learning* (#7).

Quadro 2.1: Resultados da pesquisa realizada na base de dados *Web of Science*

Resultados das Combinações (“AND”)							
Consulta	#1	#2	#3	#4	#5	#6	#7
#1	4.262	176	99	Nenhum	Nenhum	1	110
#2	176	3.716	17	Nenhum	Nenhum	Nenhum	99
#3	99	17	1.970	Nenhum	Nenhum	8	121
#4	Nenhum	Nenhum	Nenhum	1	1	-	-
#5	Nenhum	Nenhum	Nenhum	1	9	-	-
#6	1	Nenhum	8	-	-	523	-
#7	110	99	121	-	-	-	85.209
#8	2						
#9	Nenhum						
#10	Nenhum						
#11	Nenhum						
#12	Nenhum						

Essa base de consulta permite identificar a origem (países) dos cientistas que mais pesquisam sobre o referido assunto, especificamente em relação à previsão de tráfego e à otimização de planos semafóricos no contexto do controle inteligente de tráfego urbano. Fez-se uma hierarquização dos países que mais apresentam pesquisas sobre esses temas, escolhendo-se sempre os principais.

De forma geral, a China lidera expressivamente a quantidade de pesquisas, seguida pelos Estados Unidos da América (EUA). Além disso, nos últimos 4 anos, a China aumentou muito a sua participação nesse cenário em números absolutos e percentuais em relação aos demais países. O Canadá e a Índia emergiram como países que têm aumentado seus interesses sobre esse assunto. No mesmo período, novas áreas de pesquisa incluíram esses assuntos em seus trabalhos e a quantidade de pesquisas mais do que duplicou, praticamente.

Assim, o Quadro 2.2 apresenta os 10 países que têm mais publicações com as palavras-chaves que definiram as consultas #1, #2 e #3. No Quadro 2.3, as combinações possíveis entre os resultados dessas consultas, hierarquizando os 5 primeiros países que se destacam no cenário internacional.

O Quadro 2.4 discrimina as referências associadas às áreas de pesquisas correlatas.

Quadro 2.2: Panorama internacional das pesquisas conforme as consultas #1, #2 e #3.

#1			#2			#3		
Países	Qtd	%	Países	Qtd	%	Países	Qtd	%
China	1.664	39,04	China	1.640	44,13	China	638	32,39
USA	642	15,06	USA	677	18,22	USA	532	27,01
India	361	8,47	Inglaterra	173	4,66	Japão	79	4,01
Coréia do Sul	225	5,28	Austrália	157	4,22	Canadá	66	3,35
Taiwan	221	5,19	Canada	152	4,09	Inglaterra	62	3,15
Canadá	155	3,64	Índia	135	3,63	Índia	60	3,05
Inglaterra	124	2,91	Japão	99	2,66	Coréia do Sul	58	2,94
Japan	115	2,70	Coréia do Sul	99	2,66	Singapura	55	2,79
Austrália	105	2,46	Alemanha	96	2,58	Alemanha	53	2,69
França	103	2,42	Itália	90	2,42	França	47	2,39

Quadro 2.3: Panorama internacional das pesquisas conforme as combinações entre as consultas #1, #2 e #3.

#1 e #2			#1 e #3			#2 e #3		
Países	Qtd	%	Países	Qtd	%	Países	Qtd	%
China	115	65,34	China	44	44,44	China	6	35,29
EUA	25	14,20	EUA	20	20,20	EUA	3	17,65
Canada	8	4,55	Taiwan	7	7,07	Irã	2	11,76
Austrália	6	3,41	Brasil	4	4,04	Brasil	1	5,88
Índia	6	3,41	Austrália	3	3,03	Canada	1	5,88

A consulta por estudos e pesquisas abrangendo os temas de previsão de fluxos de tráfego e otimização de planos semafóricos (combinação #2 e #3) resultou em 17 documentos. Na continuação, um resumo cronológico apresenta os 11 trabalhos principais dessa consulta.

Guan e Yang (2002), em sua pesquisa, discutem a operação do sistema de controle de tráfego urbano adaptativo – AUTCS. Eles apresentam um método novo de previsão de fluxo de tráfego baseado em lógica *neuro-fuzzy*, conhecido como modelo de previsão de rolamento de tráfego – TRPM. Além disso, eles descrevem o método de otimização de sincronização fazendo referência aos três sistemas de controle semafóricos típicos da época: TRANSYT, SCOOT e SCATS. Fundamentalmente, Guan e Yang (2002) abordam

a arquitetura padrão de um AUTCS, bem como às relações intrínsecas ao funcionamento desses sistemas.

Quadro 2.4: Publicações classificadas por áreas de pesquisa conforme a combinação das consultas #2 e #3.

Áreas de pesquisa	Contagem de registros	Percentual sobre os 17 registros
Ciência da Computação	12	70,59%
Engenharia	5	29,41%
Transportes	4	23,53%
Sistemas de Controle de Automação	3	17,65%
Robótica	2	11,76%
Química	1	5,88%
Instrumentação	1	5,88%
Ciência dos Materiais	1	5,88%
Ciência de Gestão de Pesq. Oper.	1	5,88%
Telecomunicações	1	5,88%

Fora do contexto do tráfego urbano, mas relevante por sua contribuição, tem-se o trabalho de Gotteland e Durand (2003). Eles propuseram dois métodos de otimização global baseados em algoritmos genéticos para minimizar o tempo de taxiamento de aeronaves, visando a controlar o tráfego na malha aeroportuária. De acordo com os resultados da pesquisa, os atrasos gerados no aeroporto Roissy Charles de Gaulle, o mais movimentado da Europa naquela época, foram amplamente reduzidos com o emprego dessas ferramentas. Os métodos foram desenvolvidos respeitando a distância entre as aeronaves e a capacidade das pistas a fim de simular o tráfego das aeronaves em solo.

Retornando para o ambiente do tráfego urbano, Yu (2005) pesquisou um sistema de controle de semáforos em tempo real integrado por um modelo de previsão de fluxo de tráfego, que usa o princípio da máxima verossimilhança e o controle de decisão adaptativo de Markov, baseado em programação dinâmica. A abordagem proposta estima os parâmetros de chegada do fluxo de tráfego nas interseções e prevê o estado de probabilidades das transições. Baseado nisso, o autor formula o problema de controle semafórico como um problema de tomada de decisão de um sistema estocástico, em que dois padrões diferentes de chegada de fluxo de tráfego, distribuição Normal e distribuição de Poisson, são considerados. Os resultados alcançados foram animadores, concluindo que mais avaliações e testes com essa abordagem precisariam ser realizados.

Incentivados pela análise das características de sistemas de tráfego de curta duração, com grandes incertezas e não-linearidade, Weng e Du (2006) apresentaram um novo modelo de previsão baseado em rede neural híbrida, ELMAN, para fluxos de tráfego de curta duração em interseções urbanas. As informações passadas e futuras do sistema de previsão foram integradas. Segundo esses pesquisadores, o resultado da pesquisa indicou que a acurácia de previsão do modelo apresentado era mais efetiva e avançada do que os resultados obtidos pelos métodos tradicionais da época. Não apenas o período de controle do sinal foi tomado como o intervalo de tempo do modelo mas também as taxas de fluxo e ocupação dentro do período de uma fase foram tomadas como as duas variáveis dimensionais do modelo.

Kaedi *et al.* (2007) propuseram um método de controle para sincronização de semáforos em dois estágios. O primeiro estágio usa correlações horárias e diárias de fluxo de tráfego para fazer a previsão do volume de tráfego empregando uma rede *neuro-fuzzy*, chamada Sistema de Inferência Adaptativo *Neuro-Fuzzy* – ANFIS. No segundo estágio, o ciclo e a otimização do sincronismo de cada fase de um semáforo foram estimados usando uma combinação de uma rede auto organizável com uma rede neural Hopfield. Os autores relataram que os resultados obtidos na interseção foram consideravelmente melhores do que a sincronização semafórica por tempo fixo e, além disso, que o desempenho dos planos semafóricos propostos pelo método foi maior do que o dos planos calculados pelo programa SYNCHRO em 30% dos casos.

Leshem e Ritov (2007) afirmam no seu estudo, que pouco tem sido feito em relação à previsão de tráfego e, por isso, propuseram um sistema baseado em aprendizagem automática (*machine learning*) para gerenciar e controlar os fluxos de tráfego, visando o problema de previsão desses fluxos. Eles desenvolveram um algoritmo novo baseado na teoria de dois algoritmos, *Random Forest* e *Adaboost*. O desempenho desse novo algoritmo foi bem razoável usando dados reais e, de acordo com esse modelo de avaliação de fluxo de tráfego, permite estimar e prever se existe congestionamento ou não em um determinado momento em uma interseção.

Lee e Abdulhai (2008) propuseram uma abordagem, segundo eles, única e inovadora para integrar o controle de prioridade do semáforo para os transportes públicos (TSP) com estratégia de controle adaptativo de tráfego, denominada Estratégia Otimizada para Tráfego Integrado e Controle de Semáforos – OSTRAC. Essa ferramenta inclui um modelo

de previsão de fluxo de tráfego microscópico conectado em tempo real e um módulo de sincronização semaforica baseada em algoritmo genético. Os parâmetros críticos do algoritmo genético foram determinados por uma análise de sensibilidade. O modelo de fluxo de tráfego desenvolvido demonstrou resultados de previsão confiáveis de acordo com os testes estatísticos realizados.

Os referidos pesquisadores, Lee e Abdulhai (2008), afirmaram que os resultados obtidos foram avaliados comparando-os com o desempenho de outras três estratégias de controle semaforico: controle de tempo fixo sem TSP, controle de tempo fixo com TSP convencional e controle adaptativo com o método TSP convencional. Assim, revelam com clareza que a abordagem proposta por eles reduziu consistente e significativamente os atrasos, demonstrando sua eficiência na melhoria do tráfego geral e dos veículos de transporte público também.

Yang *et al.* (2010) apresentaram uma estrutura de previsão de tráfego baseada em padrões que é consistente com a evolução dinâmica do fluxo de tráfego e tem a habilidade de explorar os padrões de tráfegos passados a fim de fortalecer as previsibilidades. Eles desenvolveram vários padrões históricos para cada estado de fluxo de tráfego de acordo com os dados históricos classificados. Assim, os valores futuros do fluxo de tráfego podem ser rapidamente previstos por meio de técnicas de reconhecimento de padrões que identificam os padrões de tráfego atuais com os dados de tráfego registrados em tempo real.

Assim, esses autores garantem a qualidade da previsão, pois o método proposto por eles não introduz etapas múltiplas de previsão que costumam reduzir o sucesso dos modelos associados às mudanças abruptas do tráfego. O estudo comparativo realizado pelos autores conclui que a previsão baseada em padrões, considerando o estado do tráfego, é mais precisa do que o modelo clássico autorregressivo integrado de média móvel – ARIMA, que opera somente considerando séries temporais.

Jinhong Li *et al.* (2018) construíram um modelo de aprendizado profundo para prever o fluxo de tráfego de curto prazo baseado em LSTM (*Long Short-Term Memory*). De acordo com esses pesquisadores, a LSTM é muito adequada para prever o fluxo de tráfego a curto prazo porque essa arquitetura agrega vantagem no processamento de dados de séries temporais. A LSTM é um tipo especial de Rede Neural Recorrente ou RNN (sigla em inglês), que lembra de valores em intervalos arbitrários, sendo capaz de minerar o

comportamento dinâmico em uma sequência temporal com ótimo desempenho no processamento de linguagem natural e reconhecimento de voz. A rede LSTM é projetada com uma célula de memória para armazenar informações do histórico e, assim, pode memorizar informações de longo prazo em comparação com o RNN.

Eles aplicaram experimentalmente e analisaram esse modelo utilizando parâmetros diferentes, tais como, a duração do período anterior e o tamanho do neurônio da camada oculta. Os resultados desses experimentos indicaram que o tamanho do neurônio da camada oculta tem um grande impacto sobre o desempenho da previsão e que os modelos poderiam ser melhorados. Além disso, eles variaram a estrutura da camada oculta, utilizando a RNN básica, a LSTM e a GRU (*Gated Recurrent Unit*) para avaliar o desempenho do modelo e os resultados demonstraram que as aplicações da LSTM e da GRU foram similares, e que as duas foram melhores do que o RNN básico, para prever o fluxo de tráfego a curto prazo.

Yao *et al.* (2019) propuseram um modelo de otimização rolante para controle semafórico adaptativo em tempo real baseado em um modelo de fluxo dinâmico de tráfego. Esse modelo de otimização possui duas camadas com base em programação dinâmica para minimizar o atraso dos veículos a partir do comprimento de fase do semáforo. Depois, para capturar o fluxo dinâmico de tráfego, os pesquisadores desenvolveram uma estratégia de rolagem baseada em um modelo de previsão de fluxo de tráfego em tempo real. O modelo foi aplicado a uma interseção e, mediante simulações, os seus resultados foram comparados com a performance do algoritmo de Otimização Controlada de Fases – COP (sigla em inglês).

Para essa aplicação, o modelo precisou dos dados de tráfego de todas as interseções conectadas à interseção otimizada a fim de realizar a previsão do seu fluxo de tráfego e garantir dados realistas. Em comparação com o algoritmo COP, os resultados desse modelo de controle mostram que o método proposto foi capaz de reduzir tanto o atraso total dos veículos na interseção quanto em cada fase. Essa redução foi inversamente proporcional ao crescimento do fluxo de tráfego, sendo a taxa maior de 17,95% para 2.500 veíc./h. e a menor de 11,78% para 4.500 veíc./h.

Kim e Jeong (2020) desenvolveram um modelo de controle de tráfego em tempo real baseado nos algoritmos de LSTM e *Deep Q-Network* ou DQN, que tem várias aplicações

na área do aprendizado por reforço profundo. A rede LSTM foi acoplada ao modelo para fazer a previsão de tráfego e alimentar o algoritmo DQN. De acordo com esses pesquisadores, a maioria das pesquisas de controle de sinais de tráfego foram realizadas em um único cruzamento e o uso de simuladores virtuais, como o Simulador de Mobilidade Urbana – SUMO, empregados nesses experimentos limitam as considerações de variáveis que afetam as condições reais de tráfego, tais como horário, dia da semana e temperatura ambiente. Assim, eles propuseram um modelo de controle cooperativo de sinais de tráfego com previsão de fluxo de tráfego (TFP-CTSC) para múltiplas interseções e o aplicaram em uma malha 4x4 de interseções.

Nesse controle cooperativo de sinais de tráfego para múltiplas interseções, cada interseção é modelada como um agente e cada agente é treinado para tomar a melhor ação ao receber os estados de tráfego. De acordo com a arquitetura do modelo, os agentes estimam os valores locais da função Q e compartilham suas informações com outros cruzamentos adjacentes. Esse compartilhamento entre os cruzamentos permite estimar valores globais ideais da função Q. Depois, os resultados experimentais desse modelo foram comparados com um modelo não cooperativo e sem previsão de fluxo de tráfego. Além disso, os pesquisadores testaram combinações entre o tempo de espera e o comprimento de filas como recompensas do DQN. Os resultados do modelo proposto superaram os resultados dos modelos comparados e o seu desempenho foi melhor usando apenas o tempo de espera como recompensa.

2.2 CONTROLE DE TRÁFEGO COM SEMÁFOROS

De acordo com Newell (1989), infelizmente, muitos engenheiros de tráfego eram treinados para interpretar fórmulas como algo, ainda que na forma de um programa de computador, em que se substituíam números para realizar cálculos sem conhecer as causas e os efeitos físicos observáveis. Baseado em 35 anos de pesquisa, o objetivo do seu trabalho foi, em parte, preencher a lacuna entre a teoria e o mundo real do controle de tráfego, pois, segundo o autor, enquanto a teoria era muito acadêmica, o controle de tráfego era realizado em bases lógicas equivocadas. Assim, ele percebeu a necessidade do desenvolvimento de algumas equações fundamentais que descrevessem a interação entre os veículos e sua dependência em relação a algum sistema de controle externo para fundamentar cientificamente a teoria do controle de tráfego com semáforos.

De acordo com a abordagem de Newell (1989), dada uma função objetivo possível, a solução seria determinar os planos semaforicos que minimizassem o custo da viagem. Contudo, tais equações fundamentais para descrever o comportamento do tráfego ainda não existiam. Antes do trabalho dele, só havia uma vasta coleção de dados empíricos cuja maior parte era difícil de interpretar e não havia uma função objetivo bem definida para modelar o comportamento dinâmico dos veículos, pois a percepção da sociedade não era clara, principalmente em termos de como equilibrar o ganho ou custo de uma pessoa contra o de outra pessoa.

Contudo, os engenheiros de tráfego sabem desde há algum tempo que o trânsito se comporta como um fluido em movimento, transmitindo ondas de choque de congestionamento a montante de estreitamentos de pista ou interseções e, às vezes, a jusante deles. Essas ondas de choque podem resultar das causas mais insignificantes e, inclusive, os hábitos dos condutores podem contribuir para o colapso do tráfego.

Segundo Holmes (1994), o fluxo de tráfego nas rodovias é mais simples porque todos se deslocam na mesma direção e não há semáforos ou cruzamentos de tráfego para tornar o trânsito tão complexo quanto na malha viária de uma cidade. Quando o fluxo de tráfego colapsa, surge uma onda de choque, analogamente às ondas de compressão em um fluido. Freando, os motoristas provocam uma onda que se propaga para trás parando um motorista após o outro, que se juntam à fila. Depois, com a desobstrução, uma onda similar de aceleração do tráfego se espalha igualmente para trás através da fila. Por isso, o tráfego de uma rodovia para muitas vezes em lugares onde não há um obstáculo visível, como um acidente que pode estar muito à frente do motorista.

Aprofundando na questão dos engarrafamentos, Rick Donnelly (*apud* HOLMES, 1994) esclarece que os planejadores precisam tomar decisões táticas, como instalar semáforos para regular o fluxo de tráfego que entra em uma rodovia e definir a taxa de comutação mais eficiente entre eles, exigindo análises mais detalhadas, principalmente quando os motoristas saem de uma rodovia para uma malha urbana. Portanto, o papel mais óbvio dos planejadores de trânsito é coordenar o tempo dos semáforos para garantir o mínimo possível de atrasos. Para fazer isso, os engenheiros devem manipular a duração de cada ciclo completo do sinal verde para o vermelho e vice-versa e a sincronização de uma série de semáforos, de modo que a maior quantidade possível de motoristas cruze uma sucessão de sinais verdes.

Paradoxalmente, as estratégias mais racionais para fazer isso parecem não atender às condições dos horários de pico. Considerando a questão do comprimento do ciclo, cada vez que os semáforos mudam de fase há um período de alguns segundos em que ninguém usa a interseção, o fluxo de tráfego em movimento pára e o outro continua parado em espera da fase verde. Portanto, semáforos que comutam com menor frequência têm uma maior capacidade de tráfego, embora os carros em espera, na fase vermelho, tenham que esperar mais tempo para que possam se mover novamente.

2.3 OS SISTEMAS DE CONTROLE DE TRÁFEGO NO BRASIL

No Brasil, embora não existam registros sobre as primeiras experiências e estudos relacionados com a implantação e controle de semáforos, acredita-se que a evolução do controle semaforico se desenvolveu principalmente na década de 70, mediante iniciativas tomadas pela Companhia de Engenharia de Tráfego do Município de São Paulo – CET/SP, a partir de diretrizes oriundas das experiências de outros países (PIETRANTONIO e BONETTI, 2007).

Em 1976, a introdução de controladores multiplanos de tempo fixo importados foi o primeiro passo quando os equipamentos eletromecânicos ainda dominavam o cenário nacional. De acordo com Bonetti e Pietrantonio (2001), o segundo e grande passo foi a implantação de sistemas de controle centralizados com programações de tempos fixos, que culminou com o projeto Semáforos Coordenados – SEMCO – em São Paulo em 1980.

Depois, esses sistemas foram modernizados para sistemas de controle em tempo real a partir do final da década de 90, ainda utilizando controladores eletrônicos importados. Na mesma época, um esforço paralelo de menor importância foi empreendido para desenvolver e testar controladores eletrônicos nacionais por meio da iniciativa conjunta da CET/SP e do Instituto de Pesquisas Tecnológicas do Estado de São Paulo – IPT/SP (BONETTI, 2001, *apud* PIETRANTONIO e BONETTI, 2007).

O controle semaforico atuado não tem sido utilizado em larga escala no Brasil, exceto em estágios específicos de travessia de pedestres acionados por botoeira. Na cidade de São Paulo, por exemplo, após a implantação do controle em modo coordenado *off-line*, o controle semaforico em modo atuado foi cogitado, mas implantado em apenas 30 interseções enquanto mais de 400 semáforos eram centralizados. Segundo Pietrantonio e Bonetti

(2007), este fato decorreu em parte por causa do custo elevado de instalação e manutenção dos detectores, usualmente laços indutivos, bem como por causa da falta de conhecimento técnico sobre o seu uso e a sua programação (parametrização) e da ausência de recursos mais avançados nos equipamentos nacionais.

Esses pesquisadores destacam ainda que parece ter se formado um círculo vicioso entre a falta de aplicação do controle atuado e a falta de desenvolvimento de técnicas e de equipamentos nacionais, o que teria motivado uma deficiência nos controladores nacionais que normalmente oferecem apenas a lógica de atuação mais simples e tradicional, que é a forma mais básica de variação do controle semaforico em função da observação da demanda de tráfego.

A experiência da CET/SP parece ter norteado a realidade de outros centros urbanos, tais como: Rio de Janeiro, Juiz de Fora, Campo Grande, Porto Alegre, Vitória, Campinas, Ribeirão Preto e Curitiba, que foi a segunda cidade brasileira a implantar o controle semaforico centralizado depois de São Paulo, em meados da década de 80. Depois disso, nem o controle atuado nem o centralizado foram implementados nas demais cidades brasileiras no mesmo período.

Nos anos de 1990, a maioria dos Sistemas de Controle de Tráfego por Área – CTA – em operação no Brasil, inclusive no exterior, representavam uma variante dos antigos sistemas centralizados de tempo fixo, desenvolvidos ao longo da década de 60 (WOOD, 1993, *apud* LOUREIRO *et al.*, 2002). Em comum, os sistemas apresentavam a característica de operarem, de forma isolada ou coordenada, grupos de interseções semaforizadas dentro de regiões homogêneas, em termos de tráfego, denominadas de subáreas. O objetivo era determinar o tempo de ciclo ótimo, assim como as repartições de verdes e as defasagens, conforme um critério específico de minimização de atrasos, número de paradas e comprimentos de fila, ou ainda, de obtenção de um grau de saturação desejável nas aproximações de cada cruzamento controlado.

De acordo com Ribeiro (1994), o primeiro sistema de controle de tráfego centralizado da cidade do Rio de Janeiro – CTA-RIO – começou a operar em 1994, dividido em 6 módulos e abrangendo o total de 715 interseções semaforizadas. Esse sistema era de tempo fixo e o seu primeiro módulo, que foi a área do centro da cidade, iniciou-se com 131 interseções semaforizadas.

Em 2001, o sistema de controle de tráfego em área de Fortaleza – CTAFOR (MEDEIROS *et al.*, 2001) foi implantado na malha viária daquele município em uma área de 150 km², contemplando um conjunto de 150 interseções semaforizadas, um subsistema de CFTV com 30 câmeras de vídeo para monitorar o tráfego dos cruzamentos mais carregados, um subsistema de PMV com 20 painéis posicionados nos principais corredores arteriais da cidade e um subsistema de controle semafórico do tipo adaptativo, em tempo real, baseado no software britânico Técnica de Otimização de Defasagem, Ciclo e Fase – SCOOT (*Split, Cycle and Offset Optimization Technique*).

Vilanova (2005) relata que, atualmente, São Paulo possui dois sistemas de controle semafórico em operação: o SCOOT e o Agente Inteligente de Controle Adaptativo de Tráfego – ITACA (*Intelligent Traffic Adaptive Control Agent*), sendo que esse sistema ITACA também opera em Salvador e Belo Horizonte desde os anos de 2003 e 2005, respectivamente.

Não se obteve mais referências sobre estudos relacionados a esses temas nas outras cidades brasileiras ou sobre novas técnicas aplicadas.

2.4 SISTEMAS DE CONTROLE DE TRÁFEGO

Os sistemas de Controle de Tráfego, como parte essencial da gestão dinâmica do tráfego urbano, visam a reduzir os congestionamentos, mitigar os seus impactos ambientais e, ao mesmo tempo, aumentar a segurança do tráfego e a eficiência da rede viária. O estado da arte em sistemas de controle de tráfego urbano utiliza modelos de tráfego para estimar, prever e otimizar o fluxo de tráfego com base em medições em tempo real (Qadri *et al.*, 2020; Joo *et al.*, 2020; Papapanagiotou e Busch, 2020).

De acordo com as estratégias de controle, os sistemas de controle de tráfego se distinguem em sistemas de controle isolado, coordenado e centralizado. Além dessa distinção, os sistemas de controle de tráfego também podem ser definidos conforme o tipo de operação, ou seja, se operam com tempos fixos, atuados pelo tráfego ou em tempo real.

2.4.1 Controle de tempo fixo

Este controle utiliza planos semafóricos pré-determinados com base em dados históricos de volume de tráfego, obtidos principalmente por contagens volumétricas. Estes planos

são calculados para atender os volumes médios de tráfego. Nesse tipo de controle, os tempos semafóricos (ciclo e tempo de verde) são constantes durante um determinado período (LEAL, 2016). Neste compasso, “os controladores de tempo fixo” apresentam uma certa flexibilidade de programação, pois, modificando adequadamente os tempos pode-se definir comprimentos de ciclo, intervalos de tempo e *offsets* (defasagens) mais adequados para cada caso” (ANDRADE, 2004).

Então, o controle pode ser efetuado com base em um único plano semafórico ou na adoção de planos específicos para atender a demanda de tráfego em períodos distintos do dia e para diferentes dias da semana. Portanto, este tipo de operação é adequado para áreas urbanas onde o tráfego se comporta de maneira aproximadamente cíclica, com volumes de tráfego se repetindo na mesma hora do dia para diferentes dias da semana, sendo apropriada à aplicação de diferentes planos ou programações semafóricas conforme o período do dia (LOPES, 2010).

2.4.2 Controle atuado pelo tráfego

É o controle chamado também por controle por seleção dinâmica (LOPES, 2010) e que evoluiu a partir do controle de tempo fixo, pois, embora os seus planos semafóricos continuem sendo previamente calculados, eles não são regidos por uma tabela horária, mas pelo volume de tráfego e (ou) pela presença de pedestres no ambiente de controle.

Andrade (2004) destaca que o controle atuado pode se dar por meio de três formas diferentes para atender as demandas, a saber: controle semi-atuado, controle totalmente atuado e controle volume-densidade.

Na medida em que os sensores alocados nesse ambiente fazem a detecção, o sistema seleciona o melhor plano semafórico pré-definido em sua biblioteca para atender à demanda. Os controladores atuados pelo tráfego possuem detectores de veículos e pedestres, além de lógica de decisão, e, por isso, são mais complexos que os de tempo fixo.

2.4.3 Controle em tempo real

No controle em tempo real ou ativo (LEAL, 2016), o sistema recebe os dados dos sensores no momento em que esses são detectados, os processa, extrai os parâmetros atuais do volume de tráfego e ajusta os planos semafóricos, adaptando-os para atender as condições

reais do tráfego. Nesse tipo de controle, o ciclo e os tempos de verde são ajustados para manter um grau aceitável de saturação nas aproximações das interseções e, as defasagens são ajustadas para minimizar os atrasos e (ou) paradas dos veículos (CET-RIO, 2002, *apud* LOPES, 2010). Ele pode gerenciar dinamicamente congestionamentos recorrentes e não recorrentes.

Nesse tipo de sistema é fundamental que se tenha controle de todo o fluxo veicular em todas as aproximações de todas as interseções do ambiente de controle. Por isso, o controle em tempo real depende de uma infraestrutura densa de detectores (LEANDRO, 2001, *apud* LOPES, 2010). De acordo com Mirshahi *et al.* (2007, *apud* LEAL, 2016), os sistemas baseados nesse tipo de controle “consistem em uma combinação de estratégias operacionais que, quando implantadas em conjunto, ajudam a aperfeiçoar a operação da infraestrutura existente e oferecem benefícios mensuráveis para a rede de transporte”.

2.4.4 Sistema de controle isolado

O controle de tráfego isolado é o sistema mais simples que existe. De acordo com Leal (2016), “cada interseção é controlada independentemente das demais, ou seja, não há nenhum tipo de coordenação ou sincronismo semafórico”. Segundo Ribeiro (2007, *apud* Lopes, 2010), a grande maioria dos controles de tráfego isolados segue a teoria de Webster (1958), por meio da minimização do atraso veicular. Em controle isolado, existem dois tipos de operação semafórica, a saber: a operação em tempo fixo e a atuada pelo tráfego.

2.4.5 Sistema de controle coordenado

Esta estratégia tem a finalidade de coordenar o tráfego por progressão na via arterial ou em uma determinada área. O controle coordenado surge como solução para o problema do aumento do volume de tráfego em diversas interseções que gera saturação de cruzamentos e pelotões ao longo das principais vias bem como acréscimo do número de paradas e atraso ao longo das mesmas. Esta estratégia pode ser utilizada em áreas ou corredores semaforizados, onde se tenha uma densa rede viária sem uma hierarquização bem definida das suas vias ou em um corredor arterial, onde a coordenação semafórica é chamada de onda verde.

Uma coordenação em uma via arterial é comumente chamada de onda verde ou banda de passagem porque uma porção do ciclo na qual um pelotão de veículos, movimentando-se

a uma velocidade constante, pode cruzar um conjunto de interseções sem parar sob a luz verde. Para que isso aconteça, é preciso determinar alguns parâmetros, tais como: ciclo, tempo de verde de cada aproximação e, principalmente, defasagem, além de garantir que os semáforos estejam operando com o mesmo tempo de ciclo semafórico ou que eles sejam múltiplos entre si (LOPES, 2010).

Sunkari *et al.* (2004) apresentam os principais objetivos do controle coordenado em interseções semaforizadas:

- ✓ maximizar a capacidade global da rede, das vias e dos cruzamentos críticos, que representam os gargalos;
- ✓ minimizar os tempos de viagem, reduzindo atrasos e paradas para permitir que os veículos se desloquem continuamente, evitando a formação de filas de veículos a fim de que não aumentem tanto em uma interseção a ponto de interferir em outra interseção, fechando o cruzamento;
- ✓ dispersar os pelotões de forma que o seu movimento através dos sucessivos cruzamentos não seja interrompido;
- ✓ sincronizar os semáforos para manter o movimento contínuo do tráfego a uma velocidade definida ao longo de uma via arterial (em sistemas sincronizados ou progressivos);
- ✓ reduzir os impactos negativos do tráfego no ambiente e no consumo de energia;
- ✓ aumentar a segurança do tráfego.

2.4.6 Sistema de controle centralizado

De acordo com Oliveira Neto *et al.* (2006), os métodos normalmente usados na atualização de programações de redes semafóricas em tempo fixo demandam um grande esforço de coleta de dados em campo, envolvendo pesquisas volumétricas e de fluxo de saturação em todos os cruzamentos da rede. Esses dados são usados para alimentar um modelo de tráfego que determina os parâmetros básicos do plano semafórico (proporções de verdes, defasagens e ciclos).

No caso de redes com um número grande de semáforos, este processo é trabalhoso e demorado. Este problema pode ser eliminado por meio do monitoramento contínuo da

demanda com o uso de detectores, que são dispositivos capazes de estimar o volume veicular que passa em determinada seção de via. Estes detectores, assim como os controladores semaforicos, podem ser interligados a um computador central formando o que é conhecido como controle semaforico centralizado.

Com os sistemas centralizados de controle de trafego surgiu o termo Controle de Trafego por Área (CTA) que define uma estratégia de controle em que a região a ser controlada é subdividida em sub-regiões (áreas), com suas interseções operadas por controladores em campo que se comunicam com um computador denominado de computador de área ou zona, responsável por gerenciar os controladores de uma determinada área. E estes computadores de zona comunicam-se com um computador central que realiza o controle e direciona as ações para os controladores locais (LOPES, 2010).

A estratégia de controle centralizado dos semaforos pode operar em tempo fixo (tabela horária) e por seleção dinâmica ou tempo real (adaptativo). Em qualquer um destes tipos de operação, há a necessidade de atualização periódica das programações. Na operação em tempo fixo e por seleção dinâmica, que tomam como base planos de tempo fixo previamente calculados, os parâmetros são alterados para atender as condições de variação média do fluxo de trafego. Já no controle em tempo real, existe a necessidade tanto da calibração do modelo de trafego sendo empregado, como da atualização dos planos básicos de tempo fixo (planos de segurança usados em caso de falha de comunicação com o computador central). Esses planos básicos, no controle em tempo real, também são necessários como *input* inicial para o dimensionamento dos tempos pelo modelo adaptativo do trafego (OLIVEIRA *et al.*, 2006).

Tanto para Oliveira *et al.* (2006) quanto para Lopes (2010), na operação centralizada em tempo fixo ou *off-line*, o computador central armazena e implementa os planos semaforicos previamente calculados, com dados que refletem condições padrões esperadas do trafego. Estas condições são obtidas em dias típicos, periodicamente, ou em ocasiões especiais, como eventos esportivos ou sociais. Nessa operação, o momento da entrada de cada plano de trafego previamente calculado ocorre por intermédio de uma tabela horária (não alterada pelos padrões de trafego), ou seja, num determinado instante do dia, um determinado plano entra em operação, automaticamente imposto pelo computador central.

Na seleção dinâmica, a inserção dos planos fixos de tráfego não é regida por uma tabela horária, como acontece com a centralização em tempo fixo. Nesse caso, existe uma biblioteca de planos semafóricos pré-definidos que correspondem a dados históricos de diversos fluxos veiculares. Estes são selecionados automaticamente pelo computador quando o volume aumenta ou diminui nas aproximações de uma determinada área ou interseção. Esses planos semafóricos pré-definidos podem ser obtidos mediante a aplicação de programas de otimização *off-line* baseados nos dados volumétricos históricos. Além disso, embora não seja necessário que se tenha detectores veiculares em todas as aproximações, é indispensável que existam alguns deles em pontos estratégicos da rede.

Tanto na estratégia de operação com tempo fixo quanto de seleção dinâmica, os planos devem ser calculados antecipadamente por programas específicos de dimensionamento de programação semafórica, como, por exemplo, o software TRANSYT (*Traffic Network Study Tool*) (VINCENT *et al.*, 1980, *apud* OLIVEIRA NETO *et al.*, 2006), ou por outros softwares existentes no mercado.

A centralização semafórica com controle adaptativo, também conhecida como centralização em tempo real ou *on-line*, consiste na determinação e implementação contínua de planos semafóricos ótimos para cada interseção por meio do recebimento e da análise das informações dos sensores de tráfego e do ajuste sistemático dos parâmetros semafóricos (ciclo, tempos de verde e defasagens) para responder automática e adequadamente às variações frequentes das demandas reais de tráfego. Assim, os parâmetros são constantemente adaptados para atender às condições reais do tráfego. O ciclo e os tempos de verde são ajustados para manter um grau de saturação aceitável nas aproximações das interseções, enquanto as defasagens são ajustadas para minimizar os atrasos e (ou) paradas dos veículos (CET-RIO, 2002, *apud* LOPES, 2010).

A grande vantagem do sistema centralizado em tempo real em relação às demais operações é a possibilidade de responder rapidamente à demanda de tráfego das interseções, devido à variação diária e incidentes inesperados, como, por exemplo, acidentes ou enguiço de veículos. Portanto, o funcionamento de um sistema em tempo real depende principalmente de uma densa rede de sensores de tráfego e é fundamental que se tenha o controle de todo o fluxo veicular em todas as aproximações de todas as interseções a serem controladas (LEANDRO, 2001).

Existem alguns sistemas de controle centralizado em tempo real atualmente em uso, principalmente devido ao impulso promovido por vários projetos de pesquisa que se concentraram no desenvolvimento de estratégias de controle mais sensíveis e avançadas após a introdução de semáforos computadorizados no controle de tráfego em meados dos anos 60. Segundo Gartner *et al.* (1995), um dos estudos mais completos foi o Sistema de Controle de Tráfego Urbano (UTCS) gerenciado pela Administração Federal de Rodovias dos EUA (FHWA).

Avanços significativos em controles mais sensíveis foram obtidos durante os anos 80 com a introdução da Técnica de Otimização da Porcentagem de Verde, Ciclo e Defasagem – SCOOT (*Split Cycle Offset Optimisation Technique*), desenvolvido pelo Laboratório de Pesquisa Rodoviária e Transporte (TRRL), no Reino Unido em 1973 e do Sistema de Tráfego Adaptativo Coordenado de Sydney – SCATS (*Sydney Co-Ordinated Adaptive Traffic System*), desenvolvido pela Autoridade de Tráfego e Rodovias de Nova Gales do Sul (RTA), na Austrália (GARTNER *et al.*, 1995).

Neste contexto, o sistema de controle de tráfego centralizado em tempo real mais conhecido e utilizado em todo o mundo é o SCOOT. Este sistema foi implantado em alguns países como Inglaterra, China, Canadá, Chipre, Paquistão, Espanha e Brasil (nas cidades de São Paulo e Fortaleza).

De acordo com Shepherd (1994); Gartner *et al.* (1995); Leandro (2001); Shelby (2004); Andrade (2009); Prothmann *et al.* (2009); Zhao e Tian (2012); Smith *et al.* (2013); Nuli e Mathew (2013); Fleck *et al.* (2016); Chen e Sun (2016); Jin (2017), o SCATS é utilizado na Austrália, Nova Zelândia, China, Irlanda, Filipinas e Estados Unidos. Eles também fazem referência do desenvolvimento de outros sistemas em outros países, tais como: STAUKO (Alemanha), SAGE (França), SOS, OPAC (EUA), ITACA (Espanha), UTOPIA (Itália), ITALTEL, MIZAR *Automazione SpA* (desenvolvido para a cidade de Turin), PRODYN (França), RHODES (EUA), ALLOWS-D (França), TUC, ACS, SURTRAC e FITS.

2.4.7 Sistemas de controles adaptativos em rede

Em geral, a previsão de fluxos de tráfego e a sincronização de planos semaforicos realizadas pelos sistemas de controles adaptativos se baseiam em duas estratégias distintas,

uma de busca e outra de otimização. Segundo Shelby (2004), a estratégia de busca *look-ahead* serve como base para vários algoritmos contemporâneos de controle adaptativo de tráfego, incluindo o OPAC, PRODYN, COP (o algoritmo de controle de interseções do RHODES e ALLONS-D), entre outros. De acordo com Cai *et al.* (2009), o DYPIC, OPAC e PRODYN são desenvolvimentos sucessivos de otimização dinâmica de planos semafóricos.

Além disso, esses sistemas utilizam dados de tráfego para produzir informações sobre os atrasos mediante a implementação de modelos de simulação de tráfego. Neste mister, Shelby (2004) esclarece, por exemplo, que o modelo de simulação de uma interseção isolada é baseado nos modelos de DYPIC e de Webster, e que todos os algoritmos são implementados para utilizar as estimativas de filas atualizadas, os tempos de chegada dos veículos e os modelos de simulação de tráfego para estabelecer um ambiente de informações e simulações perfeito durante a otimização do sincronismo das fases preditas.

Neste contexto, a despeito da evolução dos sistemas, eles mantêm características comuns entre si. Por exemplo, Cai *et al.* (2009) destacam que o desempenho final do SCOOT e do SCATS depende da precisão da base de dados e de sua conformidade com os requisitos desses sistemas, que, essencialmente, são variantes *online* de estratégias de otimização *offline*, pois o plano semafórico mais adequado para atender ao tráfego detectado, embora seja selecionado e ajustado *online*, é calculado preliminarmente por um otimizador *offline* (Yu, 2005). O SCOOT reduz o atraso dos veículos em 12% quando comparado com os planos atualizados pelo TRANSYT, por exemplo. Enquanto o SCATS reduz 23% do tempo de viagem em comparação com operações não coordenadas (SHEPHARD, 1994; CAI *et al.*, 2009).

Entretanto, sistemas como esses são difíceis de configurar e manter e, demandam um tempo de computação significativo (PROTHMANN *et al.*, 2009). Alguns avanços recentes no controle semafóricos empregam tecnologia de inteligência artificial, tais como: redes neurais e lógica *fuzzy*. Entre os avanços, estão também os algoritmos que utilizam redes Petri e controle de decisão Markov, que têm sido aplicados em várias áreas de análise e controle de muitos sistemas estocásticos complicados (Yu, 2005). Portanto, é possível perceber que existe uma variedade considerável de sistemas, algoritmos e características devido à evolução dos próprios sistemas e das técnicas de abordagem do problema. Por isso, os sistemas que mais se destacam na literatura são descritos a seguir.

2.4.7.1 DYPIC

De acordo com Shelby (2004), o algoritmo DYPIC (Controle de Interseção Dinamicamente Programado) proposto por Robertson e Bretherton em 1974, usa programação dinâmica para determinar o controle ótimo e o atraso correspondente para um período de 10 minutos. O controle ótimo dado por esse algoritmo proporcionou um atraso significativamente menor do que o controle por tempo fixo atuado por um volume de tráfego, mas, como exigia uma capacidade computacional elevada para uso *online*, os pesquisadores propuseram uma estratégia simples, a de olhar para frente (*look-ahead*, em inglês) por 10 segundos, pois, assim, ele poderia ser usado *online*.

Na realidade, o DYPIC é um algoritmo que serve apenas para fins analíticos, criando uma série de tabelas de pesquisa que contêm valores exatos associados a cada fluxo de tráfego e os respectivos índices de desempenho, que servem como padrões de referência. Com o objetivo de usos práticos, uma função empírica da forma quadrática é proposta para uma solução heurística que adota o conceito de horizonte de rolamento.

Esse conceito importa na subdivisão de um horizonte de planejamento em dois períodos distintos. O primeiro deles seria o período "cabeça" com informações de tráfego detectadas e, o segundo, um período "cauda" com informações de tráfego sintetizadas. Depois, uma política ótima é calculada para todo o horizonte de planejamento, mas é implementada apenas para o período "cabeça". Finalmente, quando chega o próximo intervalo de tempo discreto, as informações recém detectadas ficam disponíveis e, então, o processo segue a frente e se repete (CAI *et al.*, 2009)

A estratégia de pesquisa *look-ahead* utiliza dados recém detectados para prever as chegadas nos próximos 10 segundos e, usando o seu modelo simples de tráfego, calcula todos os tempos de troca de fases possíveis em um horizonte de planejamento de 10 segundos. A opção de atraso mínima é implementada e, após alguns segundos, o algoritmo recalcula quando muda a fase com base nos novos dados detectados. Como dito anteriormente, essa estratégia serve como base para algoritmos de controle adaptativo modernos, tais como: OPAC, PRODYN, COP e ALLONS-D.

Segundo Shelby (2004), Robertson e Bretherton expandiram a abordagem *online* do seu modelo de otimização do tráfego para construir o SCOOT, que talvez seja o sistema de controle adaptativo mais amplamente empregado com mais de 200 implementações pelo

mundo (PROTHMANN *et al.*, 2009; ZHAO e TIAN; 2012). Esse autor destaca que a literatura apresenta diversos estudos de avaliação desse tipo de algoritmos que relatam reduções de atrasos de até 30% em relação aos controles de tempo fixo, atuado e coordenado em interseções isoladas ou de malhas abertas ou fechadas.

2.4.7.2 SCOOT

Para Shelby (2004), o SCOOT (Técnica de Otimização da Porcentagem de Verde, Ciclo e Defasagem) é um método totalmente responsivo projetado para coordenação de semáforos em rede que faz alterações frequentes, embora pequenas, nos parâmetros do ciclo ativo, na fração de verde e na defasagem para adaptar o plano de tempo fixo às variações no comportamento de tráfego.

De acordo com Zhao e Tian (2012), o sistema SCOOT divide a rede em regiões homogêneas, cada uma contém uma quantidade de nós que representam interseções semaforizadas ou travessia de pedestres. Esse sistema computa um tempo de ciclo único para todas as interseções e divide esse ciclo em tempos de verde para cada interseção. Logo ajusta os tempos de defasagem para minimizar os tempos de espera, utilizando um modelo dinâmico de tráfego (PROTHMANN *et al.*, 2009). Segundo Shepherd (1994), o SCOOT opera grupos de interseções adjacentes em um tempo de ciclo comum. Em qualquer instante, o tempo de ciclo, a duração de verde e a defasagem entre os semáforos são controlados pelas sincronizações mantidas no banco de dados do sistema.

Uma característica importante do SCOOT é o modelo de tráfego que utiliza informações de detectores de veículos nas aproximações de cada interseção para produzir as previsões. Por isso, o desempenho do SCOOT depende significativamente da informação do fluxo de tráfego obtida pelos detectores. De acordo com Zhao e Tian (2012), o sistema requer um grande número de detectores distribuídos adequadamente em todas as interseções. A localização dos detectores é importante e, geralmente, são instalados na extremidade, a montante do trecho de aproximação da interseção.

O sistema tem três procedimentos de otimização: otimização de frações de verde, otimização de defasagens e otimização de tempos de ciclos. O algoritmo prevê o atraso dos veículos e a quantidade de paradas em cada interseção para calcular o índice de desempenho do sistema a partir dessas previsões. De acordo com as performances da rede, o

SCOOT faz ajustes na sincronização dos planos semaforicos pré-determinados. Depois, faz ajustes nos tempos de verde com incrementos que variam de 1 a 4 segundos.

Assim, o SCOOT pode alterar a sincronização dos planos semaforicos de acordo com as flutuações de curta duração na demanda de tráfego em diferentes períodos de tempo, bem como monitorar as tendências diárias do fluxo e manter uma coordenação constante da rede semaforica. As tendências de longo prazo são satisfeitas pela acumulação de pequenas alterações ao longo de vários minutos. Assim, não ocorrem alterações bruscas na sincronização que podem interromper o fluxo de tráfego (SHEPHERD, 1994). Ainda, essa estratégia de controle tem baixa sensibilidade ao mau funcionamento de detectores e afasta muitos problemas de previsão do comportamento do tráfego por vários minutos futuros (ZHAO e TIAN, 2012).

Além da redução média de 12% nos atrasos dos veículos, Shepherd (1994) estima que, como as mudanças nos padrões de tráfego causam defasagem nos planos de tempos fixos, o SCOOT poderia conseguir uma redução de cerca de 20% nos atrasos em comparação a um sistema de tempo fixo em que os planos não são atualizados anualmente. Finalmente, conforme o relato de Bretherton a complexidade introduzida pelo SCOOT não traz vantagem quando a utilização de uma via atinge aproximadamente 80% de sua capacidade máxima, pois, nessa situação, não existe diferença entre o desempenho do SCOOT e o de uma estratégia de tempo fixo (PROTHMANN *et al.*, 2009).

2.4.7.3 SCATS

Para Zhao e Tian (2012), o SCATS é provavelmente o sistema de controle adaptativo mais avançado e amplamente usado. Como um sistema de controle semaforico adaptativo em tempo real, o SCATS pode ajustar a sincronização de semaforos em resposta às flutuações do fluxo de trânsito e capacidade do sistema viário. Segundo Shepherd (1994), o objetivo do SCATS é minimizar dinamicamente, por seleção de planos, um índice de desempenho idêntico ao do TRANSYT. O critério de otimização pode depender do estado atual do tráfego. Por exemplo, o sistema pode minimizar o número de paradas durante a noite ou maximizar esse número ao longo das horas do dia (PROTHMANN *et al.*, 2009).

Trata-se de um método adaptativo que requer uma base de dados predeterminada, inclusive uma biblioteca de planos de duração de verdes e de defasagens para cada interseção,

além, de planos de defasagem e parâmetros de controle para cada subsistema que são selecionados de acordo com as condições de tráfego (SHEPHERD, 1994; PROTHMANN *et al.*, 2009). Portanto, o desempenho final do SCATS depende da precisão desta base de dados tanto em termos de atendimento do intervalo esperado para as condições de tráfego quanto de sua conformidade com os requisitos do programa (SHEPHARD, 1994).

O SCATS foi projetado com três níveis de controles: central, regional e local. Para cada interseção, o sistema distribui a computação entre um computador regional no centro de operação do tráfego e o controlador de campo (ZHAO e TIAN, 2012). Em sua arquitetura, o SCATS usa computadores regionais para controlar a estratégia de controladores locais que são responsáveis pela coleta de dados e controle tático (PROTHMANN *et al.*, 2009). O nível central é operado por um computador central que se comunica com os outros níveis na hierarquia, principalmente para fins de monitoramento das finalidades.

O SCATS combina controle semafórico adaptativo com estratégias de controle convencional para prover aos usuários um sistema que pode integrar várias necessidades operacionais. As estratégias de controle incluem: operação adaptativa, coordenação entre os dias da semana e as horas do dia, e operação de semáforos isolados. Com ferramentas de relatórios em tempo real, o sistema permite que os engenheiros de tráfego façam o monitoramento de suas operações. O monitoramento contínuo das interseções alerta rapidamente os operadores sobre qualquer condição incomum ou falhas de equipamentos (Zhao e Tian, 2012).

O uso do sistema na Austrália foi amplo e resultou na implementação de 49 sistemas SCATS controlando 4400 conjuntos de semáforos. Estudos em vias arteriais tipicamente urbanas demonstraram que, em comparação com a operação não coordenada, o SCATS, além de reduzir 23% do tempo de viagem, produziu os seguintes benefícios:

- ✓ reduziu em 46% as paradas de veículos,
- ✓ reduziu em 20% os acidentes, e
- ✓ reduziu em 12% o consumo de combustíveis.

2.4.7.4 ITACA

Segundo Vilanova (2005), os conceitos aplicados no desenvolvimento do Sistema ITACA (Agente Inteligente de Controle Adaptativo de Tráfego) são semelhantes aos do

SCOOT, pois ambos são sistemas adaptativos em tempo real, ou seja, procuram a melhor programação dos semáforos através de pequenas e frequentes alterações dos tempos de verde, de ciclo e defasagens, em função do padrão de trânsito reconhecido pelos detectores.

O ITACA possui um subsistema adaptativo que opera com um modelo de tráfego e produz sincronismo entre ciclos, tempos de verde e defasagens para uma área centralizada de controle de tráfego. O sistema utiliza dados de fluxo de tráfego em tempo real, coletadas por detectores no campo, para modelar a sequência do tráfego em cada linha de parada. O sistema atualiza os dados de tráfego coletado e os processa a cada 5 segundos. Assim, a sincronização minimiza atrasos e paradas do tráfego na área, calculando a melhor solução para cada interseção e adaptando continuamente as sequências semaforicas para atender à demanda do tráfego.

De acordo com Kumar e Kumari (2016), o ITACA é uma solução integral para o gerenciamento do tráfego em áreas urbanas, promovendo a capacidade de controlar inteligentemente o tráfego em tempo real, enquanto se adapta constantemente as necessidades das mudanças do tráfego.

2.4.7.5 OPAC

Shephard (1994) esclarece que o Sistema de Controle Adaptativo para Políticas de Otimização – OPAC (*Optimization Policies for Adaptive Control*) – é uma estratégia computacional para controle semaforico descentralizado responsivo à demanda, caracterizado por um algoritmo de otimização dinâmica que calcula a sincronização de semáforos para minimizar o total de atrasos e paradas nas interseções (ZHAO e TIAN, 2012). O OPAC foi desenvolvido pela Universidade de Massachusetts em Lowell, sob o patrocínio do Departamento de Transportes Americano no início dos anos 80, para apoiar o controle responsivo à demanda de tráfego em interseções simples (SHEPHERD, 1994; PROTHMANN, 2011).

Shelby (2004) destaca que a estratégia do OPAC tem os seguintes objetivos:

- ✓ a estratégia tem que ter performance melhor do que os métodos *offline*;

- ✓ desenvolvimento de uma nova concepção de controle, mais adequado à variabilidade do tráfego – as noções convencionais de defasagem, fases e tempo de ciclo não eram adaptadas ao controle responsivo à demanda;
- ✓ a estratégia deve ser verdadeiramente responsiva à demanda, ou seja, adaptada às condições reais do tráfego e não aos valores históricos ou previstos que podem estar muito distantes dos reais;
- ✓ a estratégia não deve ser arbitrariamente restrita a períodos de controle de um comprimento especificado, mas deve ser capaz de atualizar frequentemente os planos, se necessário. Deve se basear em uma tomada de decisão descentralizada.

Ao contrário do SCOOTs, do SCATS e de outros sistemas de controle adaptativos em rede, o OPAC trabalha de forma descentralizada no sentido de que o seu algoritmo de controle é aplicado independentemente em cada interseção. Para o controle semafórico de interseções, esse sistema depende da programação dinâmica para calcular a política de mudança de sinais locais que é ótima para um horizonte futuro de tempo curto (PROTHMANN, 2011).

Cai *et al.* (2009) afirmam que Gartner descreveu detalhadamente a abordagem do horizonte de rolamento na introdução do OPAC. Neste contexto, Prothmann (2011) destaca que a programação dinâmica aplicada demandava um esforço computacional grande, impedindo a sua aplicação como um sistema *online* e, por isso, a programação dinâmica foi substituída na prática pela técnica de busca sequencial ótima restrita – OSCO (*Optimal Sequential Constrained*). Portanto, o OPAC não obedece ao princípio da otimalidade aderente à programação dinâmica e, ao invés disso, utiliza a busca OSCO para planejar todo o horizonte e emprega o custo final para penalizar as filas deixadas após o horizonte (CAI *et al.*, 2009).

O desenvolvimento da estratégia do OPAC se deu em três estágios. Primeiro, o procedimento de programação dinâmica foi desenvolvido, servindo como um padrão de performance para a responsividade à demanda, desde que a programação dinâmica é capaz de estratégias de controle ótimas. Depois, o procedimento foi simplificado para se ajustar à computação *online*. No terceiro estágio, o procedimento foi mais refinado pela introdução da abordagem do horizonte de rolagem, semelhante ao do UTOPIA. O procedimento tem as seguintes características básicas (Shelby, 2004):

- ✓ o processo de otimização é dividido em estágios sequenciais de t segundos, sendo o comprimento de um estágio compreendido entre 50 e 100 segundos;
- ✓ durante cada estágio, existe pelo menos uma mudança de sinal e, no máximo, três alterações de fase;
- ✓ uma função objetiva (atraso total) é avaliada sequencialmente para todas as sequências de alteração viáveis e é selecionada a sequência que gera o menor atraso.

Quanto à técnica OSCO, ela fornece resultados que são muito próximos (dentro de 10%) em relação à abordagem da programação dinâmica genuína (PROTHMANN, 2011). Shelby (2004) descreve que o OPAC utiliza a restrição de que pelo menos um e não mais do que três mudanças ou alterações são permitidas durante um horizonte de planejamento (intervalo entre 50 e 100s). Esta redução no espaço de solução permite uma performance efetiva enquanto reduz substancialmente o esforço computacional. O sistema possui as seguintes características:

- ✓ calcula os controles que se aproximam do ideal teórico;
- ✓ requer dados *online* de detectores localizados à montante e em interseções vizinhas;
- ✓ forma um bloco de construção para o controle descentralizado responsivo à demanda em uma rede.

Para Zhao e Tian (2012), o OPAC se distingue das estratégias de controle semafórico ciclo-fases por descartar o conceito de ciclo. Nesse sistema, o controle semafórico consiste de uma sequência de decisões de mudanças feitas em um intervalo de tempo fixo e a decisão se dá em cada ponto onde se inicia ou termina a fase atual. As técnicas de programação dinâmica são usadas para calcular as soluções ótimas. A geração mais recente desse sistema tem as seguintes características:

- ✓ simulação completa da interseção com identificação do pelotão e algoritmo de modelagem;
- ✓ otimização de duração de verde até oito fases em uma configuração de anel duplo;
- ✓ funções de performance configuráveis de todos os atrasos ou paradas nas interseções, ou ambos;

- ✓ comprimento de ciclo opcional e otimização de defasagem;
- ✓ modos coordenados livres e explícitos;
- ✓ pular fases na ausência de demanda; e
- ✓ respostas automáticas às alterações na sequência de fase.

De acordo com Cai *et al.* (2009), nas simulações e nos testes de campo, o desempenho do OPAC foi de 5 a 15% melhor do que os métodos existentes atuados pelo tráfego, sendo a maior parte dos benefícios alcançados em situação de alto grau de saturação. As preocupações com o OPAC se devem as restrições na busca OSCO que reduzem a flexibilidade da tomada de decisão e ao extenso horizonte de planejamento (60s) que levanta questões práticas sobre o valor da otimização tão distante no futuro com base em informações sintetizadas quando as decisões planejadas nunca podem ser implementadas.

2.4.7.6 PRODYN

Para Shelby (2004), o Sistema de Programação Dinâmica – PRODYN (*programmation dynamique*) é um algoritmo de busca em largura com método de programação dinâmica (FDP, *forward dynamic programming*) para resolver a formulação típica de estabelecer a melhor ação para minimizar o atraso em um horizonte de planejamento de curta duração.

De acordo com Shepherd (1994), O PRODYN é um algoritmo de controle de tráfego em tempo real desenvolvido ao longo da década de 80 pelo CERT e que tem sido implementado e testado no sistema da zona experimental e laboratório de tráfego de Toulouse – ZELT (*Zone Expérimentale et Laboratoire de Traffic de Toulouse*). Segundo Cai *et al.* (2009), o PRODYN otimiza as sincronizações por meio da programação dinâmica (FDP), adotando também a abordagem do horizonte de rolagem ou móvel.

As principais características desse sistema são (SHEPHERD, 1994):

- ✓ o controle é a decisão de mudar de um estágio para outro;
- ✓ a utilização de dois sensores de laço indutivo por pista, um na entrada da ligação e o outro 50 m da linha de parada;
- ✓ minimização explícita do atraso total; e
- ✓ uso de métodos de controle automático como, estimativa bayesiana, programação dinâmica e métodos descentralizados.

O controle é realizado na decisão de mudar de um estágio para outro. O método PROLYN se baseia na descrição do comportamento do tráfego por um conjunto de equações de estados não-lineares discretos no tempo, em que os estados são:

- ✓ o estágio e o tempo decorrido desde a última mudança para cada interseção;
- ✓ os tempos variáveis do fluxo de saturação que modela os movimentos não prioritários, congestionamento e a fila vertical para cada ligação;
- ✓ o número de veículos circulando em velocidade livre em cada ligação a cada cinco segundos.

Shepherd (1994) esclarece ainda que o critério usado no controle é o atraso total que é dado pela soma de filas verticais de todas as ligações e tempos de amostragens. Trata-se de uma aproximação dada pela soma de todas as filas de todos os tempos amostrados pertencentes ao horizonte de rolagem mais uma função dependendo das filas e do estágio no final do horizonte.

O controle computado pelo PROLYN é o resultado de uma estratégia de horizonte móvel, que é uma resposta otimizada de loop aberto. A estratégia de controle é otimizada sobre todo o horizonte, considerando as filas e as chegadas previstas. O controle é então implementado sobre o próximo período de amostragem e o processo é repetido. Todas as variáveis de estado, com exceção das filas, são previstas em uma base de loop aberto. Para cada fila, um estimador ou previsor de estado discreto é utilizado. A otimização semafórica é realizada por meio de um algoritmo FDP, que difere do algoritmo tradicional pelo seguinte:

- ✓ ao invés de calcular funções de custo nos pontos da malha usando a equação de estado reverso, faz comparações de avanço subconjunto do espaço de estados;
- ✓ a memória não é alocada para todos os subconjuntos existentes, mas apenas para aqueles subconjuntos que são efetivamente alcançados durante a otimização; e
- ✓ o tempo decorrido desde a última mudança não é tratado como um estado.

Shelby (2004) explica que a eficiência algorítmica adicional é alcançada através de uma relação de equivalência de estado aproximada, em que dois estados são considerados

equivalentes se estiverem na etapa de tempo na árvore, se mudaram para a mesma fase e se têm comprimentos de fila aproximadamente iguais em todas as faixas.

Para evitar a computação da equação de otimização no ponto da malha que eventualmente estabelece o problema da dimensionalidade, o FDP é particularmente projetado para agregar variáveis de estado em alguns subconjuntos e o valor de pertencer a um subconjunto só é avaliado quando se atinge ele realmente. A função de valor apresentando o custo futuro no FDP é diretamente adotada pelo trabalho de Robertson e Bretherton. Ao avaliar todos os subconjuntos que podem ser possivelmente atingidos, o FDP registra a trajetória ótima da política de controle no horizonte de planejamento (75s). E o processo segue como é definido na abordagem do horizonte de rolagem (CAI *et al.*, 2009).

O PROLYN também é capaz de estimativas em tempo real de parâmetros de tráfego tais como índices de movimentos alterados e taxas de fluxo de saturação. Esse sistema possui um nível superior para o controle de tráfego urbano em tempo real que foi desenvolvido para lidar com situações de congestionamento. Conforme foi reconhecido, o modelo de fila vertical do PROLYN é válido apenas para condições sub saturadas, ou seja, ele não considera as limitações dos resultados devido ao congestionamento à jusante. Dessa forma, essa restrição é útil para limitar os estados e (ou) controles do problema de otimização e forçar o sistema a permanecer em um estado onde o modelo é válido. Assim, o controle de nível superior determina os tempos de fase mínimo e máximo das interseções da rede (Shephard, 1994).

Os experimentos no sistema ZELT demonstraram ganhos médios de 10% com 99,99% de significância no tempo total de viagens (CAI *et al.*, 2009; SHELBY, 2004).

2.4.7.7 UTOPIA

Shepherd (1994) explica que o sistema de automação integrada pela otimização de tráfego urbano – UTOPIA (*Urban Traffic Optimization by Integrated Automation*) – é o nome dado a estratégia de controle usada no controle de tráfego em tempo real que foi implementado inicialmente sobre uma ampla e significativa área de Turin a partir de 1984. Tido como um sistema inovador de controle de tráfego descentralizado hierárquico com os objetivos de garantir prioridade absoluta para veículos públicos selecionados e otimizar o fluxo de tráfego privado em todas as condições de tráfego. Cai *et al.* (2009) o descrevem

como um sistema de controle híbrido que combina otimização dinâmica *online* e otimização *offline*.

O UTOPIA foi projetado para ser aplicado a sistemas de grande escala e, de forma geral, a sua abordagem tem os seguintes objetivos (SHEPHERD, 1994):

- ✓ decompor todo o problema de controle de uma forma hierárquica descentralizada;
- ✓ definir funcionalidades adequadas para os problemas resultantes, junto com regras para suas interações; e
- ✓ definir técnicas e algoritmos para resolver esses problemas.

A decomposição do problema foi feita topologicamente, definindo-se um subproblema para cada interseção da rede controlada. Essa série de subproblemas pequenos e inter-relacionados podem ser classificados em duas classes: nível de interseção e nível de área. Essa decomposição justifica-se porque a descrição do controle é híbrida (CAI *et al.* 2009). Eles explicam que esse controle é alcançado pela construção da hierarquia do sistema, tanto em nível de área como em nível local, que seria o nível de interseção supracitado. Assim, foram definidos tanto um controle robusto de resposta para as interseções quanto regras consistentes para a interação entre elas e para garantir a estabilidade no nível da rede, também foram determinadas interações nesse nível superior.

De acordo com esses autores, o controle de área gera um plano de referência e, o controle local adapta o plano de referência e coordena dinamicamente os semáforos em interseções adjacentes. Neste sistema, a abordagem do Horizonte de Rolamento é usada para otimizar o desempenho pelo controlador local, com horizonte de planejamento de 120 segundos e o processo sendo repetido a cada 3 segundos.

Para automatizar o processo de atualização dos planos de referência que são gerados pelo TRANSYT, foi desenvolvido o módulo de atualização automática – AUT (*Automatic Updating of TRANSYT*). Primeiro, o AUT coleta dados de tráfego continuamente por meio de alguns detectores na rede viária. Esses dados são processados para calcular os cenários de fluxo de tráfego para as diversas partes do dia. O modelo prevê os perfis de fluxo de tráfego para serem usados no cálculo de um novo plano de referência. Depois, o AUT prepara os dados para serem usados nos cálculos do TRANSYT e inicia a otimização do TRANSYT para os efeitos selecionados.

Os benefícios registrados depois da implementação do UTOPIA mostra um crescimento de 15% na velocidade média dos veículos particulares e 28% para o transporte público com prioridade (CAI *et al.*, 2009).

2.4.7.8 ALLONS-D

O sistema descentralizado de otimização limitada adaptativa de semáforos em rede – ALLONS-D (*Adaptive Limited Look-Ahead Optimization of Network Signals –Decentralized*) é um método baseado no algoritmo *branch-and-bound* com busca em profundidade (DFS – *depth-first search*) dirigido heurísticamente com um horizonte de planejamento de duração variável (PORCHE e LAFORTUNE, 1999; SHELBY, 2004; ZHANG *et al.*, 2007; ALAM e PANDEY, 2017).

De acordo com Zhang *et al.* (2007), a árvore de decisão utilizada no ALLONS-D é similar àquela utilizada no DYPIC em que cada nó representa um ponto de decisão e tem um valor de custo associado a ele, enquanto cada arco é uma ação de controle. O processo inteiro de otimização do ALLONS-D pode ser dividido em duas partes, sendo uma de construção do caminho sequencial de decisão inicial e a outra de retrocesso e exploração. A construção do caminho de decisão é baseada na técnica de heurística do maior custo que servir – STLC (*serve the largest cost*).

Ações de controle na DFS são ordenados usando a heurística STLC. Essa política postula que a fase que mais recentemente incorreu no maior custo ou no maior atraso deve obter a luz verde. Assim, o procedimento de busca avalia primeiro a decisão de mudar conforme uma fase tenha incorrido em um custo maior ou de outra forma avalia a decisão de extensão. Dirigindo a pesquisa com esta heurística é pretendida a obtenção de melhores soluções (um limite superior melhor) antecipadamente no processo de pesquisa, o que resulta na supressão de uma porção maior da árvore de busca e, por isso, em uma busca mais rápida. ALLONS-D não usa o horizonte de planejamento típico de duração fixa e, ao invés disso, continua a avaliação da árvore de busca até todo o tráfego conhecido (ou seja, todas as filas e chegadas previstas) tenha deixado a interseção (SHELBY, 2004, ZHANG *et al.*, 2007).

De acordo com Zhang *et al.* (2007), o caminho de decisão inicial não é ótimo na maioria das vezes e, por isso, é necessário um processo de retrocesso e exploração para melhorar

ainda mais o caminho de decisão inicial. O processo de retrocesso é semelhante ao método recursivo para trás usado para resolver o problema de programação dinâmica, mas o processo de exploração se distingue desse mesmo método. O retrocesso e exploração é um processo recursivo que começa a partir do nó final do caminho de decisão inicial. O valor de custo correspondente para o nó final é zero, e todas as filas são consideradas encerradas neste ponto. Então, o caminho de decisão inicial é definido como o melhor caminho atual de decisão (CBDP).

Assim, o processo retorna um intervalo para cada iteração e calcula o valor de custo do nó atual. Para cada nó, exceto para o nó final, todos os ramos crescendo a partir dele serão avaliados e comparados com o CBDP. Um valor de custo é definido para ambos os arcos e caminhos. Desta forma, o atraso acumulado durante cada intervalo é definido como o custo do arco e o custo do caminho é o somatório dos custos de todos os arcos no caminho. Se algum dos ramos tiver um custo menor do que o ramo no CBDP, então o ramo no CBDP será substituído pelo novo ramo. Caso contrário, a exploração a partir deste nó será encerrada, o processo retorna um intervalo e define o nó pai como o nó atual.

Shelby (2004) afirma que este método pretende superar a miopia das abordagens de horizonte fixo de curto prazo e Zhang *et al.* (2007) destaca que nenhum experimento foi conduzido para demonstrar se este método pode realmente ser aplicado para coordenar controladores de sinais de trânsito.

2.4.7.9 RHODES

Zhao e Tian (2012) descrevem que o Sistema Efetivo Distribuído Otimizado Hierárquico em Tempo Real – RHODES (*real-time hierarchical optimized distributed effective system*), que foi desenvolvido pela Universidade do Arizona em 1990, é um sistema de controle adaptativo de tráfego em tempo real com estrutura hierárquica. O RHODES pode receber dados de diferentes tipos de detectores e, com base nas condições de tráfego previstas, gerar planos de controle semafóricos otimizados.

Três características principais que fazem do RHODES um sistema de controle adaptativo viável e eficaz foram observadas pela equipe que o desenvolveu. Primeiro, novas tecnologias e métodos são bem adotados no RHODES para garantir que o sistema tenha alto

desempenho na transferência, processamento, previsão de dados de tráfego e controle semaforico. Em segundo lugar, o RHODES leva em consideração a natureza estocástica das variações do fluxo de tráfego. Em terceiro lugar, a previsão explícita de chegadas de veículos individuais, chegadas de pelotão e taxas de fluxo de tráfego são totalmente consideradas pelo sistema.

Zhang *et al.* (2007) explicam que o RHODES tem dois módulos principais: previsão e controle. O módulo de previsão faz a previsão de dados de chegada de tráfego futuro, tais como quando e quantos veículos irão chegar. O módulo de controle é usado para controlar fluxos de tráfego de interseção e de rede. A lógica de controle de interseção usa um algoritmo chamado de Otimização Controlada de Fases – COP (*controlled optimization of phases*) – que também é baseado em programação dinâmica. A lógica de controle de rede usada no RHODES é baseada na COP e no REALBAND. O algoritmo REALBAND é utilizado para produzir bandas de progressão em termos de pelotões observados na rede e estas bandas de progressão são então utilizadas como restrições para a COP desenvolver estratégias de controle ótimas para cada interseção.

Embora o algoritmo COP também se baseie na programação dinâmica, ele usa definições para estágios, estados e ações que são bastante diferentes dos métodos DYPIC e OPAC. Na COP, os estágios são definidos como uma sequência de fases; os estados em cada estágio são definidos como o número de intervalos que poderiam ser atribuídos ao estágio atual e a meta de otimização é encontrar um plano ótimo para alocar etapas de tempo para cada estágio (fase) de modo que o atraso total veicular, o número de paradas e os comprimentos de fila possam ser minimizados. Esta abordagem de modelagem é semelhante à aplicação de programação dinâmica a problemas de alocação de recursos (ZHANG *et al.*, 2007).

Neste contexto, cabe destacar também a abordagem de Shelby (2004) para a COP. Segundo ele, o RHODES é considerado uma arquitetura ou estrutura de sistema que consiste de uma coleção de vários algoritmos, incluindo um algoritmo de estimação de fila, algoritmos de previsão de chegada e algoritmo de controle adaptativo de interseção. O COP é um método FDP aproximado que utiliza uma partição do espaço de estados como estágios faseados ao invés da formulação típica de divisão do espaço de estados em estágios ao longo do tempo.

Em cada estágio, a COP identifica estados equivalentes de forma que nenhum cálculo redundante é desperdiçado em suas sub árvores equivalentes. A COP também usa uma relação de equivalência de estados aproximada muito relaxada para alcançar maior eficiência. Dois estados são considerados equivalentes se eles tiverem acabado de mudar para a mesma fase no mesmo intervalo e trocado de fases o mesmo número de vezes desde o estado inicial. As filas associadas aos dois estados diferentes não são levadas em consideração. Como qualquer um dos dois estados equivalentes experimentou o menor custo para chegar no intervalo atual, qualquer um deles é armazenado na fase atual e o outro estado é rejeitado.

Assim como no OPAC, o sucesso do modelo RHODES depende de uma previsão precisa das chegadas de tráfego ao longo de todo o horizonte de decisão (ZHANG *et al.*, 2007).

2.4.7.10 ACS

Zhao e Tian (2012) esclarecem que, em meados da década de 1990, uma coleção de protótipos de sistemas de controle adaptativo (ACS) foi desenvolvida pela FHWA. Depois, o ACS Lite, uma versão reduzida da ACS, foi desenvolvido pela FHWA também, mas em parceria com a Siemens ITS, a Universidade do Arizona e a Universidade de Purdue. O sistema oferece às pequenas e médias comunidades um sistema de controle de tráfego de baixo custo que opera em tempo real, ajusta o tempo do semáforo para acomodar padrões de tráfego em mudança e facilita o congestionamento de tráfego.

O ACS Lite pode ser utilizado com novos semáforos ou para adaptar semáforos existentes. Ele é projetado para fornecer controle ciclo-a-ciclo para sistemas de loop fechado, o que representa 90% dos sistemas de sinal de trânsito nos Estados Unidos. A eficácia de duas configurações de defasagem nas interseções a montante e a jusante é mensurada ou quantificada pelo cálculo do fluxo progressivo ou captado. Esta medida de desempenho é um substituto para paradas e atrasos de veículos, que não podem ser medidos diretamente no campo a partir de detectores pontuais.

Especificamente, o fluxo veicular captado ou progredido é a quantidade de fluxo (em unidades de veículo-segundos de ocupação) que chega à linha de parada num determinado ponto do ciclo multiplicado pela percentagem de tempo em que a fase de progressão é

verde nesse momento durante o ciclo. O algoritmo avalia diferentes defasagens calculando o fluxo capturado em cada aproximação e selecionando a defasagem que maximiza a quantidade total de fluxo capturado.

O ACS Lite tem sido demonstrado em campo nas cidades de Gahanna (Ohio), Houston (Texas), e Bradenton (Flórida). De acordo com Zhao e Tian (2012), o último teste de campo foi planejado para El Cajon, na Califórnia. Todos os locais de teste mostraram melhora no fluxo de tráfego. Os benefícios amplamente aceitos do uso do ACS Lite são os seguintes:

- ✓ baixo custo;
- ✓ compatibilidade com sistemas em loop fechado;
- ✓ operação em tempo real;
- ✓ facilidade de configuração e calibração, não demandando calibração periódica;
- ✓ capacidade comprovada de aliviar o congestionamento de tráfego.

2.4.7.11 TUC

Segundo Prothmann *et al.*, 2009, o sistema de Controle de Tráfego Urbano – TUC (*Traffic-responsive Urban Control*) – é um desenvolvimento mais recente, com foco no controle de semáforo coordenado responsivo pelo tráfego em redes urbanas de grande escala. O TUC tenta estabelecer sistemas semafóricos progressivos – PSSs (*progressive signal system*) adaptando tempos de verde, tempos de ciclo e defasagens e pode considerar prioridades de transporte público.

Um mecanismo de controle de ciclo é usado para ajustar o tempo de ciclo para o nível de saturação máximo enquanto um algoritmo de controle de deslocamento descentralizado coordena as fases principais de nós sucessivos. As decisões de controle destes dois componentes servem como entrada para o controle de fases que visa minimizar as filas de veículos na interseção. Os planos semafóricos resultantes são finalmente adaptados por um módulo de prioridade de transporte público que dá prioridade aos veículos de transporte público através da aplicação de um algoritmo baseado em regras (PROTHMANN *et al.*, 2009).

2.4.7.12 SURTRAC

Smith *et al.* (2013) definem e avaliam a implementação piloto de uma abordagem desenvolvida recentemente para o controle semafórico adaptativo em tempo real, que é chamado Controle de Tráfego Urbano Escalável – SURTRAC (*Scalable Urban Traffic Control*). Esse sistema piloto integra conceitos de teoria de controle de tráfego com trabalhos recentes no campo do planejamento multi-agente e tem diversas características distintas importantes.

Primeiro, para promover escalabilidade e confiabilidade, o SURTRAC opera de maneira totalmente descentralizada:

- a) cada interseção aloca seus tempos de verde independente e assincronamente baseada na chegada nesse instante dos fluxos de veículos;
- b) gerencia redes viárias urbanas com fluxos de tráfego múltiplos (concorrentes), a coordenação do nível de rede é conseguida pela comunicação das saídas de fluxos projetadas para as vizinhanças à jusante, que fornecem a essas interseções uma base de informação maior para equilibrar localmente os ingressos concorrentes enquanto estabelece a promoção simultânea de corredores verdes maiores; e
- c) opera em tempo real porque cada interseção recalcula o seu plano de alocação e retransmite as saídas de fluxo previstas tão frequente quanto uma vez por segundo no modelo de horizonte de rolamento, permitindo tanto a operação efetiva em redes de semáforos justamente espaçados quanto responsividade para mudanças bruscas nas condições de tráfego (SMITH *et al.*, 2013).

Os resultados apresentados pelos autores demonstram que os níveis de melhoria são substanciais em todas as métricas de desempenho calculadas e para todos os períodos do dia em relação aos resultados fornecidos pelo sistema de controle de tráfego pré-existente no local de testes. Com relação à eficiência dos fluxos de tráfego, os tempos médios de viagens diminuíram em mais de 25%, a velocidade média veicular aumentou em 34%, o número de paradas teve uma redução acima de 31% e, o tempo médio de espera foi reduzido em mais de 40%. Quanto à melhoria da qualidade do ar, que foi a motivação para o financiamento do projeto piloto, as emissões globais foram reduzidas em 21%.

2.5 CONTRIBUIÇÃO DA CIÊNCIA DE INTELIGÊNCIA ARTIFICIAL NOS SISTEMAS DE CONTROLE DE TRÁFEGO

De acordo com o OSTP (2016), a inteligência artificial (IA) é uma tecnologia transformadora que promete enormes benefícios para a sociedade pois tem o potencial de revolucionar a maneira como vivemos, trabalhamos, aprendemos, descobrimos e nos comunicamos. A demanda e as possibilidades da IA são tão grandes, que o governo dos EUA vem investindo na pesquisa da IA há muitos anos. Por causa das grandes oportunidades e diversas considerações relativas à pesquisa e ao desenvolvimento de IA no setor público, o governo norte americano criou um subcomitê especialmente para o Aprendizado de Máquina e Inteligência Artificial dentro do seu Conselho Nacional de Ciência e Tecnologia (NSTC, em inglês), visando a ajudar a coordenação da atividade federal em IA, bem como criou um Plano Nacional Estratégico de Pesquisa e Desenvolvimento de Inteligência Artificial para definir as prioridades estratégicas federais para a área de pesquisa e desenvolvimento (P&D) em IA, com atenção especial nas áreas em que a indústria não se interessa.

Cabe destacar que esse plano estratégico americano de P&D em Inteligência Artificial estabeleceu um conjunto de objetivos para a pesquisa da IA financiada pelo governo tanto para as pesquisas que ocorrem no âmbito de sua administração como para a pesquisa financiada pelo governo federal que ocorre fora do governo, como na academia, por exemplo. O objetivo final dessa pesquisa é produzir novos conhecimentos e tecnologias de IA que proporcionem uma gama de benefícios positivos para a sociedade, minimizando os impactos negativos.

Na área de transportes, a IA pode ampliar todos os modos de transporte para impactar materialmente a segurança de todos os tipos de viagens (OSTP, 2016). A IA pode ser usada em veículos de passageiros e de carga para melhorar a segurança, aumentando a consciência situacional, e para fornecer informações sobre as rotas em tempo real para motoristas e outros viajantes. As aplicações de IA podem também melhorar o nível de mobilidade da rede, reduzir o consumo geral de energia do sistema e as emissões relacionadas com os transportes. Além disso, a IA pode ser usada no monitoramento e no gerenciamento da infraestrutura, a fim de proporcionar maior confiança dos usuários e reduzir os custos de reparos e reconstrução. Também, cadeias logísticas e de suprimento mais eficientes estão sendo criadas através de sistemas especialistas de decisão, produtos

podem ser transportados de forma mais eficaz por meio de sistemas automatizados ou robóticos de assistência à condução baseados em imagens (OSTP, 2016).

Neste trabalho, a aplicação de IA é proposta para otimizar os fluxos de tráfego em uma rede urbana e, por isso, a revisão bibliográfica e teórica deste trabalho abordará na sequência os sistemas inteligentes de controle de tráfego, como tais sistemas têm integrado os dados coletados por sensores instalados nas vias e a contribuição da inteligência artificial, especialmente a técnica de Aprendizado por Reforço, na integração desses dados em tempo real. Depois, será apresentada uma descrição da formulação que embasa o Aprendizado por Reforço Profundo a partir dos Aprendizados Profundo e por Reforço.

2.5.1 Sistemas Inteligentes de Controle de Tráfego

Atualmente, os Sistemas Inteligentes de Controle de Tráfego – SICT – ganharam ênfase e notoriedade principalmente por causa da capacidade que possuem para integrar sensores, semáforos e simulações, assim como, o sistema idealizado por Gartner (1975), permitindo um grande avanço no controle de tráfego.

Nesse sentido, Hawi *et al.* (2015) fizeram uma revisão aprofundada de técnicas de inteligência artificial no desenvolvimento de sistemas de controle de tráfego inteligente.

2.5.1.1 Sistemas Inteligentes Fuzzy (SIF)

É uma abordagem adequada para o controle dinâmico de semáforos devido à natureza das incertezas do tráfego cujas distribuições variam de forma não uniforme. Principalmente porque a lógica difusa ou *fuzzy* tenta imitar ou refletir como os seres humanos pensam e modelar o sentido das palavras usadas para descrever certos fenômenos, assim como o senso comum na tomada de decisão. Os sensores coletam dados do ambiente e enviam para o processamento no controlador de lógica *fuzzy*.

O processo de inferência nesse controlador é semelhante à forma como os responsáveis pelo trânsito lidam com o fluxo de tráfego em uma rotatória típica. O seu objetivo é controlar as operações em sistemas, tomando decisões que utilizam regras expressas de acordo com a incerteza em termos humanos, como baixo (um pouco baixo) ou alto (um pouco alto).

De acordo com Hawi *et al.* (2015), os controladores de lógica *fuzzy* são uma abordagem adequada para o controle do semáforo porque atribuem um sinal de luz verde ou vermelho baseado na urgência ou na maneira como o tráfego flutua e seleciona a melhor decisão que minimizará o congestionamento em um intervalo particular. Por essa abordagem, uma pista poderia, além de não ter tráfego algum (0) ou tráfego alto (1), ter também tráfegos baixo ou médio.

2.5.1.2 Rede Neurais Artificiais (RNA)

A principal diferença entre RNA e SIF é que, enquanto um SIF usa o conhecimento atual para tomar decisões, uma RNA, como um sistema capaz de aprender, considera experiências acumuladas ou o conhecimento de exemplos bem-sucedidos para tomar decisões. Para tentar imitar o cérebro humano, as RNA possuem um recurso adaptativo que permite a cada nó dentro de uma rede modificar o seu estado em resposta ao conhecimento passado e presente. Assim, a entrada de dados em um sistema RNA para controlar o tráfego consiste em uma lista de dados coletados pelos sensores que são colocados ao redor dos semáforos.

Então, o modelo processa essa entrada e seleciona a saída mais adequada para a situação de tráfego atual. Assim, esses resultados são utilizados pelos semáforos para definir o tempo para os sinais verdes e vermelhos. Patel *et al.* (*apud* HAWI *et al.*, 2015), avaliaram que para uma RNA gere decisões precisas são necessários 83 nós neurais, sendo que o sistema desses autores produziu um nível de precisão de 73% para as soluções resultantes.

2.5.1.3 Redes de Sensores Sem Fio (RSSF)

As RSSF não são utilizadas apenas para recolher dados de trânsito, mas para controlar ativamente o tráfego rodoviário também, incorporando funcionalidades adicionais ao controlador da rede, tal como um algoritmo que é incorporado para controlar os semáforos, gerando decisões sobre as rotas com base em dados de sensores agregados. Ao contrário de alguns sistemas de inteligência artificial (IA), a RSSF não exige que os veículos tenham sistemas adicionais como etiquetas de identificação por rádio frequência para controlar e gerenciar o tráfego.

Por isso, as RSSF têm um custo baixo e são mais práticas do que as abordagens RNA e SIF, especialmente em economias emergentes. Desta forma, Yousef *et al.* (apud HAWI *et al.*, 2015) apresentam um sistema de controle adaptativo de semáforos para interseções simples e múltiplas usando RSSF para rotear o trânsito com base na densidade de tráfego e nos tempos de espera. Esse sistema é composto por:

- a) sensores que detectam a presença de veículos e têm memórias que armazenam seus tempos de espera em cada via;
- b) um controlador de tráfego inteligente que processa os dados dos sensores e, em seguida, emprega dois algoritmos, sendo um de comunicação do sistema de tráfego (ACST) e outro de manipulação do tempo dos sinais de um semáforo (AMTST) para rotear o tráfego com base nas variações de trânsito em todas as faixas das interseções em um momento particular e;
- c) um algoritmo de controle de tráfego em interseções múltiplas (ACTIM).

2.5.1.4 *Sistemas Híbridos (neuro-fuzzy)*

Para superar as limitações de implementações individuais de abordagens RNA e SIF, tais como: falta de capacidade de aprendizagem de sistemas difusos e ausência de processo de inferência de RNA, Patel *et al.* (apud HAWI *et al.*, 2015) desenvolveram um sistema inteligente híbrido de tomada de decisão (SIHTD) para aplicações de controle de tráfego urbano. Sensores foram instalados nas vias para recolherem dados de tráfego: volume (quantidade de tráfego) e ocupação (tempo de espera) de cada pista.

Entretanto, o SIHTD calcula somente suas decisões com base em um parâmetro, a quantidade de tráfego. Os dados de volume são usados para calcular cinco parâmetros de trânsito que descrevem em maior detalhe o fluxo de tráfego das pistas de uma interseção: (1) saturação mais alta, (2) a saturação cruzada, (3) a diferença de saturação do tráfego, (4) a diferença de volume e (5) a extensão de tempo verde necessária.

Basicamente, quatro parâmetros do cenário anterior (exceto a diferença de saturação), que são armazenados em um dispositivo de memória, e os cinco parâmetros do cenário atual tornam-se entradas para a RNA, que alimenta o SIHTD com valores nítidos (não difusos). Então, a RNA processa todos os dados do sistema, passados (coletados e armazenados em ciclos anteriores) e presentes.

A saída da RNA fornece a entrada para o SIF, que realiza a inferência e atribui um rótulo ou valor *fuzzy* à entrada recebida. Em seguida, o SIF dispara as regras com base nesses valores difusos para decidir. Depois, a unidade de defuzificação converte as decisões computadas em valores nítidos que são usados para sincronizar os sinais verdes de cada semáforo. O ciclo continua repetindo-se e tenta mudar a condição de sincronização do semáforo para garantir que o SIHTD se autoajuste de acordo com a situação.

O SIHTD integra as habilidades de aprendizagem de uma RNA e a capacidade de tomada de decisão baseada no conhecimento de um SIF, em um ambiente dinâmico. Um resumo das simulações para o SIHTD, a RNA e o SIF indicam que o sistema SIHTD forneceu uma taxa de decisão correta de 95% e um tempo médio de espera de 2,186 minutos, aliviando o congestionamento da interseção melhor do que a abordagem com a RNA, que, por sua vez, forneceu uma taxa de 73% de decisão correta e um tempo de espera médio de 2,958 minutos. A taxa de decisão correta do SIF foi igual à do SIHTD, mas a decisão calculada não conduziu a uma redução melhor nos tempos de espera. O SIF teve um tempo de espera médio de 2,975 minutos que é mais baixo do que os das outras duas abordagens.

2.5.2 Sensoriamento e Inteligência Artificial

Muitos trabalhos utilizam abordagens de inteligência artificial associadas às várias tecnologias de sensoriamento para decidir as ações mais adequadas a partir de comportamentos monitorados e apreendidos. As quantidades de dados gerados por sensoriamento são imensas e variadas, sendo ideal o emprego de técnicas de inteligência artificial para a adequada busca, organização, interpretação e aprendizado das informações, bem como para a adoção da melhor decisão.

Yuan *et al.* (2016) preocupados com a importância de garantir a segurança dos pedestres em grandes eventos, compararam o desempenho de três algoritmos para estimar em tempo real o estado dos pedestres durante o maior evento mundial aberto de náutica (SAIL2015) que acontece a cada 5 anos em Amsterdam. Assim, destacam que isso pode ser feito mediante o desenvolvimento de sistemas de suporte de monitoramento e gerenciamento apoiado pelos avanços tecnológicos, tais como: câmeras de contagem, sensores WiFi, rastreadores GPS e veículo aéreo não tripulado (VANT).

O monitoramento do comportamento dos pedestres e a previsão dos cenários decorrentes podem ser realizados em tempo real mediante a identificação dos estados do tráfego: contagens, fluxos, densidades, velocidades, tempos de viagens e rotas escolhidas, visando principalmente identificar situações potencialmente perigosas em tempo útil. De acordo com os autores, com as informações do monitoramento em tempo real dos pedestres, os interessados podem agir para melhorar o fluxo deles e aliviar ou prevenir a ocorrência de gargalhos.

Os autores usaram dados produzidos pelo painel de monitoramento do evento, aproveitando as três principais funções descritas do sistema: coleta de dados em tempo real, funções de engenharia de tráfego e visualização. As tecnologias empregadas foram: câmeras de contagem, sensores WiFi, rastreadores de GPS, mídias sociais e câmeras suspensas por balão. A partir da combinação e extrapolação desses dados, os autores compararam três algoritmos de estimativa de cenários: tempo de viagem (velocidade), densidade e fluxo para concluir que as câmeras de contagem foram capazes de realizar a contagem local e não foram capazes de gerar as informações de velocidade nem de rota, provavelmente devido às limitações do algoritmo.

Além disso, eles concluíram também que o conjunto de dados gerados pelos sensores WiFi foram suficientes para produzir informações sobre as rotas e velocidades em certos locais, enquanto a densidade e o fluxo foram obtidos pela combinação dos dados produzidos pelas câmeras de contagem e pelos sensores WiFi. As informações dos rastreadores GPS, embora promissoras para a estimativa do tempo de viagem, não eram contínuas e formaram um conjunto menor do que aquele produzido pelos sensores WiFi.

O trabalho de Yuan *et al.* (2016) adere perfeitamente ao caso do trânsito de veículos pois os mesmos dispositivos de sensoriamento e monitoramento podem ser empregados no gerenciamento do tráfego urbano, principalmente por meio do uso de técnicas de inteligência artificial. Neste mister, existem muitos trabalhos que se dedicam às mais variadas formas de aproveitamento da inteligência artificial.

2.5.3 Aprendizado por Reforço

Sistemas de controle de tráfego adaptativo usam dados de trânsito em tempo real a fim de minimizar os congestionamentos mediante a otimização do sincronismo e extensão dos

sinais em semáforos. Enquanto a eficiência das soluções implementadas depende da avaliação precisa do tráfego, previsões de tráfego confiáveis baseadas em dados em tempo real podem fortalecer consideravelmente esses sistemas. Assim, se um estudo recente afirma que os motoristas dirigindo em busca de uma área de estacionamento em São Francisco gera 30% de todo o congestionamento da cidade, então, a previsão de vagas disponíveis pode ajudar também as autoridades de gerenciamento do tráfego urbano a reduzir os congestionamentos, pois essa informação permitiria aos motoristas deduzir um plano de viagem otimizado.

Neste sentido, Ziat *et al.* (2016), baseados em um trabalho recente sobre previsão de séries temporais relacionais, adotaram a abordagem de *machine learning* em que o modelo aprende sobre um conjunto de dados históricos e, em seguida, pode prever o futuro. Mais precisamente, eles confiaram em um recente paradigma do aprendizado da representação que é fundamentado nos conceitos de *deep learning*.

Esse paradigma consiste na construção de espaços latentes contínuos de alta dimensão capazes de capturar correlações estatísticas fortes nos dados disponíveis. No caso desse trabalho, foram os dados de tráfego e ocupação de estacionamento projetados no mesmo espaço unificado.

Basicamente, o trabalho de Ziat *et al.* (2016) reforça o fato de que a variação da demanda é importante para a previsão do tráfego, o que também é reforçado pelo trabalho de Stefanello e Bazzan (2016). Empregando o aprendizado por reforço multiagente (MARL), esses autores pesquisaram o quanto as propriedades topológicas de uma rede de tráfego podem induzir o comportamento dos usuários e, conseqüentemente, a escolha de uma rota alternativa, visando garantir robustez do aprendizado no contexto da inteligência artificial.

Um problema típico do aprendizado por reforço multiagente é o efeito que a decisão de um agente tem sobre o comportamento de outros agentes. Portanto, para Stefanello e Bazzan (2016), é importante definir novas estatísticas e métricas que representem a complexidade ou o grau de dificuldade apresentado por uma rede para o problema de alocação do tráfego (TAP) de acordo com a demanda. Pois, uma vez definidas, essas ferramentas servem como um meio de estimar o quão fortemente um agente em uma via poderia ser afetado por outros agentes que podem mudar os seus comportamentos.

Neste contexto, a topologia dos grafos que representam a rede de tráfego tem uma grande influência sobre o TAP na rede, assim como outras características que descrevem como a demanda é distribuída e como são definidas as funções de latência (custo). Então, Stefanello e Bazan (2016) propõem uma métrica baseada nas propriedades topológicas da rede de tráfego para medir o quanto as rotas são acopladas, ou seja, quantos pontos de interação uma rota tem com outras rotas e quanto semelhantes elas são, de modo que o agente possa desviar a rota.

Essa métrica é um meio de estimar o efeito da influência de um agente sobre os demais e essa medida é importante desde que dependências fortes produzem aprendizados mais consistentes no cenário do MARL. Eles aplicam o método em várias redes de tráfego com diferentes topologias e demandas, considerando tanto redes reais como hipotéticas, a fim de analisar e estender o paradoxo de Braess em tamanhos arbitrários de redes, considerando que esse paradoxo estabelece que a adição de arcos a uma rede para criar mais rotas pode terminar causando mais congestionamentos.

Segundo Ortúzar e Willumsen (2011), a escolha de rotas é um estágio importante no planejamento e na modelagem clássicas dos transportes. Por isso, o aprendizado por reforço multiagente tem sido associado à escolha de rotas e, conseqüentemente, à variação de demanda nas pesquisas de emprego da inteligência artificial na previsão e no controle do trânsito.

Afinal, os métodos de escolha selecionam as rotas e as aloca para os usuários, visando conectar suas origens individuais aos respectivos destinos, pois o problema de escolha da rota se deve a forma como os motoristas se comportam racionalmente quando precisam escolher a rota entre uma origem e um destino para minimizar o custo de suas viagens (RAMOS e BAZZAN, 2016). Portanto, os resultados desse processo de escolha descrevem o estado do sistema de transportes que é uma variável relevante para testar as conseqüências das mudanças na infraestrutura física da rede.

Os Sistemas de Transportes Inteligentes (ITS) ajudam aos usuários a decidir suas rotas mediante informações de tráfego adquiridas por laços de indução (detecção e classificação de veículos por circuito elétrico), detecção de veículos por câmeras, dispositivos GPS, dentre outros. Entretanto, tais sistemas não têm controle sobre o total de fluxo que será

redirecionado para as rotas sugeridas porque, no mundo real, os motoristas têm suas próprias opiniões sobre quais rotas devem ser seguidas. E, neste contexto, Grunitzki e Bazzan (2016) combinam o aprendizado por reforço multiagente e a comunicação de dados entre os veículos e a infraestrutura para modelar o comportamento do motorista moderno que utiliza as informações fornecidas pelos ITS para planejar suas rotas.

A previsão de rotas é de grande importância para um modelo de controle de tráfego, cujo objetivo é decidir em tempo real a duração ou extensão de um sinal, visando evitar engarrafamentos, principalmente porque o sistema alimentado por esse modelo poderia antecipar os gargalhos do trânsito (Ramos e Bazzan, 2016).

2.6 PREVISÃO DE FLUXOS DE TRÁFEGO

De acordo com Yisheng *et al.* (2015), a previsão de fluxos de tráfego depende fortemente do histórico e dos dados de tráfego coletados em tempo real por meio de vários recursos, tais como: laços indutivos, radares, câmeras, Sistema de Posicionamento Global móvel, recursos de massa, mídias sociais etc. Com a generalização dos sensores de tráfego tradicionais e as novas tecnologias de sensores de tráfego emergentes, os dados de tráfego estão se expandindo demais numa era de *big data* de transportes (Chen e Zhang, 2014).

Yisheng *et al.* (2015) fazem uma boa revisão bibliográfica sobre este assunto apontando diversas pesquisas devidamente contextualizadas conforme as técnicas de abordagens utilizadas, traduzindo-se numa excelente fonte de pesquisa para aqueles mais interessados. Nesse sentido e a fim de evitar uma repetição desnecessária de conteúdo, sugere-se acrescentar à referida revisão os trabalhos abaixo, além da própria pesquisa de Yisheng *et al.* (2015).

Devido à dependência de fenômenos espaciais e temporais no fluxo de tráfego e à aleatoriedade dessas variáveis no ambiente urbano, Vlahogianni *et al.* (2005) utilizaram dados de diversos sensores de laços indutivos de interseções urbanas semaforizadas para formular uma abordagem de otimização que desse os meios para assegurar que a rede neural desenvolvida tivesse a estrutura adequada e, conseqüentemente, o melhor comportamento com respeito ao conjunto de dados de fluxo de tráfego requerido pelo modelo.

Assim, eles propuseram uma estrutura de otimização genética para modelar o comportamento dinâmico do fluxo de tráfego por meio de uma rede neural alimentada para frente,

do tipo *feedforward*, e treinada por retro propagação de erro, cujos resultados na época indicaram maior habilidade dessa rede otimizada geneticamente para modelar fluxos altos em relação às outras abordagens disponíveis como o modelo auto-regressivo integrado de médias móveis – ARIMA, o que foi considerado promissor especialmente para a previsão de fluxos em vias urbanas sinalizadas e altamente congestionadas.

Sun *et al.* (2006) propuseram na época uma nova abordagem baseada em uma rede bayesiana, apoiada num modelo de mistura Gaussiana, para prever o fluxo de tráfego. Estes pesquisadores apontaram a falta de capacidade efetiva de sistemas como o SCOOT e o SCAT para realizar previsões de fluxo adequadas. De acordo com a pesquisa, essa nova abordagem era muito promissora e efetiva em relação aos vários métodos de modelagem (ARIMA, KARIMA, ATHENA e Neuro-*fuzzy*) e previsão de fluxo de tráfego urbano existentes tanto a partir de um conjunto de dados completo quanto incompleto.

Como uma opção mais avançada em relação aos métodos *offline* de previsão de fluxo da época, Jeong *et al.* (2013) apresentaram um novo modelo de previsão supervisionado chamado Aprendizado Online Ponderado pela Regressão do Vetor de Suporte (sigla em inglês, OLWSVR). Nesta pesquisa, os autores esclarecem que o modelo é bastante afetado pela imprecisão de dados coletados recentemente ou pela perda desses dados, principalmente na previsão mais próxima, mas que essa fragilidade é rapidamente recuperada com a coleta de dados atualizados e mais precisos. No caso dos dados perdidos, a fim de evitar discontinuidades, o modelo pode interromper a previsão e manter as leituras mais recentes como o seu estado atual, passando a processar os dados antigos com os dados novos na medida em que a coleta deles recomeça.

Yisheng *et al.* (2015) propuseram o primeiro método de previsão de fluxos de tráfego baseado em aprendizado profundo no qual foi usado um modelo de autoencodificadores empilhados para aprender características de fluxo de um tráfego genérico. Segundo esses pesquisadores, a arquitetura profunda é mais robusta e aprende melhor do que as redes rasas que possuem apenas uma camada intermediária. Esse modelo considera intrinsecamente as correlações espaciais e temporais, permite treinar a rede facilmente mediante um algoritmo de aprendizado não supervisionado ávido por camadas e, assim, obtém um desempenho superior em relação aos outros métodos que utilizam redes neurais artificiais de retro propagação, busca aleatória, máquina de vetor de suporte e função de base radial.

Polson e Sokolov (2016) desenvolveram um modelo de aprendizado profundo para prever o fluxo de tráfego e, segundo esses autores, a principal contribuição do trabalho foi o desenvolvimento de uma arquitetura que combinou um modelo linear que é ajustado usando uma regularização e uma pilha de camadas de tangente hiperbólica. Considerando que o maior desafio da predição de fluxos é a não linearidade acentuada devido à transição entre o fluxo livre, congestionamento, recuperação e congestionamento, estes pesquisadores destacam que as arquiteturas de *deep learning* podem perceber e representar esses efeitos espaço-temporais não lineares.

Muitos métodos estatísticos e de redes neurais têm sido empregados em pesquisas que almejam a previsão de fluxos de tráfego, mas, considerando os resultados das diversas pesquisas divulgadas, é possível concluir que as redes neurais são frequentemente consideradas mais flexíveis em comparação com os modelos estatísticos sempre que elas modelam conjunto de dados complexos com possibilidades de não linearidade ou dados perdidos. A forma sem restrições das redes neurais é frequentemente preferida ao invés do poder explicativo da estatística (Karlaftis e Vlahogianni, 2011). Por isso, os trabalhos de Yisheng *et al.* (2015) e Polson e Sokolov (2016) convergem para destacar o *deep learning* como um método excelente para perceber e representar a não linearidade acentuada dos dados provocada pelas correlações espaciais e temporais do tráfego, principalmente.

2.7 SINCRONIZAÇÃO DE TEMPOS SEMAFÓRICOS

A capacidade de exercer o controle adaptativo de processos de transporte em tempo real é o cerne de muitas ferramentas de suporte à decisão em sistemas de transporte inteligentes (ABDULHAI *et al.*, 2003) e sincronizar os tempos semafóricos é uma das maneiras mais rápidas e econômicas de reduzir o congestionamento no cruzamento e otimizar o fluxo do tráfego nas vias urbanas. Nesse sentido, um plano capaz de se adaptar às flutuações da demanda é imprescindível e muitos parâmetros de sincronização semafórica afetam o desempenho das interseções (Qadri *et al.*, 2020). Então, vários estudos têm sido conduzidos para melhorar a inteligência dos sistemas de controle de tráfego a partir das interseções.

Entretanto, problemas complicados de otimização de semáforos não podem ser resolvidos usando métodos convencionais e, por isso, a sincronização semafórica tem empregado

atualmente técnicas de Inteligência Artificial (IA) (Joo *et al.*, 2020). Muitos pesquisadores que trabalharam no desenvolvimento dessa área, conforme descrito extensamente neste trabalho, propuseram vários modelos de otimização de planos semafóricos ou sincronização de tempos semafóricos baseados, por exemplo, em lógica *fuzzy*, algoritmos genéticos, programação dinâmica e redes neurais numa evolução gradativa e bem-sucedida de métodos baseados em técnicas de inteligência artificial até o *Deep Reinforcement learning* (*Deep Q-learning*).

A lógica *fuzzy* tem sido usada para otimizar os tempos semafóricos. Trata-se de um método adaptativo em comparação aos controladores de tempo fixo em que o ambiente dinâmico é analisado e modelos predefinidos são adaptados às demandas desse ambiente, continuamente. Dessa forma, o sistema requer muito poder de processamento para executar todas as tarefas necessárias e, eventualmente, isso degrada o seu desempenho em alguma medida.

Consequentemente, os pesquisadores passaram a experimentar outras técnicas como a de aprendizado por reforço e, depois, de aprendizado por reforço profundo baseadas respectivamente em algoritmos *Q-learning* e *Deep Q-learning* para executar o gerenciamento do fluxo de tráfego (Joo *et al.*, 2020). Ao contrário da lógica *fuzzy*, o *Q-learning* não utiliza modelos predefinidos, tornando-se por isso mais adequado para problemas de gerenciamento de tráfego em tempo real em relação à lógica *fuzzy* (Joo *et al.*, 2020).

O aprendizado por reforço oferece vantagens importantes a este respeito tanto em termos de melhoria da eficácia quanto da eficiência, principalmente porque a capacidade de um agente de controle aprender por meio da interação dinâmica (ao mesmo tempo em que persegue um objetivo) com o ambiente é vista como um benefício significativo em relação às metodologias de controle que dependem de modelos pré-especificados desses processos.

Os modelos pré-especificados são um pré-requisito dos métodos de controle convencionais e sua precisão limita o desempenho dos agentes de controle. Então, Abdulhai *et al.* (2003) introduziram o *Q-learning* como um simples, mas poderoso, algoritmo de aprendizado por reforço. No referido trabalho, os autores esboçam um esforço de pesquisa mais amplo, incluindo sistemas semafóricos lineares e em rede e a integração com um guia dinâmico de rotas. O objetivo da pesquisa envolve o controle ótimo do tráfego, fortemente

congestionado, por meio de uma rede rodoviária bidimensional, que seria uma tarefa desafiadora para as metodologias convencionais de controle de semáforos.

Os resultados preliminares da aplicação do *Q-learning* a um sinal de trânsito isolado, de duas fases, foram encorajadores. O agente *Q-learning* foi executado em paralelo com sinais pré-estimados em condições de tráfego susceptíveis de controle pré-temporizado, envolvendo taxas constantes ou taxas de fluxo de proporção constante. De acordo com Abdulhai *et al.* (2003), sob condições de tráfego mais variáveis, o agente *Q-learning* demonstrou uma superioridade destacada devido à sua capacidade de se adaptar às mudanças das circunstâncias.

Por sua vez, Bazzan (2005) descreve “uma abordagem onde cada semáforo é modelado como um agente. Cada um possui planos pré-definidos para sincronização/coordenação com agentes adjacentes. Planos diferentes podem ser escolhidos para haver coordenação em diferentes direções de acordo com a hora do dia. Essa abordagem utiliza técnicas de teoria dos jogos evolucionária, tendo como principais benefícios:

- a) os agentes podem criar subgrupos de sincronização para melhor atender as necessidades do fluxo em alguma direção;
- b) não há necessidade de um controle central e;
- c) não há comunicação nem negociação direta entre os agentes.

Depois, Oliveira e Bazzan (2006) propuseram uma abordagem de simulação *bottom-up* em que cada semáforo seria um agente capaz de alterar o seu comportamento para atender às necessidades de trânsito em outros cruzamentos a partir dos estímulos fornecidos por eles e considerando também o fluxo nas vias secundárias, além das arteriais, para selecionar o plano de sinal apropriado.

Neste sentido, Oliveira e Bazzan (2007) introduzem uma abordagem baseada em *swarm intelligence*, propondo uma analogia entre a capacidade dos insetos sociais de alocarem dinamicamente as tarefas entre os membros da colônia e a capacidade de os semáforos executarem os planos semaforicos como se eles fossem os insetos e os planos semaforicos as tarefas. Para esses autores, tal abordagem se ajusta bem ao caso porque os veículos deixam um rastro de feromônios quando param em um cruzamento, assemelhando-se ao mecanismo de comunicação indireta utilizada pelos insetos sociais (*stigmergia*).

Entretanto, mais recentemente, Rosyadi *et al.* (2016), preocupados com a persistência dos congestionamentos nas metrópoles mundiais e com os problemas que induzem, especialmente nas cidades com grandes densidades populacionais e quantidades de vias, desenvolveram uma simulação para o controle de semáforos inteligentes baseada em métodos de algoritmos *Q-Learning* colaborativos. Segundo os autores, o propósito da pesquisa foi otimizar a sincronização dos semáforos e os resultados demonstram taxas de aprendizagem e recompensas elevadas em relação aos demais métodos de algoritmos controladores de semáforos (TLC), sendo, portanto, uma referência para a solução de congestionamentos no mundo real.

A abordagem de aprendizagem por reforço modela implicitamente a dinâmica de sistemas complexos, aprendendo as ações de controle e as mudanças resultantes do fluxo de tráfego. Enquanto isso, ele busca o plano semaforico ótimo para os pares de entrada e saída aprendidos (Li *et al.*, 2016). Alguns trabalhos utilizaram o *Q-learning* para realizar a otimização do tempo semaforico e, conseqüentemente, a redução do congestionamento por meio da minimização de parâmetros de controle do tráfego, tais como: o atraso de parada, o comprimento da fila e tempo de espera por veículo. Contudo, embora se adaptem à demanda em tempo real, esses modelos não podem alterar a sequência de sinais entre semáforos distintos (Joo *et al.*, 2020).

Por isso, um modelo de *Q-learning* posterior, combinando a técnica de clusterização com os parâmetros tempo de espera e comprimento de fila, conseguiu variar a ordem dos semáforos de acordo com o fluxo de tráfego. Esse trabalho mais recente de (Joo *et al.*, 2020) buscou uma solução adaptativa para um sistema de tráfego dinâmico e complexo, visando a propor uma solução para o controle semaforico diante do surgimento de cidades inteligentes e o desenvolvimento da Internet das Coisas mediante o emprego de um algoritmo *Q-learning* e a maximização do número de veículos. Apesar da proposta de uma estrutura flexível, facilmente aplicável em várias interseções de n vias de acordo com os autores, a referida proposta foi aplicada em apenas uma interseção.

Contudo, é preciso considerar o tamanho da rede de tráfego e que o aprendizado por reforço tem uma dificuldade importante na otimização dos tempos semaforicos na medida em que a complexidade de um plano semaforico cresce exponencialmente com o número de estados dos fluxos de tráfego considerados e das ações de controle (Li *et al.*, 2016).

Por isso, um novo método foi proposto para resolver simultaneamente os problemas de modelagem e otimização de sistemas complexos, combinando duas ferramentas importantes: aprendizado por reforço e aprendizado profundo, o que resultou no *Deep Q-learning*, que adere melhor às condições do problema na medida em que o aprendizado profundo complementa o aprendizado por reforço usando várias camadas de redes neurais artificiais para aprender a recompensa futura descontada máxima implícita quando uma ação especial em um determinado estado especial é executada (Li *et al.*, 2016)(Mousavi *et al.*, 2017)(Rasheed *et al.*, 2020).

Nesse contexto, entendendo que os métodos convencionais de *Q-Learning* dificilmente conseguem capturar de forma adequada a dinâmica do fluxo de tráfego, bem como resolver, em um tempo finito, os problemas de sincronização de semáforos, devido ao enorme intervalo de possibilidades associado, Li *et al.* (2016) propuseram uma metodologia baseada em aprendizado por reforço profundo ou *Deep Q-learning* aplicado a uma interseção semaforizada hipotética e composta por 2 faixas de rolamento em cada direção, onde não eram permitidas conversões à direita ou à esquerda.

Estes pesquisadores treinaram a rede a partir de fluxos de tráfego simulados aleatoriamente desde o mínimo de 100 veículos por hora até o máximo de 2.000 veículos por hora. Assim, eles mediram os comprimentos das filas de 5 segundos formadas nas 8 faixas conectadas pela interseção e utilizaram uma função de recompensa que minimizasse a diferença de comprimento total entre as filas formadas nas duas direções da interseção. Mediante essa nova abordagem, os autores relatam que encontraram planos de sinais mais adequados do que aqueles simulados pelos métodos convencionais de *Q-Learning*.

O *Deep Q-learning* aprende a função Q por meio de uma rede neural profunda (DNN). Em seguida, o agente baseado em função de valor seleciona a ação de controle otimizada, tornando-o capaz de lidar com entradas de alta dimensão para vários estados além do *Q-learning* (Joo *et al.*, 2020). Então, ele aprende simultaneamente a dinâmica do sistema de tráfego e o plano de controle ideal, modelando implicitamente as ações de controle e a mudança dos estados do sistema. Desta forma, ele supera as abordagens convencionais na otimização dos tempos semaforicos (Li *et al.*, 2016)(Rasheed *et al.*, 2020).

Alguns trabalhos demonstram a viabilidade e a eficácia do aprendizado por reforço profundo na sincronização de planos semáforos. Testes numéricos mostram que redes profundas são o meio mais conveniente e poderoso para aproximar a recompensa futura descontada máxima (Li *et al.*, 2016). Mais uma vez, combinações entre parâmetros de controle de tráfego, tais como comprimentos de filas e atrasos acumulativos totais em uma interseção foram usados como variáveis de recompensa (Joo *et al.*, 2020)(Li *et al.*, 2016)(Mousavi *et al.*, 2017).

Existe uma bibliografia extensa que desenvolve as abordagens do aprendizado por reforço profundo aplicadas ao controle semaforico, descrevendo suas arquiteturas e os respectivos atributos: métodos, recompensas, ações e estados, de acordo com os principais modelos que já foram aplicados, tais como as revisões bibliográficas feitas por Tan *et al.* (2017), Y. Gong *et al.* (2019) e Rasheed *et al.* (2020). Considera-se que seu estudo é de extrema importância para o leitor interessado em aprofundar o conhecimento sobre esse tema. Entretanto, na sequência deste trabalho, é apresentada uma revisão resumida para descrever o *Deep Reinforcement Learning*.

2.8 APRENDIZADO POR REFORÇO PROFUNDO

Uma combinação muito bem-sucedida entre o Aprendizado Profundo (*Deep Learning* – DL) e a abordagem tradicional de Aprendizado por Reforço (*Reinforcement Learning* – RL) criou o Aprendizado por Reforço Profundo (*Deep Reinforcement Learning* – DRL) como uma técnica avançada de inteligência artificial, que é recente e se desenvolveu rapidamente. De acordo Y. Gong *et al.* (2019) e Rasheed *et al.* (2020), essa abordagem supera as deficiências do RL e tem mostrado resultados promissores na solução de problemas complexos sujeitos aos dados desagregados de alta dimensão, assim como o problema do congestionamento de tráfego.

Nesse contexto, o Aprendizado por Reforço Profundo é uma família de algoritmos de Aprendizado por Reforço incorporados com Redes Neurais Profundas (DNNs), que aprende a alcançar uma meta complexa em muitas etapas discretas interagindo com o ambiente (Y. Gong *et al.*, 2019). De acordo com Rasheed *et al.* (2020), o DRL tem três vantagens principais.

- ✓ Permite uma representação contínua do espaço do estado de modo que pode haver um grande número de estados para definir o ambiente.
- ✓ Reduz o tempo de aprendizagem necessário para explorar todos os pares de estados-ações e identificar as ações ótimas.
- ✓ Usa várias camadas de neurônios para armazenar os pesos (ou parâmetros de rede) dos vínculos que conectam os neurônios, que são usados para aproximar os valores Q de forma eficiente a fim de resolver o problema da capacidade de armazenamento em RL (Mnih, V. *et al.*, 2015).

Rasheed *et al.* (2020) explicam que o DRL pode ser uma abordagem baseada em modelos ou livre deles e permite que um agente realize o autoaprendizado em tempo real sem ter conhecimento prévio sobre o ambiente operacional, tais como: a condição do tráfego e a rede. Então, no âmbito dos congestionamentos, embora a condição do tráfego possa evoluir de forma complexa e imprevisível devido a distúrbios inesperados, como, por exemplo, as condições climáticas adversas e os acidentes rodoviários, o DRL permite que um agente se adapte à condição de tráfego em tempo real.

A abordagem baseada em modelos cria um modelo do ambiente operacional, seleciona uma ação e observa a resposta do modelo (Nagabandi, A. *et al.*, 2018). Por outro lado, a abordagem livre não cria um modelo do ambiente operacional e foi escolhida para o controle dos semáforos porque tem menor complexidade e exigência computacional em comparação com a abordagem baseada em modelos. O DRL cria recompensas de acordo com metas e medidas de desempenho do sistema, considerando múltiplos fatores que afetam esse desempenho a partir do ambiente operacional. Por exemplo, a recompensa muda de acordo com o tempo médio de espera, o comprimento de fila ou a passagem dos veículos em um cruzamento.

Além disso, o DRL supera o problema da dimensionalidade que afeta negativamente a aplicação do RL tradicional no controle de semáforos. Afinal, uma rede de tráfego tem um grande espectro de estados possíveis, porque existem muitas variáveis que podem afetar as suas condições, e o DRL pode lidar com todas as dimensões que representam cada um dos estados possíveis. Ainda, o DRL oferece vantagens adicionais em comparação à lógica Fuzzy, aos Algoritmos Genéticos e à Programação Dinâmica aplicadas ao controle de semáforos (Rasheed *et al.*, 2020)

Portanto, considerando a importância do *Deep Reinforcement Learning* e que a sua criação se deu a partir da evolução combinada de outras duas técnicas de Inteligência Artificial, o *Deep Learning* e o *Reinforcement Learning* são abordados brevemente abaixo para subsidiar a compreensão dessa nova técnica de Inteligência Artificial e a sua aplicação neste trabalho.

2.8.1 *Deep Learning*

O Aprendizado Profundo (DL) é uma inteligência artificial avançada que consiste em uma Rede Neural Profunda (DNN), tal como uma Rede de Camadas Totalmente Conectadas (FCLN) (Bengio, Y. *et al.*, 2017). O termo "profundo" indica que a rede neural consiste em um número grande de camadas ocultas, como, por exemplo, até 150 camadas, que podem estar totalmente conectadas umas às outras, muito além de uma rede neural tradicional que é geralmente formada por duas ou três camadas ocultas. Durante o treinamento, os dados fluem a partir da camada de entrada para a camada de saída. A saída y_k de um neurônio k nas camadas ocultas e de saída é a seguinte (Rasheed *et al.*, 2020):

$$y_k = \varphi \left(\sum_{j=0} w_{kj} \cdot x_j \right) \quad (1)$$

onde, w_{kj} representa o peso (ou parâmetro de rede), que é atribuído com base na importância relativa de entrada x_j em comparação com outras entradas, e $\varphi(\cdot)$ representa a função de ativação no neurônio k .

De acordo com a descrição de Rasheed *et al.* (2020), existem vários tipos de arquiteturas DL aplicadas ao controle de semáforos, incluindo a tradicional FCLN, a Rede Neural Convolutiva (CNN), o Codificador Automático Empilhado (SAE), a Rede de Duelo e Memória Longa de Prazo Curto (LSTM).

2.8.2 *Reinforcement Learning*

O Aprendizado por Reforço (RL) é o terceiro paradigma da inteligência artificial, sendo diferente da aprendizagem supervisionada e das abordagens de aprendizagens não-supervisionadas. Ele permite que um agente explore e aproveite diferentes pares de estado-

ação para atingir a melhor recompensa positiva possível (ou custo negativo) para aperfeiçoar o desempenho do sistema conforme o tempo passa $t = 1, 2, 3, \dots$ (Sutton e Barto, 2018; Nachum *et al.*, 2018; Botvinick *et al.*, 2019). O RL é um algoritmo de aprendizado de máquina orientado por metas.

Y. Gong *et al.* (2019) explica que, para um problema de controle, um agente de controle RL, como, por exemplo, um controlador de sinal, observa iterativamente o estado do ambiente, tal como, uma rede rodoviária, em cada etapa de controle discreto e toma uma ação, como alternar a fase do sinal ou ajustar a duração dessa fase de acordo com a sua política de comportamento subjacente π . Então, ele recebe uma resposta que reforça a recompensa r , tal como, o tempo de espera, o atraso ou o tempo de viagem para a ação que foi tomada.

Essa recompensa será acumulada para a sua meta de longo prazo mediante, por exemplo, a minimização do atraso, do tempo de viagem ou das paradas na rede de tráfego. Em seguida, ele passa para o próximo estado de acordo com a dinâmica do ambiente e a probabilidade de transição do estado. Então, o agente RL otimiza a política, que é o mapeamento do conjunto de todos os estados possíveis para o conjunto de todas as ações possíveis, aprendendo com a recompensa de longo prazo descontada mediante um fator de desconto e acumulada pela aplicação de diferentes sequências de ações. Durante esse processo de aprendizado, ele continua ajustando a sua política pela maximização da expectativa de recompensa de longo prazo até convergir para a política ótima.

Toda essa explicação descreve um algoritmo tradicional de RL, que, basicamente, pode ser resumido a partir do instante $t \in T$, em que um agente observa seus fatores decisórios Markovianos (ou os *estados* $s_t \in S$) em um ambiente operacional dinâmico e estocástico, e seleciona e executa uma ação $a_t \in A$ (Nair *et al.*, 2018; Gao *et al.*, 2018; Alshiekh *et al.*, 2018; Jaderberg *et al.*, 2019). Na sequência, o agente observa o próximo estado s_{t+1} e recebe uma recompensa imediata $r_{t+1}(s_{t+1})$ que depende do próximo estado s_{t+1} para o par de estado-ação (s_t, a_t) . Depois, esse agente atualiza o valor $Q_t(s_t, a_t)$ que representa o conhecimento para o par estado-ação (Rasheed *et al.*, 2020).

Y. Gong *et al.* (2019) apontam que o valor do estado é a recompensa descontada de longo prazo esperada por seguir a política π do estado s_t , definida como:

$$v^\pi(s_t) = \mathbb{E}[R_t|s_t] \quad (2)$$

Essa função de valor tem a propriedade da equação de Bellman. Portanto, pode ser aproximada iterativamente assim:

$$v^\pi(s_t) = \sum_{a_t} \pi(a_t|s_t) \sum_{s_{t+1}, r} P(s_{t+1}, r|s_t, a_t) [r + \gamma v^\pi(s_{t+1})] \quad (3)$$

O valor Q, $Q_t(s_t, a_t)$, ou valor da ação refere-se à recompensa descontada de longo prazo esperada ou à conveniência de adotar a ação a_t , sob o estado s_t e depois seguir a política π , definida como: (Y. Gong *et al.*, 2019; Rasheed *et al.*, 2020).

$$Q^\pi(s_t, a_t) = \mathbb{E}[R_t|s_t, a_t] \quad (4)$$

Decompondo-a também pela equação de Bellman, essa função Q pode ser reescrita desta forma:

$$Q^\pi(s_t, a_t) = \sum_{s_{t+1}, r} P(s_{t+1}, r|s_t, a_t) \left[r + \gamma \sum_{a_{t+1}} \pi(a_{t+1}|s_{t+1}) Q^\pi(s_{t+1}, a_{t+1}) \right] \quad (5)$$

De acordo com Rasheed *et al.* (2020), o valor Q é atualizado usando a função Q da seguinte forma:

$$Q_{t+1}(s_t, a_t) \leftarrow Q_t(s_t, a_t) + \alpha \delta_t(s_t, a_t) \quad (6)$$

onde, $0 \leq \alpha \leq 1$ é a taxa de aprendizado, e $\delta_t(s_t, a_t)$ é a diferença temporal que se baseia na equação de Bellman, que representa a diferença entre as recompensas imediata e descontada para duas estimativas sucessivas como segue:

$$\delta_t(s_t, a_t) = r_{t+1}(s_{t+1}) + \gamma \max_{a \in A} Q_t(s_{t+1}, a) - Q_t(s_t, a_t) \quad (7)$$

onde, $\gamma \max_{a \in A} Q_t(s_{t+1}, a)$ representa a recompensa descontada, que é o valor Q máximo esperado no tempo $t + 1$ e assim por diante, e $0 \leq \gamma \leq 1$ representa um fator de desconto que mostra a preferência pela recompensa descontada. Em outras palavras, a recompensa imediata $r_{t+1}(s_{t+1})$ representa uma recompensa de curto prazo, enquanto a recompensa

descontada $\gamma \max_{a \in A} Q_t(s_{t+1}, a)$ representa uma recompensa de longo prazo. Com o passar do tempo $t = 1, 2, 3, \dots$, o agente explora, atualiza e armazena os valores $Q, Q_t(s_{t+1}, a)$, de todos os pares de estado-ação (s_t, a_t) em uma tabela Q bidimensional.

Durante a seleção da ação, um agente seleciona a exploração ou o aproveitamento. A exploração seleciona uma ação aleatória com uma pequena probabilidade ε para atualizar o seu valor Q de modo que melhores ações possam ser identificadas em um ambiente operacional dinâmico e estocástico na medida em que o tempo avança. Por outro lado, o aproveitamento seleciona a ação mais conhecida (ou gananciosa) com probabilidade $1 - \varepsilon$ para maximizar o valor do estado usando a função de valor da seguinte forma (Rasheed *et al.*, 2020):

$$v_t^\pi(s_t) = \max_{a \in A} Q_t(s_t, a) \quad (8)$$

onde, π é a política que é aplicada pelo agente para decidir a próxima ação a_{t+1} com base no estado atual s_t , e é definida da seguinte forma:

$$\pi(s_t) = \arg \max_{a \in A} Q_t(s_t, a) \quad (9)$$

Portanto, um agente seleciona uma ação com o valor Q máximo.

Segundo Y. Gong *et al.* (2019), um dos famosos algoritmos de RL é o Q-learning, que é um algoritmo sem política. Isso significa que a política seguida é independente do seu processo de aprendizado. No Q-learning, o agente escolhe a ação $a \in A$ com o maior valor de Q (ação gananciosa) baseado na matriz da Tabela-Q, que é uma tabela de mapeamento de todos os valores de estado discretos $s \in S$ para todos os valores de ação discretos $a \in A$. A cada passo discreto, o Q-learning melhora a ganância de sua política. O valor Q ajustado Q_{t+1} é aprendido por:

$$Q_{t+1}(s_t, a_t) = (1 - \alpha)Q_t(s_t, a_t) + \alpha \left(r_{t+1}(s_{t+1}) + \gamma \max_{a \in A} Q_t(s_{t+1}, a) \right) \quad (10)$$

2.8.3 *Deep Reinforcement Learning*

O Aprendizado por Reforço Profundo (DRL) é a combinação de duas abordagens de inteligência artificial, como destacado acima. E o Deep Q-network (DQN) é o primeiro método de DRL proposto pelo DeepMind (Mnih *et al.*, 2013) e tem sido utilizado amplamente no controle de semáforos. O DQN tem duas características principais: repetição de experiência e rede alvo (Li, 2017; Henderson *et al.*, 2018; Ye *et al.*, 2019; Nguyen e Reddi, 2019). De acordo com Rolnick *et al.* (2019), usando a repetição de experiência, um agente armazena uma experiência em uma memória de repetição e, na sequência, ele se treina usando experiências selecionadas aleatoriamente nessas memórias.

Com a rede alvo, um agente utiliza uma duplicata da rede principal e os seus pesos para calcular os valores Q alvos, que são usados em seguida para calcular uma função de perda minimizada por meio de um gradiente de queda (Chen *et al.*, 2018). Os pesos das redes alvo são fixos ou atualizados após um certo número de iterações para melhorar a estabilidade do treinamento. Durante esse treinamento, o valor Q alvo é usado para calcular a perda de uma ação selecionada a fim de estabilizar o treinamento. Então, ele é atualizado a cada número de iterações (Takano *et al.*, 2019; He *et al.*, 2019; Behzadan e Hsu, 2019; Liu *et al.*, 2019; Liu *et al.*, 2020). A rede principal permite que um agente selecione uma ação após observar o seu estado a partir do ambiente e, posteriormente, ele atualiza os seus principais valores Q.

2.8.3.1 *Arquitetura do DQN*

O DQN possui um dos diferentes tipos de arquiteturas do DL, tais como: FCLN, CNN, SAE, 3DQN e LSTM. O FCLN tem sido amplamente utilizado com o DQN e, na sua arquitetura, um agente tem três componentes principais: memória de repetição, rede principal e rede alvo. A memória de repetição é um conjunto de dados das experiências de um agente $D_t = (e_1, e_2, \dots, e_t, \dots)$, que são coletados quando o agente interage com o ambiente com o passar do tempo $t = 1, 2, 3, \dots$. Posteriormente, as experiências D_t são utilizadas durante o processo de treinamento.

A rede principal consiste de um FCLN e o seu peso θ_k é usado para aproximar os valores Q $(s, a; \theta_k)$ da rede na iteração k . A rede principal é usada para selecionar uma ação a_t para um determinado estado s_t observado no ambiente, a fim de alcançar a melhor

recompensa possível $r_{t+1}(s_{t+1})$ e o próximo estado s_{t+1} no próximo instante $t + 1$. A rede alvo é uma duplicata da rede principal e o peso θ^- da FCLN é usado para aproximar seus valores Q, $Q(s, a; \theta_k^-)$ após a k – ésima iteração.

Y. Gong *et al.* (2019) explica que, embora tenha a mesma estrutura da rede primária, a rede alvo é atualizada com menos frequência, sendo utilizada para gerar o valor Q alvo e atualizar os hiperes parâmetros θ da rede primária da seguinte forma:

$$J = \sum_s P(s) \left(Q_{alvo}(s, a; \theta^-) - Q_{principal}(s, a; \theta) \right) \quad (11)$$

onde, $P(s)$ denota a probabilidade do estado s no minilote; $Q_{principal}$ e Q_{alvo} são valores Q estimados pelas redes primária e alvo, respectivamente. J é usado como uma função de perda para atualizar θ na otimização da retropropagação. A cada etapa, os hiperes parâmetros da rede alvo θ^- são atualizados pelos hiperes parâmetros θ da rede primária. Como resultado, a função de perda da etapa de treinamento corrente é avaliada por meio de um instante anterior, decorre dos valores Q e estados alvo e principal e aumenta a estabilidade do algoritmo de aprendizado.

De acordo com Rasheed *et al.* (2020), existem duas diferenças principais entre os valores Q da rede principal e da rede de destino. Primeiro, a rede principal é utilizada durante a seleção e o treinamento da ação, enquanto a rede alvo é usada somente durante o treinamento. A rede alvo melhora a estabilidade do treinamento, sem ela a política pode oscilar entre os valores Q principal e alvo como ocorre em uma rede simples. Em segundo lugar, os valores Q, $Q(s, a; \theta_k)$, da rede principal são atualizados em cada iteração k , enquanto os pesos θ_j^- da rede alvo são atualizados copiando os pesos j da rede principal em cada iteração k .

2.8.3.2 Algoritmo DQN

De acordo com o algoritmo DQN, no episódio $m \in M$, um agente observa o estado atual $s_m \in S$. No instante $t \in T$, o agente seleciona uma ação $a_t \in A$ usando a Equação (5), que é dada pelo valor Q da rede principal. Em seguida, ele recebe a recompensa $r_{t+1}(s_{t+1})$, observa o próximo estado s_{t+1} e armazena a sua experiência $e_t = (s_t, a_t, r_t, s_{t+1}, a_{t+1})$ na memória de repetição $D_t = (e_1, e_2, \dots, e_t, \dots)$. Então, o agente

amostra aleatoriamente um minilote de experiências dessa memória D_t para aprender os pesos θ_j . Na iteração $j \in J$ o agente atualiza os valores Q alvo da rede alvo, especificamente $Q_j(s_j, a_j^*; \theta_k^-) \approx Q^*(s_j, a_j)$. Os pesos θ_j^- da rede alvo são substituídos pelos pesos θ_j da rede principal a fim de fornecer valores Q atualizados, $Q(s, a; \theta_k^-)$, da rede alvo com o passar do tempo. Os pesos θ_j^- da rede alvo são fixados para minimizar a perda entre os valores Q da rede principal e da rede alvo, o que ajuda a estabilizar os valores Q. A função de perda na iteração j é minimizada para treinar a rede principal da seguinte forma (Rasheed *et al.*, 2020):

$$L_j(\theta_j) = \mathbb{E}_{s_j, a_j \sim p(\cdot)} \left[\left(y_j - Q_j(s_j, a_j; \theta_j) \right)^2 \right] \quad (12)$$

onde $p(s, a)$ representa a distribuição de probabilidade de um par de estado-ação (s, a) , e y_j representa o alvo dado por θ_{j-1}^- na iteração anterior $j - 1$. O gradiente da função de perda $\nabla_{\theta} L_j(\theta_j)$ é dado da seguinte forma:

$$\nabla_{\theta} L_j(\theta_j) = \mathbb{E}_{s_j, a_j \sim p(\cdot)} \left[\left(y_j - Q_j(s_j, a_j; \theta_j) \right) \nabla_{\theta_j} Q_j(s_j, a_j; \theta_j) \right] \quad (13)$$

Rasheed *et al.* (2020) destacam que, durante a retropropagação, um passe para trás utiliza o gradiente de queda, em que os pesos θ_j da rede principal são atualizados na direção oposta, para alcançar o valor mínimo do $\nabla_{\theta} L_j(\theta_j)$.

2.8.3.3 Double DQN

Como exemplo das variações da arquitetura do DRL, desenvolvidas para melhorar o desempenho do algoritmo padrão, o Double DQN foi introduzido para evitar estimativas de valores Q super otimistas. Outras variações, tal como, o *Dueling DQN*, que acelera a convergência do valor Q (Wang *et al.*, 2016), têm o mesmo propósito.

Nesse contexto, Y. Gong *et al.* (2019) apontam que a seleção da ação gananciosa e a avaliação do valor Q no DQN padrão usam o mesmo valor de ação e isso pode derivar estimativas de valores super otimistas. Por isso, Van Hasselt *et al.* (2016) propuseram uma versão melhorada do DQN, o *Double DQN*, para estimar a ação gananciosa pela rede alvo por meio da modificação do cálculo do valor Q alvo:

$$Q_{alvo}(s_t, a_t) = r_t - \gamma Q \left(s_{t+1}, \arg \max_{a_{t+1}} (Q(s_{t+1}, a_{t+1}; \theta)); \theta^- \right) \quad (14)$$

O *Double* DQN é comprovadamente capaz de encontrar políticas melhores em relação ao DQN padrão.

3 ÁREA DE ESTUDO E LEVANTAMENTO DE DADOS

A região escolhida para validar a proposta desenvolvida nessa pesquisa são interseções monitoradas da rede viária do Distrito Federal, especificamente do seu ramo urbano. Entretanto, cabe contextualizar que essa rede viária tem características interessantes porque, a despeito de possuir rodovias, vias arteriais, vias coletoras e vias locais como outras cidades brasileiras, no caso do Distrito Federal, a capital é a origem de oito rodovias federais radiais: BR-010, BR-020, BR-030, BR-040, BR-050, BR-060, BR-070 e BR-080, e isso poderia provocar alguma confusão se não fosse uma adaptação feita em relação ao Plano Nacional de Viação – PNV. De acordo com Sistema Rodoviário do Distrito Federal – SRDF (DER-DF, 2016), essa adaptação institui que as rodovias radiais que seguem a partir da DF-001, Estrada Parque do Contorno – EPCT, são rodovias federais e aquelas que se desenvolvem dentro do anel delimitado pela EPCT são rodovias distritais.

Ainda, de acordo com DER-DF (2016), as rodovias do DF incluindo rodovias distritais coincidentes (com rodovias federais), distritais, vicinais e acessos (anéis, contornos e arcos) somam a extensão de 1.912 km. A NOVACAP (2016) totaliza em 11.678,48 km a extensão das rodovias (2.343,73 km), vias arteriais (1.170,68 km), vias coletoras (1.103,51 km) e vias locais (7.060,56 km) do DF. O mapa do Sistema Viário do Distrito Federal (SEGETH-DF, 2016) considera a composição do sistema rodoviário dividida em rodovias federais, rodovias distritais, vias vicinais e vias urbanas.

Interpretando as informações oficiais citadas anteriormente, têm-se que são computadas como vias urbanas as vias coletoras e as vias locais. Além disso, o Plano Diretor Local – PDL (SEGETH-DF, 2016) estabelece a hierarquia das vias como arteriais (rodovias), principais (avenidas de atividades e eixos de circulação), secundárias e locais. Então, ainda interpretando, as vias urbanas do Distrito Federal são classificadas como avenidas de atividades, eixos de circulação, vias secundárias e vias locais que juntas totalizam 8.164,07 km de extensão.

Portanto, na sequência, este trabalho descreverá a metodologia de escolha da zona de estudo a fim de motivar a opção pela avenida Hélio Prates, do tratamento do banco de dados obtido para viabilizar a análise do comportamento do fluxo de tráfego nessa avenida e o levantamento de dados realizado em campo para determinar o fluxo de saturação

e validar os resultados da primeira análise realizada. Toda essa fase de trabalho proposta nesse capítulo é com o intuito de validar o modelo posteriormente.

3.1 ESCOLHA DA ZONA DE ESTUDO

Entrevistas realizadas com integrantes do DETRAN/DF constataram que o Distrito Federal tem 469 interseções semaforizadas das quais apenas 205 são centralizadas segundo 4 áreas: Brasília, Taguatinga, Ceilândia e Guará. Águas Claras e as demais regiões administrativas não possuem semáforos centralizados. Das áreas centralizadas, Brasília está dividida em 6 subáreas e Taguatinga em 2 subáreas enquanto Ceilândia e Guará não possuem subáreas. Brasília tem 129 interseções centralizadas, Taguatinga tem 39 interseções exclusivas e divide as 33 interseções da subárea Hélio Prates com Ceilândia e, finalmente, o Guará possui somente 4 interseções centralizadas.

Como resultado, a maioria das interseções semaforizadas são isoladas, com controle de tempo fixo e os ajustes necessários são realizados manualmente pelos técnicos do DETRAN/DF, sendo esses ajustes definidos de acordo com a experiência dos profissionais responsáveis pelo atendimento em cada interseção. No sistema semaforico do Distrito Federal, existem semáforos atuados, mas somente por botoeiras para pedestres.

Em relação aos semáforos centralizados, embora os operadores possam visualizar e proceder às mudanças de fases remotamente, o tráfego não é monitorado por eles na central pois as câmeras e equipamentos de fiscalização eletrônica de veículos não funcionam de forma centralizada e não estão disponíveis em todas as interseções. Por isso, o controle demanda pelo apoio de técnicos nas aproximações das interseções semaforizadas para avaliar as necessidades e o resultado das mudanças procedidas.

Neste contexto, a avenida Hélio Prates, classificada como uma avenida de atividades pelo PDL de Taguatinga e de Ceilândia (SEGETH-DF, 2016), opera como uma via arterial com dois segmentos contínuos entre Taguatinga e Ceilândia. Dada a sua relevância, essa avenida integra uma única subárea com 33 interseções centralizadas. Por isso, foram realizadas pesquisas exploratórias nessa avenida visando a descobrir como se comporta o trânsito naquela região e como este trabalho poderia contribuir. Nessa pesquisa, buscou-se identificar a ocorrência de congestionamentos, preliminarmente no horário de pico no

final da tarde em dias do meio da semana, especificamente nas 3^a, 4^a ou 5^a feiras entre as 17:00h e 19:30h.

Assim, foram identificadas na avenida Hélio Prates três interseções monitoradas em todas as direções por detectores de avanço semafórico. A Figura 3.1 apresenta o trecho compreendido entre a via M4 e a via Nm 12A. Portanto, esse trecho é definido por duas das três interseções citadas e, conseqüentemente, limitado por cada uma delas em suas extremidades, sendo a interseção A o cruzamento entre a avenida Hélio Prates e a via M4 e a interseção B o cruzamento entre a avenida Hélio Prates e a via Nm 12A. As interseções distam 1.380 metros entre si.



Figura 3.1: Área de estudo na avenida Hélio Prates

Em todas as pesquisas exploratórias supracitadas, foram observadas formações de congestionamentos nas vias M4 e Nm 12A a montante da interseção A, na direção sul, e da interseção B, na direção norte. Raramente, foram observadas retenções na avenida Hélio Prates que ocorreram somente a montante da interseção B, na direção oeste.

Como ilustração e amostra, a **Erro! Fonte de referência não encontrada.** foi extraída da plataforma Google Maps e permite observar a condição do tráfego em tempo real nas interseções A e B às 18:00h do dia 15 de março de 2017. Depois, com base no histórico do banco de dados da referida plataforma, a Figura 3.3 e a Figura 3.4 representam o trânsito típico das interseções A e B nas quartas-feiras em horários distintos.

Cabe salientar que as observações feitas nas pesquisas exploratórias realizadas foram con-



Figura 3.2: Detalhes das condições de tráfego reais nas aproximações das interseções A e B as 18:00h do dia 15 de março de 2017.



Figura 3.3: Condição de tráfego típica com detalhe da interseção A nas quartas-feiras as 8:30h, de acordo com a plataforma Google Mapas

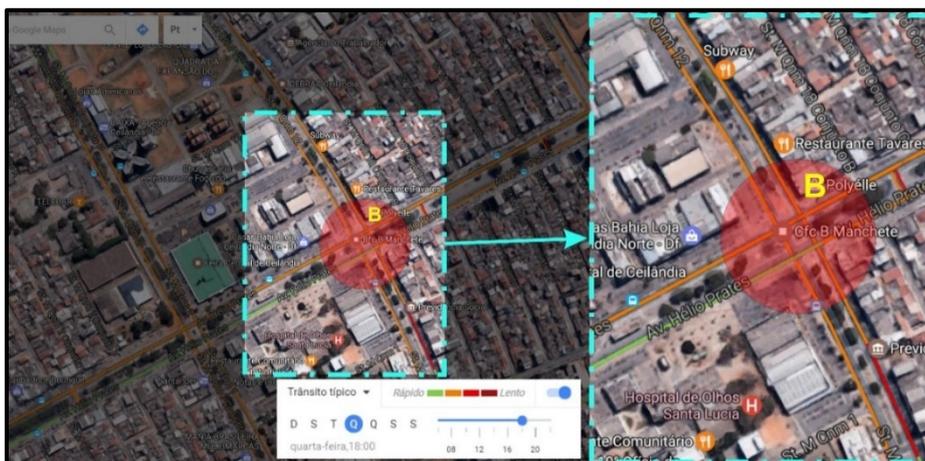


Figura 3.4: Condição de tráfego típica da interseção B nas quartas-feiras as 18:00h, de acordo com a plataforma Google Mapas.

sistentes com os dados da plataforma Google Mapas. Embora as pesquisas exploratórias preliminares não tenham se estendido ao longo de um dia inteiro, os dados extraídos da

plataforma Google Mapas permitiram amostragens da formação de congestionamentos em outros horários. Essas amostragens sugeriram que os horários de picos na interseção A ocorreram entre 6:30h e 8:15h e entre 17:25h e 19:30h. Enquanto isso, na interseção B, os horários de pico estavam entre as 10:30h e 13:10h e 13:55h e 18:35h.

Adiante, no subtítulo abaixo, o banco de dados dos sensores de contagem de fiscalização eletrônica veicular foi analisado, as interseções foram individualizadas e suas características descritas por meio de indicadores numéricos, conforme demonstram os exemplos que esse subtítulo apresenta.

3.2 DADOS DISPONIBILIZADOS PELO DETRAN-DF

Este trabalho dispõe de um banco de dados composto pelos registros diários de cada veículo que cruza um determinado equipamento de fiscalização eletrônica. Os registros feitos pelos sensores são agrupados por meses e cada mês possui em média 520.000 linhas de registros com 7 (sete) informações em cada uma: equipamento, data, hora, faixa, velocidade registrada, velocidade limite e tamanho do veículo.

Sendo 2 (duas) interseções com um equipamento em cada direção, são 8 (oito) equipamentos no total. Os registros dos sensores se iniciam em dezembro de 2014 e se estendem até junho de 2017, somando 31 meses de dados. A identificação e localização dos equipamentos são apresentadas na Figura 3.5. Contudo, depois das análises do banco, apenas 3 meses: maio, junho e julho de 2016, foram usados para treinar a rede e rodar o modelo.



Figura 3.5: Identificação e localização dos sensores no trecho da área de estudo

Cabe destacar que as informações dos tamanhos dos veículos, que poderiam ajudar no cálculo da ocupação da via, são incompletas e inconsistentes. Embora tenha sido solicitado outro banco de dados a fim de corrigir essa informação, os registros dessa informação continuaram insatisfatórios porque, além de falhas, os sensores apenas qualificam se o veículo é leve ou pesado, conforme o seu comprimento seja de até 4,0 metros ou esteja entre 4,0 e 11,3 metros, respectivamente.

A Figura 3.6 apresenta para fins de comparação um extrato de cada banco de dados. O primeiro conjunto de dados exemplifica o banco de dados utilizado e os seus registros são ordenados em intervalos de tempo pequenos, sendo o espaço entre registros subsequentes medidos em poucos segundos (por exemplo: 1, 2, 4 ou 5 segundos). Do outro lado, os registros do outro banco de dados, exemplificados pelo conjunto de dados mais à direita, possuem intervalos grandes demais para o que deveria ser o mesmo dado coletado pelo sensor em questão. Enquanto o primeiro banco de dados não apresenta o tamanho dos veículos, o segundo traz esse dado nas últimas 5 (cinco) posições de cada linha. Ainda, cabe ressaltar que para cada faixa de rolamento os registros estão gravados em ordem decrescente no banco, quando deveria ser em ordem crescente.

Banco de Dados Utilizado		Banco de Dados Descartado	
RSI0332014/12/01	00:04:432048,0060,0000,0	RSI0332014/12/01	00:50:522068,0060,0004,0
RSI0332014/12/01	00:04:372055,0060,0000,0	RSI0332014/12/01	01:48:162079,0060,0004,0
RSI0332014/12/01	00:04:322050,0060,0000,0	RSI0332014/12/01	02:56:372073,0060,0004,0
RSI0332014/12/01	00:04:222036,0060,0000,0	RSI0332014/12/01	03:43:052077,0060,0004,0
RSI0332014/12/01	00:03:432047,0060,0000,0	RSI0332014/12/01	05:59:281021,0060,0004,0
RSI0332014/12/01	00:03:082045,0060,0000,0	RSI0332014/12/01	06:15:292020,0060,0004,0
RSI0332014/12/01	00:02:522042,0060,0000,0	RSI0332014/12/01	06:47:433027,0060,0004,0
RSI0332014/12/01	00:02:362045,0060,0000,0	RSI0332014/12/01	09:35:383070,0060,0004,0
RSI0332014/12/01	00:02:262049,0060,0000,0	RSI0332014/12/01	11:42:562070,0060,0004,0
RSI0332014/12/01	00:02:112036,0060,0000,0	RSI0332014/12/01	11:53:552092,0060,0004,0
RSI0332014/12/01	00:01:492033,0060,0000,0	RSI0332014/12/01	12:00:011052,0060,0004,0
RSI0332014/12/01	00:01:412049,0060,0000,0	RSI0332014/12/01	12:00:053050,0060,0004,0
RSI0332014/12/01	00:01:022046,0060,0000,0	RSI0332014/12/01	12:00:092052,0060,0004,0
RSI0332014/12/01	00:00:262040,0060,0000,0	RSI0332014/12/01	15:27:351080,0060,0004,0
RSI0332014/12/01	00:00:212043,0060,0000,0	RSI0332014/12/01	20:18:263074,0060,0004,0
RSI0332014/12/01	00:00:032033,0060,0000,0	RSI0332014/12/01	21:51:253096,0060,0004,0
RSI0332014/12/01	00:04:411034,0060,0000,0	RSI0332014/12/02	04:54:472080,0060,0004,0
RSI0332014/12/01	00:03:571037,0060,0000,0	RSI0332014/12/02	05:36:002019,0060,0004,0
RSI0332014/12/01	00:03:511033,0060,0000,0	RSI0332014/12/02	05:46:371045,0060,0004,0
RSI0332014/12/01	00:03:401038,0060,0000,0	RSI0332014/12/02	05:50:112078,0060,0004,0
RSI0332014/12/01	00:02:521056,0060,0000,0	RSI0332014/12/02	06:37:103033,0060,0004,0
RSI0332014/12/01	00:00:281044,0060,0000,0	RSI0332014/12/02	11:24:062034,0060,0004,0
RSI0332014/12/01	00:00:231031,0060,0000,0	RSI0332014/12/02	12:00:001043,0060,0004,0
RSI0332014/12/01	00:00:221026,0060,0000,0	RSI0332014/12/02	12:00:003036,0060,0004,0
RSI0332014/12/01	00:03:293035,0060,0000,0	RSI0332014/12/02	12:00:012035,0060,0004,0
RSI0332014/12/01	00:09:541025,0060,0000,0	RSI0332014/12/02	12:35:041069,0060,0004,0
RSI0332014/12/01	00:09:361034,0060,0000,0	RSI0332014/12/02	12:50:231078,0060,0004,0

Figura 3.6: comparativo entre o banco de dado utilizado e o outro descartado

Além disso, os registros do banco de dados destacado apresentaram inconsistências por algum motivo desconhecido e, por isso, optou-se por usar o primeiro banco de dados com registros até dezembro de 2017.

Analisando previamente os dados do sensor RSI033 (Interseção A ou 353), que fica no final do trecho da área de estudo na avenida Hélio Prates, no sentido de Ceilândia para

Taguatinga, foi possível identificar algumas características, comportamentos e descontinuidades dos dados coletados para entender melhor o tráfego na região e os dados coletados.

Por exemplo, existem descontinuidades na coleta dos dados e o espectro de velocidades registradas, embora seja bastante amplo, é irregular (Figura 3.7). A relação entre os fluxos e as velocidades é consistente e o comportamento do fluxo varia entre os dias comerciais e o final de semana (Figura 3.9). Outro comportamento importante ocorre entre as 05:00 e 10:00h, quando a velocidade decresce inversamente com o aumento do fluxo a partir da 05:00h até as 07:30h, aproximadamente.

Nesse período, as velocidades se aproximam dos 20 km/h enquanto o fluxo atinge praticamente 1,25 veículos/s para as 3 faixas ou 1.500 veículos/h/faixa, havendo, portanto, um indicativo de que ocorre um congestionamento nesse intervalo de tempo. Depois, até as 10:00h, o processo se inverte de forma menos acentuada. Então, surge um regime praticamente estável até as 20:00h e, com fluxos baixos, as velocidades aumentam consideravelmente após as 23:30h até as 02:00h, aproximadamente (Figura 3.9). Fica evidenciado que nessa seção da av. Hélio Prates ocorre um regime de fluxo congestionado apenas no período compreendido entre as 05:00 e as 10:00h.

Na Figura 3.7, a seta aponta um intervalo grande sem dados coletados, as linhas horizontais pontilhadas e vermelhas destacam a faixa de velocidades mais usuais e as áreas circundadas indicam provavelmente o comportamento dos motoristas que, ao avistarem os equipamentos de fiscalização, reduzem bruscamente as suas velocidades de trânsito enquanto outros mantêm a velocidade ou a reduzem gradualmente.

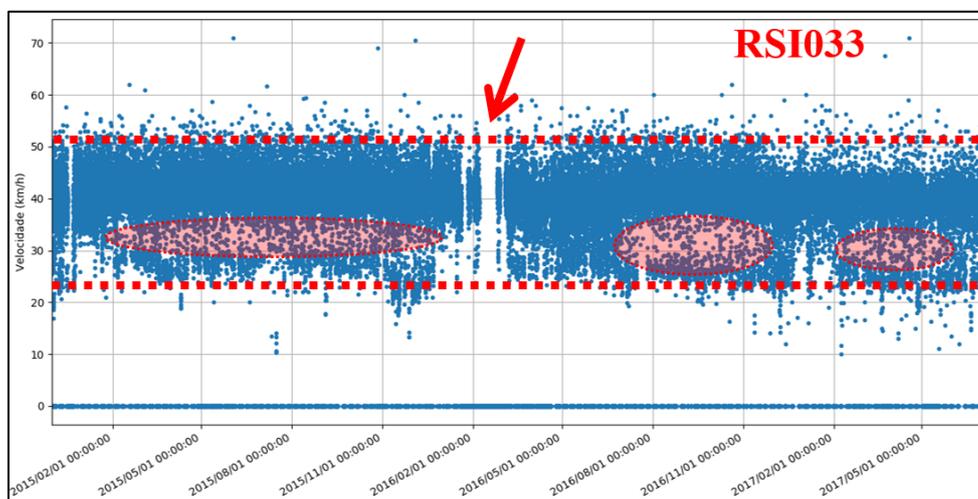


Figura 3.7: Exemplo da série temporal de velocidade coletada pelo equipamento RSI033.

A Figura 3.8 apresenta o comportamento do fluxo e da velocidade ao longo de uma semana, começando em uma segunda-feira e terminando em um domingo. Assim, além de um relacionamento consistente entre essas duas variáveis, a Figura 3.8 permite identificar um comportamento praticamente regular das variáveis ao longo dos dias úteis, conforme é representado pelas curvas vermelhas. Depois, outra observação importante está dentro das áreas sombreadas em vermelho, nas quais ocorre uma concentração de fluxos baixos no sábado e no domingo e a ausência de velocidades baixas, o que não ocorre entre terça e sexta-feira.

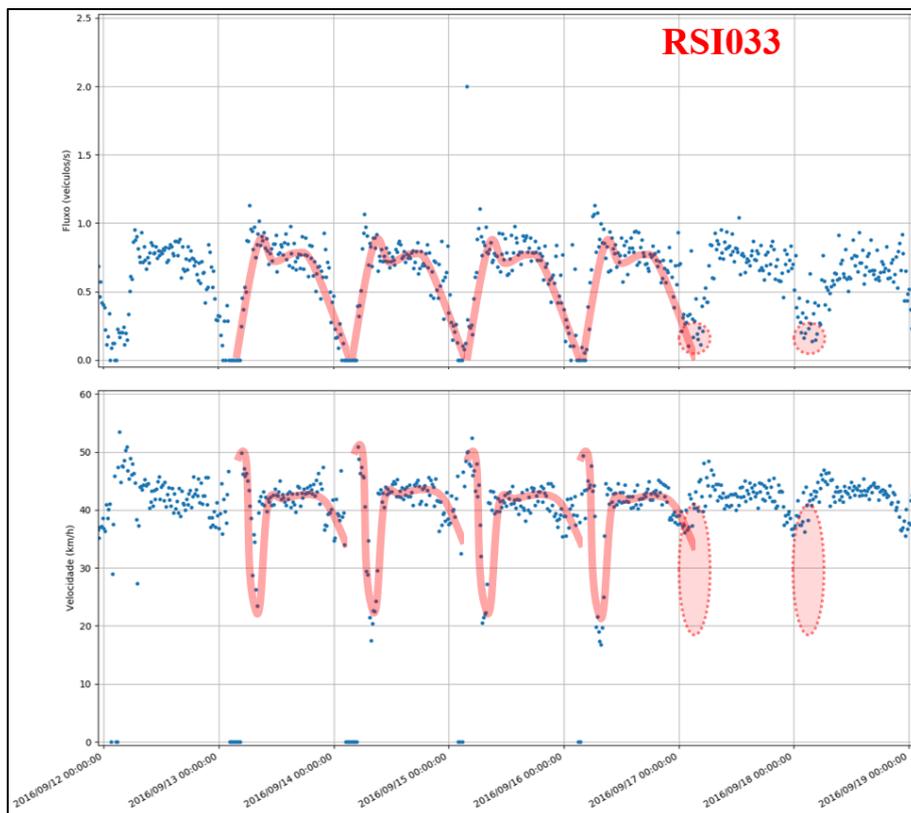


Figura 3.8: Exemplo de comportamento do fluxo e do tráfego em uma semana para o equipamento RSI033

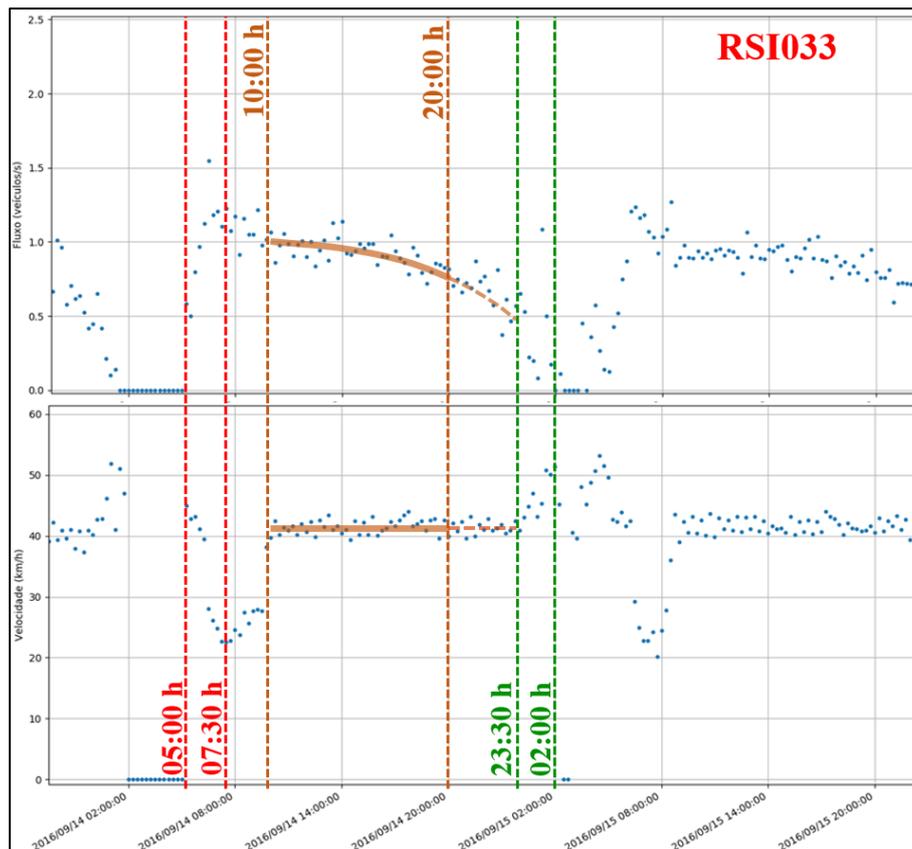


Figura 3.9: exemplo de comportamento do tráfego em um dia útil registrado pelo sensor do equipamento RSI033

Dervisoglu *et al.* (2009) advertem sobre a importância de uma boa medida na performance dos equipamentos de fiscalização eletrônica de veículos no que tange ao tamanho das amostras coletadas e sobre a presença expressiva de dados de fluxo congestionado nessas amostras.

Assim, períodos desfavoráveis ficaram evidenciados, bem como os horários em que ocorriam os congestionamentos ao longo do dia, e, por isso, foram escolhidos os meses de maio, junho e julho do ano de 2016 para o trabalho.

Além disso, por meio de um código em linguagem Python, os registros foram reordenados em ordem decrescente de tempo, independentemente da faixa de rolagem, para dar consistência à sequência dos registros e os dados foram segmentados em cada linha a fim de filtrar e desconsiderar os dados irrelevantes: velocidade limite e tamanho do veículo, bem como para formatar os demais dados.

4 MODELAGEM DO CONTROLE ADAPTATIVO DE TRÁFEGO

O modelo está proposto em duas etapas interligadas entre si, mas que podem ser abordadas distintamente como: previsão de fluxos de tráfego e otimização dos planos semaforicos. Ainda, cabe salientar que todas as etapas envolveram a criação de algoritmos na linguagem *Python* para organizar, filtrar, processar e analisar os dados e que, a partir desse ponto, eles serão referenciados apenas como algoritmos. A Figura 4.1 apresenta as etapas que serão descritas na sequência e estabelece as relações entre cada uma delas, bem como os respectivos produtos.

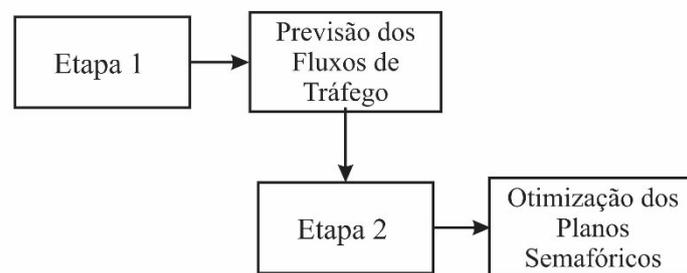


Figura 4.1: Etapas do trabalho, produtos e relacionamentos.

4.1 PREVISÃO DOS FLUXOS DE TRÁFEGO

A natureza dos dados de fluxo de tráfego urbano é estocástica e possui uma não linearidade acentuada e, neste contexto, os trabalhos de Yisheng *et al.* (2015) e Polson e Sokolov (2016) destacam a grande contribuição que as arquiteturas de *deep learning* podem dar na previsão desses fluxos diante da não linearidade espacial e temporal intrínsecas. Existem algumas peculiaridades entre esses dois trabalhos, tais como o uso de funções diferentes para ativar as camadas intermediárias da rede neural – Yisheng *et al.* (2015) usaram a função Sigmóide enquanto Polson e Sokolov (2016) usaram a função Tangente Hiperbólica. No entanto, embora ambos os trabalhos tenham norteado esta etapa, o método de Yisheng *et al.* (2015) é a sua base principal.

Assim, utilizou um modelo de arquitetura profunda – *Stacked Autoencoder* – para aprender as características do fluxo de tráfego e uma camada de regressão logística para realizar cada previsão, sendo que o treinamento da rede neural profunda foi para frente (*straight-forward*) por meio do método de *Backpropagation* ajustado pelo algoritmo de aprendizado não supervisionado denominado *Greedy Layer-Wise*. A rede neural foi desenvolvida com 4 camadas, sendo uma camada de entrada, duas intermediárias e outra de saída.

A camada de entrada e as camadas intermediárias possuem 400 neurônios cada uma e a camada de saída apenas um neurônio. A primeira camada tem como entrada um vetor com o fluxo atual e dois fluxos passados normalizados, ou seja, o valor de cada um menos a média, dividido pelo desvio padrão. A função logística sigmóide ativa todas as camadas e a entrada da camada seguinte é a saída da anterior multiplicada por uma matriz de pesos e somado a um vetor de vies. A última camada resulta apenas um valor que é desnormalizado em seguida. A Figura 4.2 apresenta um diagrama dessa rede neural.

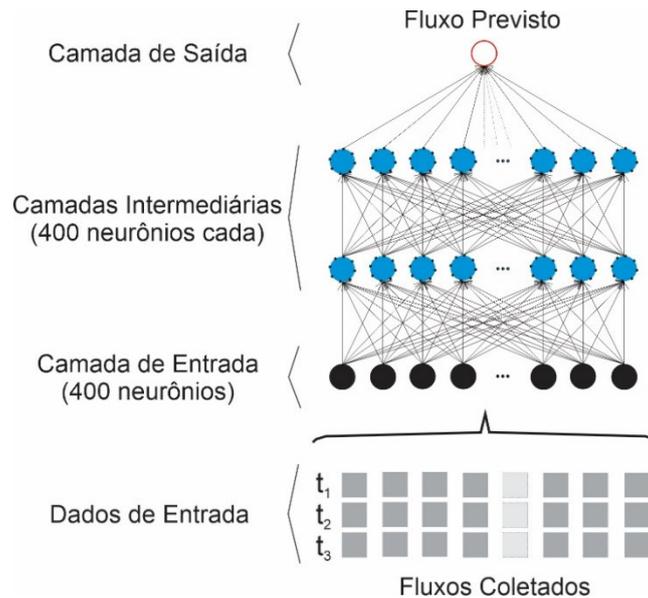


Figura 4.2: Diagrama da rede neural desenvolvida nesse trabalho para realizar a previsão.

Alguns parâmetros, tais como a média e o desvio padrão da distribuição normal que inicializa aleatoriamente a determinação dos pesos, foram calibrados. O treinamento foi realizado com dois terços dos dados disponíveis para cada camada mediante a minimização da função de erro por *backpropagation*. Repetindo-se o treinamento e o conjunto de dados na camada seguinte. A otimização da rede neural recebeu 400 registros por vez e a taxa de aprendizado foi reduzida exponencialmente em 0,9604 no treinamento de cada camada.

A Figura 4.3 apresenta graficamente a série de dados do período de 01 de maio a 31 de julho de 2016 que foi utilizada nesta etapa. A calibração dos parâmetros, o treinamento e otimização da rede foi feita com os dados dos meses de maio e junho (série de dados na cor azul) e a validação ou o teste da previsão dos fluxos com os dados do mês de julho (série de dados na cor vermelha).

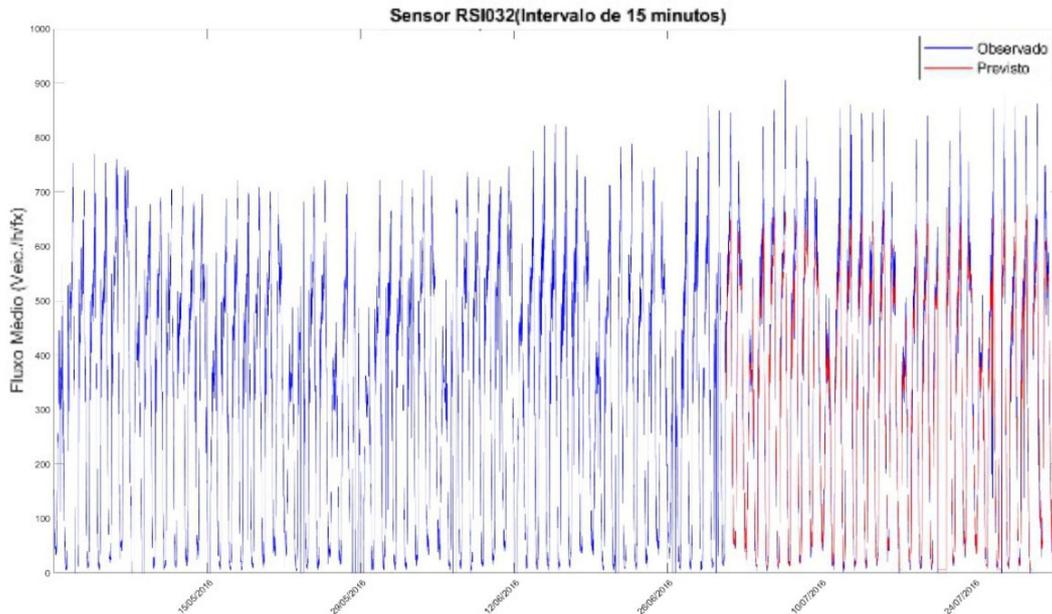


Figura 4.3: Representação dos dados usados no treinamento, previsão e validação dos fluxos

Esta etapa de previsão dos fluxos de tráfego tem como objetivo principal gerar dados de entrada para o algoritmo da etapa 2 a fim de que ele possa sincronizar os tempos semafóricos oportunamente antes da chegada dos pelotões de veículos. Contudo, mediante o emprego de uma metodologia como aquela que está descrita no Apêndice, esta etapa 1 poderá também identificar em sua previsão a transição entre os fluxos livre e congestionado por meio do fluxo de saturação. Assim, será possível oferecer ao usuário a oportunidade de mudar a sua rota diante da iminência ou existência de um colapso do tráfego, inclusive como forma de mitigar o congestionamento.

4.2 OTIMIZAÇÃO DOS PLANOS SEMAFÓRICOS

Esta etapa do modelo foi inspirada no trabalho de Li *et al.* (2016). Além das adaptações feitas ao caso real da área de estudo, descrita no Capítulo 3 acima, das simplificações na quantidade de faixas analisadas, da proposição de um modelo em rede com duas interseções e de uma nova abordagem para a função de recompensa, os demais conceitos do controlador proposto por Li *et al.* (2016) foram mantidos. Aqui, o foco é a otimização dos planos semafóricos de duas interseções contíguas a partir de dados de fluxo coletados por equipamentos de fiscalização eletrônica de veículos instalados nas aproximações de todas as faixas dessas interseções.

Li *et al.* (2016) minimizaram o comprimento de filas para otimizar os tempos semafóricos de uma interseção. Neste trabalho, os registros dos dados coletados pelos detectores de tráfego não continham os tamanhos dos veículos nem os comprimentos das filas que foram formadas e descarregadas no ciclo semafórico. Além do mais, é razoável considerar que quanto maior o fluxo de tráfego que cruza a rede menor será o congestionamento. Por isso, uma função de recompensa foi definida para maximizar os fluxos de tráfego em todas as direções das interseções da rede, bem como entre elas também.

Desta forma, o objetivo foi garantir que a via arterial, que interliga as duas interseções, dê a maior vazão possível ao fluxo de tráfego sem prejudicar o escoamento das vias coletoras, perpendiculares à via arterial em cada interseção. Para fins de analogia com o trabalho de Li *et al.* (2016), cabe destacar que aqui as vias coletoras e a via arterial em questão possuem 2 e 3 faixas de rolamento em cada direção, respectivamente, totalizando 10 faixas de rolamento por interseção (Figura 4.4). Os veículos que trafegam em uma determinada direção não podem fazer uma conversão a esquerda em qualquer uma das interseções.

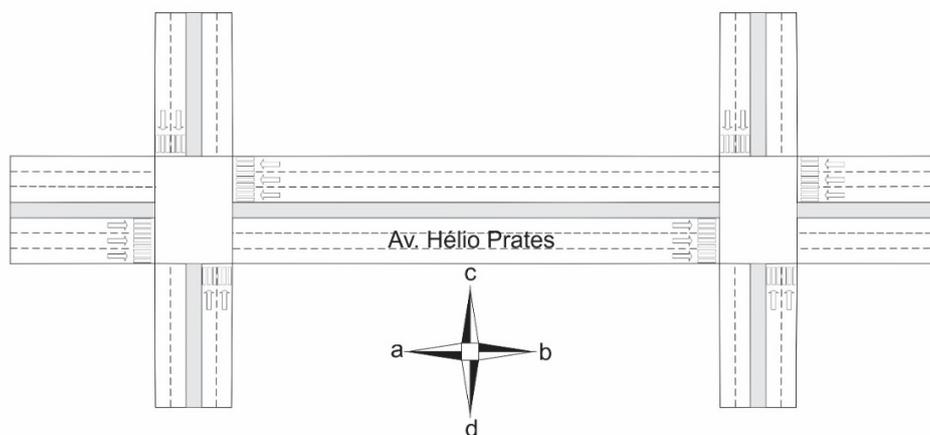


Figura 4.4: Geometria das interseções

Para cumprir com o objetivo dessa pesquisa, simplificou-se o modelo proposto adotando a premissa de que cada direção de uma interseção é um elemento e ocorrem somente tempos sinais verde e vermelho. Conseqüentemente, cada interseção é composta por dois elementos. Então, como um semáforo só pode estar aberto ou fechado, o tempo de sinal verde de um sentido é o mesmo para o sentido oposto em um mesmo elemento e o tempo de verde de um elemento foi tomado como o tempo de vermelho do outro elemento da mesma interseção.

Os fluxos foram calculados em cada elemento da interseção de acordo com a quantidade de veículos que passavam em cada faixa de rolamento por sentido do tráfego e unidade de tempo dentro do intervalo de sinal verde. Entretanto, como também não havia os registros dos planos semaforicos passados para avaliar as extensões das fases dos sinais, considerou-se que, enquanto houvesse fluxo de tráfego em um sentido, o semáforo estava aberto nesse elemento e, caso não existisse fluxo nele, o fluxo na outra direção era testado no mesmo intervalo de tempo.

Dessa forma, uma vez confirmado que o semáforo estava sob a luz verde, a quantidade de veículos era contada dentro do intervalo avaliado e deduzia-se que o semáforo no elemento anterior estava fechado. Então, o fluxo foi calculado pela razão entre a quantidade de veículos e a diferença de tempo decorrido entre o primeiro e o último veículo do intervalo. O tempo mínimo de verificação de fase foi definido igual a um tempo de verde mínimo de 30 segundos embora o algoritmo desenvolvido permita qualquer variação desse tempo de verificação. Depois desse processo de análise e verificação, cada fluxo de tráfego calculado foi registrado.

Foi empregada uma rede neural com quatro camadas, sendo uma de entrada, duas intermediárias e mais uma camada de saída. Como o modelo integra duas interseções com medidas de fluxo nas quatro direções e tomou-se as três medidas mais recentes como amostra para treinar a rede, tem-se 24 neurônios na camada de entrada. Depois, a segunda e a terceira camadas, ativadas pela função sigmoide, foram estruturadas com 16 e 8 neurônios, respectivamente. Assim, como cada interseção possui um elemento para cada sentido, a camada de saída foi concebida com quatro neurônios, ou seja, um neurônio para cada elemento.

A Figura 4.5 discrimina a quantidade de neurônios por camada da rede neural profunda utilizada, bem como apresenta a arquitetura para aproximação da função Q a partir dos estados de entrada, representado pelas últimas três medidas de fluxos.

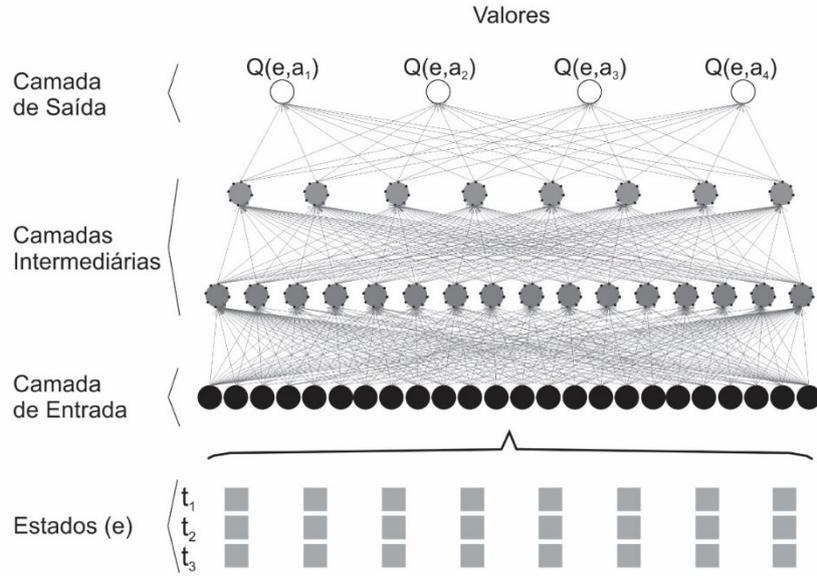


Figura 4.5: Arquitetura da rede neural profunda utilizada para aproximar a função Q

Nesta pesquisa, a recompensa total (R_t) para o aprendizado é proposta como o somatório dos fluxos máximos (f), considerando os três últimos registros (i) mais recentes em cada uma das quatro direções possíveis ($a \rightarrow b$, $b \rightarrow a$, $c \rightarrow d$ e $d \rightarrow c$) para as duas interseções (n) analisadas, tanto no nível local delas quanto na direção principal entre elas (*interlocal*).

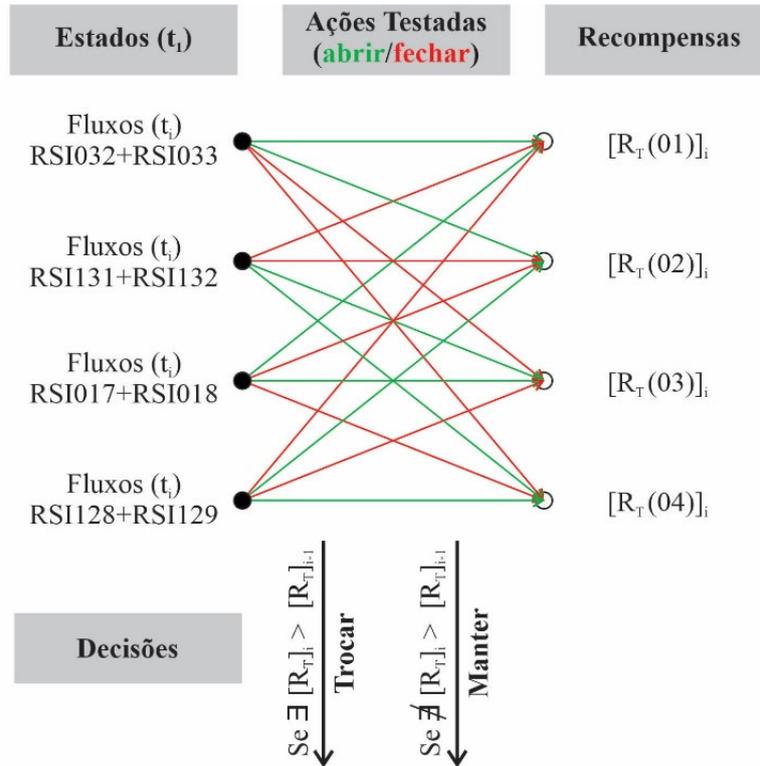
$$R_t = \sum_{\substack{i=1,2,3 \\ n=1,2 \\ i,n}} \left\{ \overbrace{\text{máx} [f_{i_n}^{(a \rightarrow b)}; f_{i_n}^{(b \rightarrow a)}]}^{\text{local}} + \overbrace{\text{máx} [f_{i_n}^{(c \rightarrow d)}; f_{i_n}^{(d \rightarrow c)}]}^{\text{local}} + \overbrace{\text{máx} [f_{i_1}^{(\text{princ.})}; f_{i_2}^{(\text{princ.})}]}^{\text{interlocal}} \right\}$$

No caso da área de estudo, deve-se observar a Figura 4.4 e a Figura 3.1. Como a direção principal está na avenida Hélio Prates de Ceilândia para Taguatinga, a notação *princ.* foi substituída por $b \rightarrow a$ e a equação acima reescrita.

$$R_t = \sum_{\substack{i=1,2,3 \\ n=1,2 \\ i,n}} \left\{ \text{máx} [f_{i_n}^{(a \rightarrow b)}; f_{i_n}^{(b \rightarrow a)}] + \text{máx} [f_{i_n}^{(c \rightarrow d)}; f_{i_n}^{(d \rightarrow c)}] + \text{máx} [f_{i_1}^{(b \rightarrow a)}; f_{i_2}^{(b \rightarrow a)}] \right\}$$

A Figura 4.6 apresenta o diagrama do processo de controle de sinais intrínseco ao modelo de *Deep Reinforcement Learning* desenvolvido. Basicamente, o modelo acumula os fluxos e, a cada intervalo de tempo (t_i), testa um plano de ações para todas as combinações possíveis entre as interseções e calcula as recompensas totais que cada plano entrega. Se

existir uma recompensa maior nessa iteração do que aquela do plano de ações em execução, essas ações são trocadas pelas ações do respectivo plano. Então, o modelo decide quais dos 4 planos de ações são adotados nos intervalos t_i , mantendo ou trocando-os.



Intervalos	Ações Adotadas			
	Inters. 353 RSI032+RSI033	RSI131+RSI132	Inters. 289 RSI017+RSI018	RSI128+RSI129
t_1	Abrir	Fechar	Abrir	Fechar
t_2	Abrir	Fechar	Fechar	Abrir
t_3	Fechar	Abrir	Fechar	Abrir
t_4	Fechar	Abrir	Abrir	Fechar

Figura 4.6: Diagrama do processo de controle

5 RESULTADOS ALCANÇADOS

O modelo foi construído em duas etapas e, em cada uma delas, foram estruturados dois módulos básicos, cujos algoritmos foram desenvolvidos em *Python*. A função do primeiro módulo foi prever os fluxos de tráfegos, gerando uma sequência de fluxos futuros em intervalos de previsão padronizados e de curta duração (1, 5 ou 15 minutos) para cada aproximação. O segundo módulo utilizou essas sequências de fluxos como entrada e fez a sincronização dos tempos semafóricos, adaptando-os às condições do tráfego previsto pelo módulo anterior. A variabilidade dos dados reais introduziu as características intrínsecas do ambiente urbano e os sensores de fiscalização veicular que coletaram esses dados estão bem disseminados em muitas cidades brasileiras.

A Figura 5.1, a Figura 5.2, a Figura 5.3 e a Figura 5.4 representam graficamente os resultados gerados pelo modelo de previsão fazendo a sobreposição dos fluxos de tráfego observados e previstos ao longo de um período de tempo (15 minutos). A Figura 5.3 e a Figura 5.4 ampliam a sobreposição para facilitar a visualização da validação que será demonstrada numericamente pela Tabela 5.1. Os sensores RSI033 e RSI132 integram o monitoramento da mesma interseção. O sensor RSI033 fiscaliza a via arterial com 3 faixas de rolamento e o sensor RSI132 fiscaliza a via coletora com duas faixas de rolamento, no sentido Ceilândia-Taguatinga.

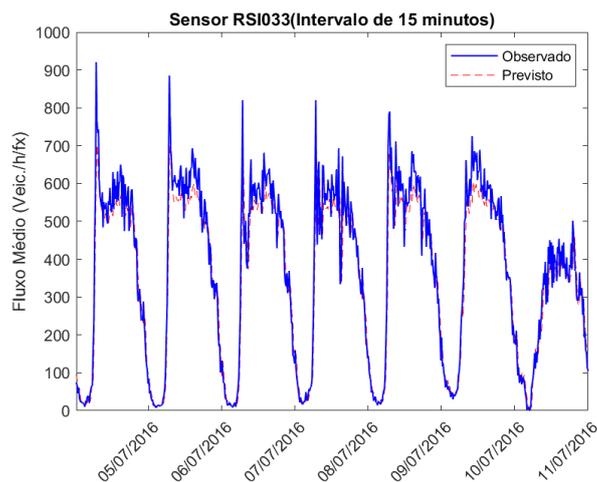


Figura 5.1: Sobreposição dos fluxos de tráfego observados e previstos ao longo de uma semana, começando numa 2ª feira, para o sensor RSI033

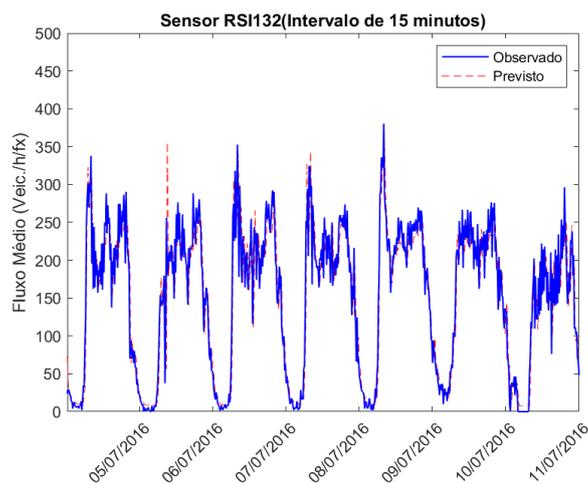


Figura 5.2: Sobreposição dos fluxos de tráfego observados e previstos ao longo de uma semana, começando numa 2ª feira, para o sensor RSI132

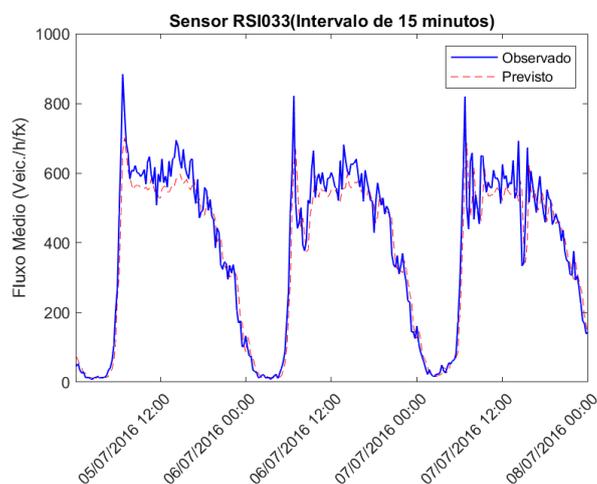


Figura 5.3: Sobreposição dos fluxos de tráfego observados e previstos ao longo de três dias, 3ª, 4ª e 5ª feiras, para o sensor RSI033

Depois, o trabalho realizou previsões de fluxos de tráfego para intervalos menores do que 15 minutos. A Figura 5.5 até a Figura 5.16 destacam os comparativos entre os resultados obtidos para as previsões de 5 minutos e 1 minuto. Primeiro, são apresentados exemplos de resultados mensais (Figura 5.5 e Figura 5.6) e de resultados semanais (Figura 5.7 e Figura 5.8) para cada um desses intervalos menores. Por último, os resultados obtidos para intervalos de previsão de 1 minuto foram discretizados também para as terças, quartas e quintas-feiras e apresentados para todas as interseções da rede de tráfego modelada (Figura 5.9 a Figura 5.16).

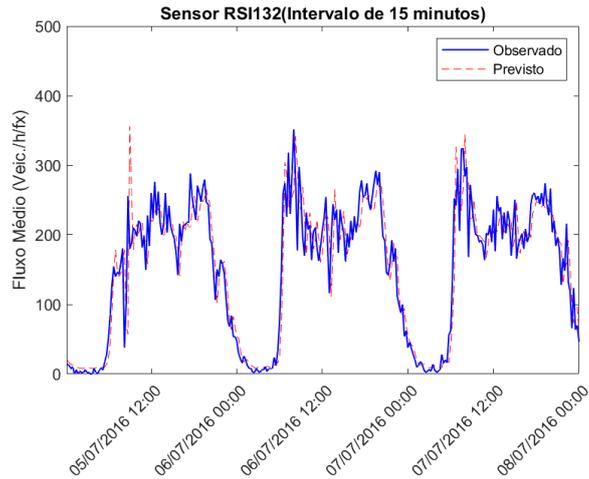


Figura 5.4: Sobreposição dos fluxos de tráfego observados e previstos ao longo de três dias, 3^a, 4^a e 5^a feiras, para o sensor RSI132

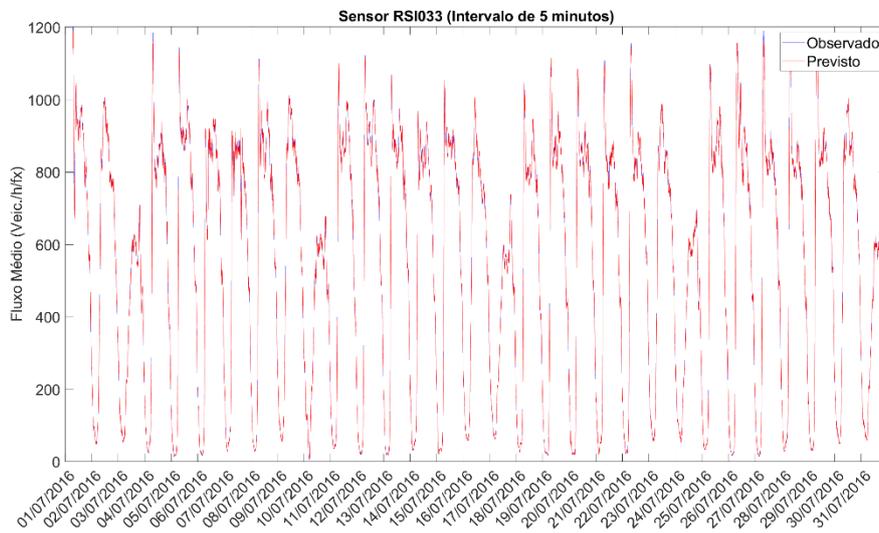


Figura 5.5: Exemplo de resultado mensal para a previsão de fluxo de tráfego obtido em intervalos de 5 minutos.

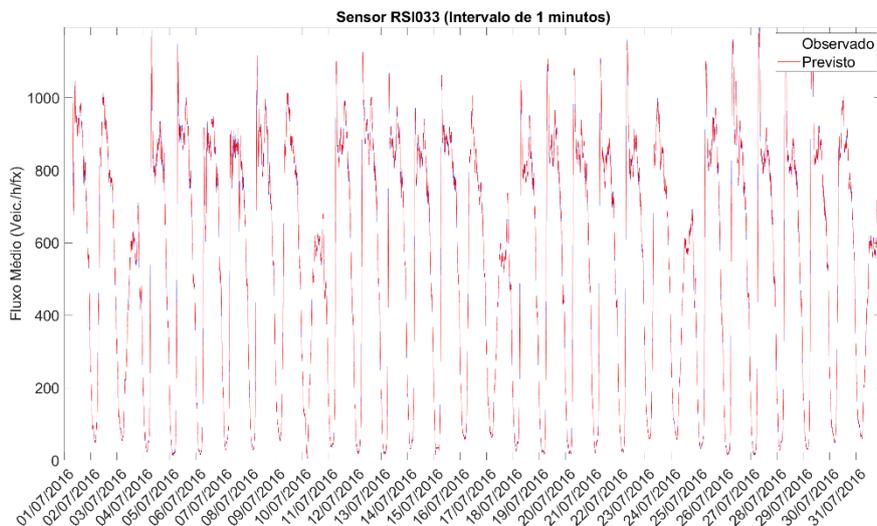


Figura 5.6: Exemplo de resultado mensal para a previsão de fluxo de tráfego obtido em intervalos de 1 minuto.

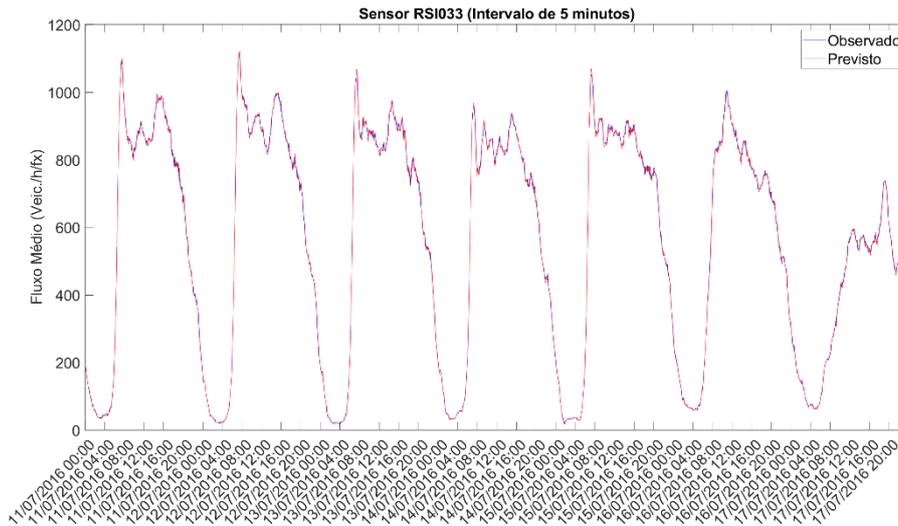


Figura 5.7: Exemplo de resultado semanal para a previsão de fluxo de tráfego obtido em intervalos de 5 minutos.

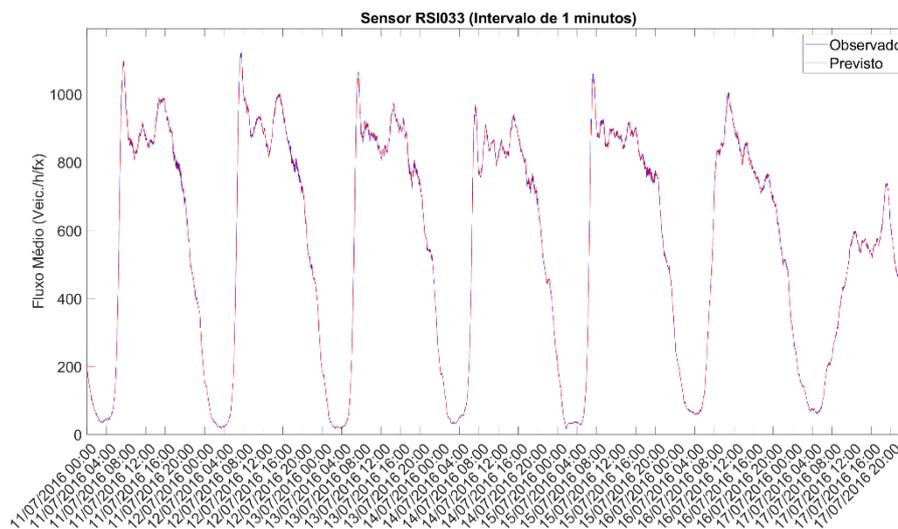


Figura 5.8: Exemplo de resultado semanal para a previsão de fluxo de tráfego obtido em intervalos de 1 minuto.

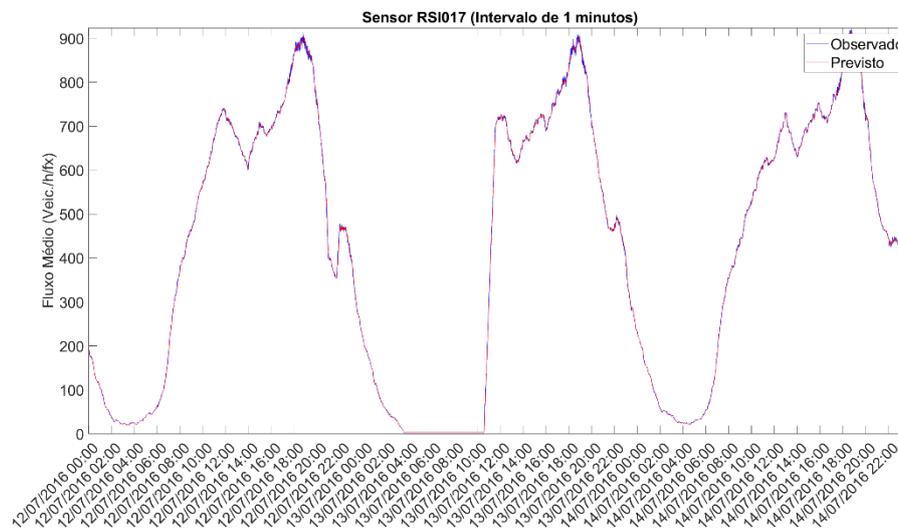


Figura 5.9: Exemplos de resultados diários para as previsões de fluxos de tráfego em intervalos de 1 minuto para a aproximação do sensor RSI017 na interseção 289.

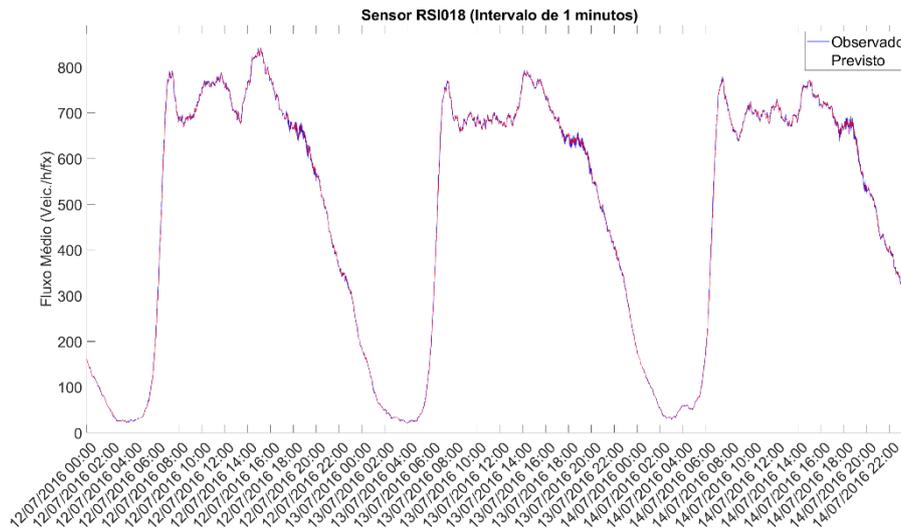


Figura 5.10: Exemplos de resultados diários para as previsões de fluxos de tráfego em intervalos de 1 minuto para a aproximação do sensor RSI018 na interseção 289.

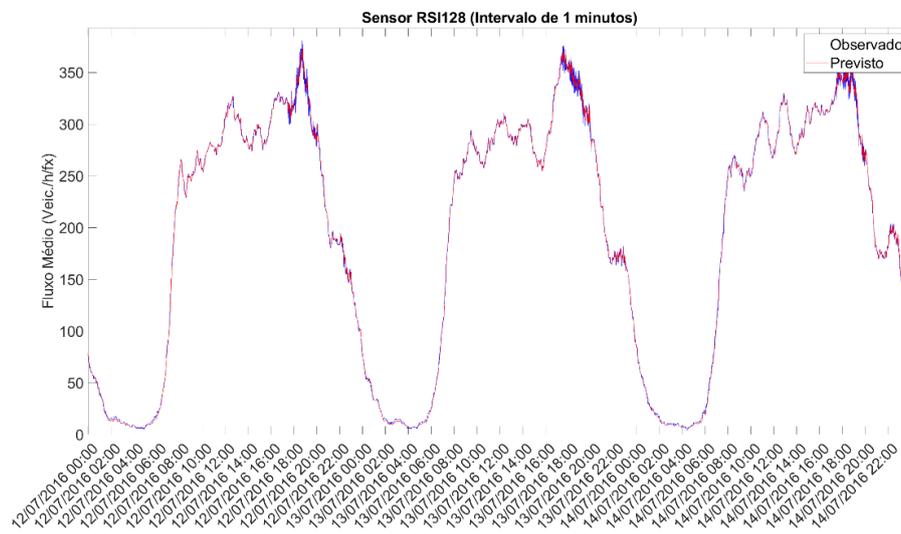


Figura 5.11: Exemplos de resultados diários para as previsões de fluxos de tráfego em intervalos de 1 minuto para a aproximação do sensor RSI128 na interseção 289.

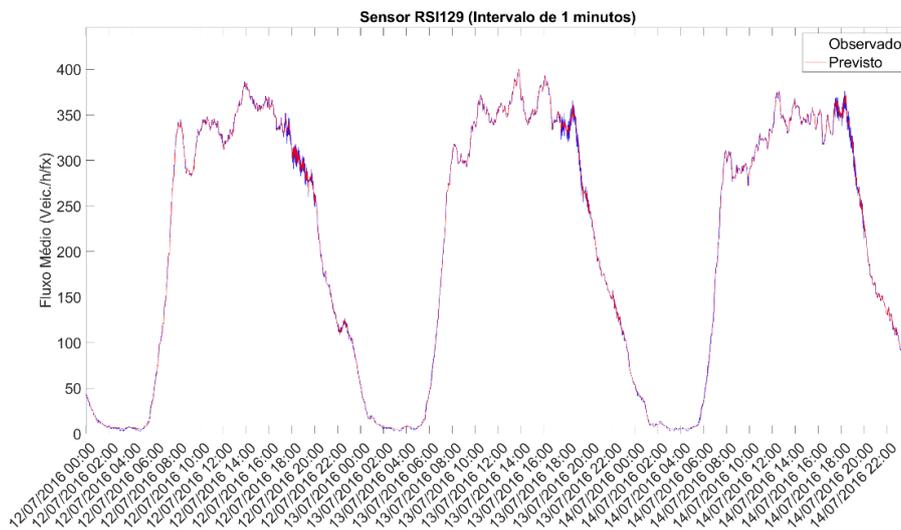


Figura 5.12: Exemplos de resultados diários para as previsões de fluxos de tráfego em intervalos de 1 minuto para a aproximação do sensor RSI129 na interseção 289.

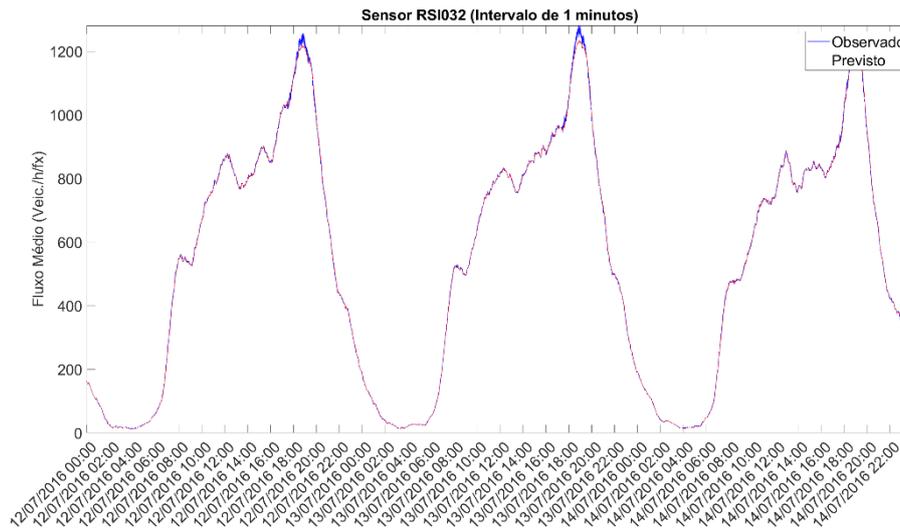


Figura 5.13: Exemplos de resultados diários para as previsões de fluxos de tráfego em intervalos de 1 minuto para a aproximação do sensor RSI032 na interseção 353.

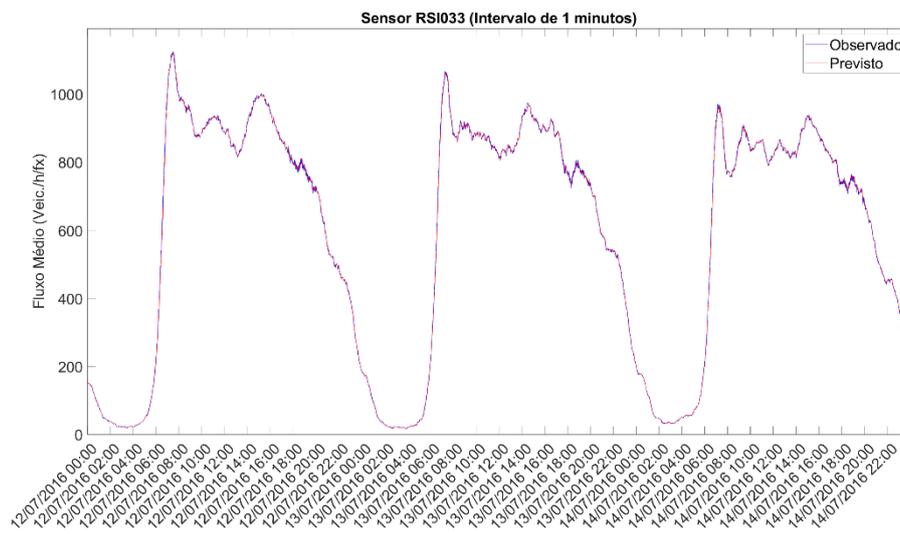


Figura 5.14: Exemplos de resultados diários para as previsões de fluxos de tráfego em intervalos de 1 minuto para a aproximação do sensor RSI033 na interseção 353.

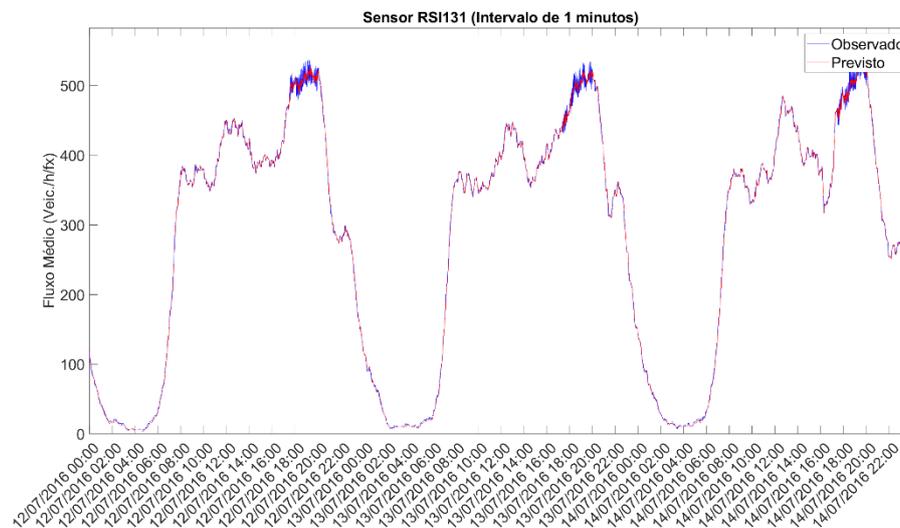


Figura 5.15: Exemplos de resultados diários para as previsões de fluxos de tráfego em intervalos de 1 minuto para a aproximação do sensor RSI131 na interseção 353.

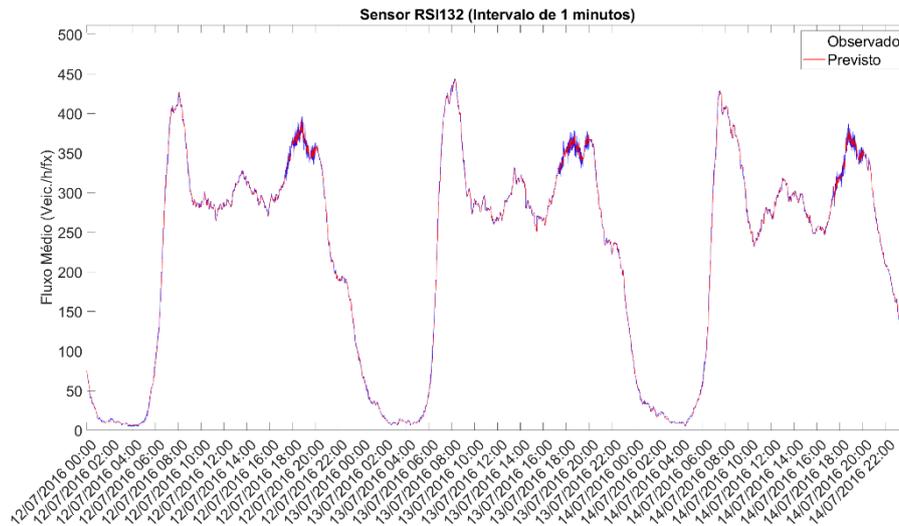


Figura 5.16: Exemplos de resultados diários para as previsões de fluxos de tráfego em intervalos de 1 minuto para a aproximação do sensor RSI132 na interseção 353

Além das comparações gráficas dos fluxos previstos e observados feitas acima desde a Figura 5.1, os gráficos da Figura 5.17 a Figura 5.19 abaixo exemplificam e relacionam os erros absolutos e relativos dos fluxos previstos e observados para os intervalos de 15 minutos, 5 minutos e 1 minuto para o sensor RSI033, respectivamente. Assim, é possível observar que os erros absolutos (diferenças entre fluxos observados e previstos) são maiores nas previsões de fluxos elevados enquanto os erros relativos (relações entre erros absolutos e fluxos observados) são mais baixos. No caso dos fluxos baixos, essa relação se inverte. Esses gráficos apresentam também os valores dos 1º, 2º e 3º quartis dos erros absolutos para destacar a concentração de 50% desses erros com valores bem baixos.

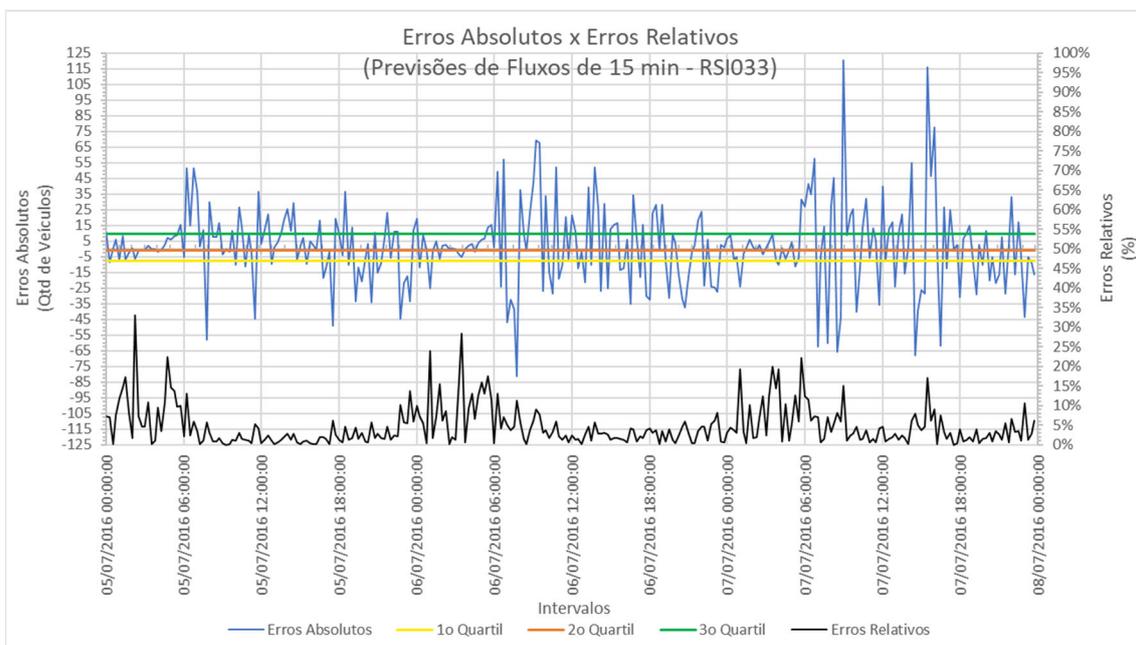


Figura 5.17: Erros absolutos e erros relativos das previsões de fluxos de 15 minutos (RSI033).

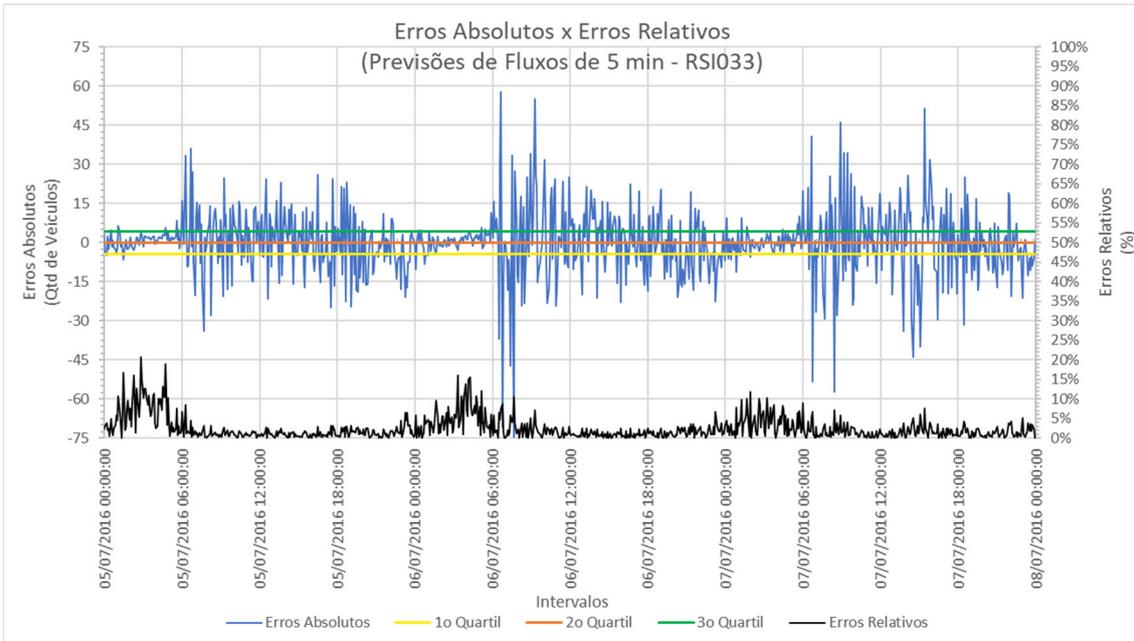


Figura 5.18: Erros absolutos e erros relativos das previsões de fluxos de 5 minutos (RSI033).

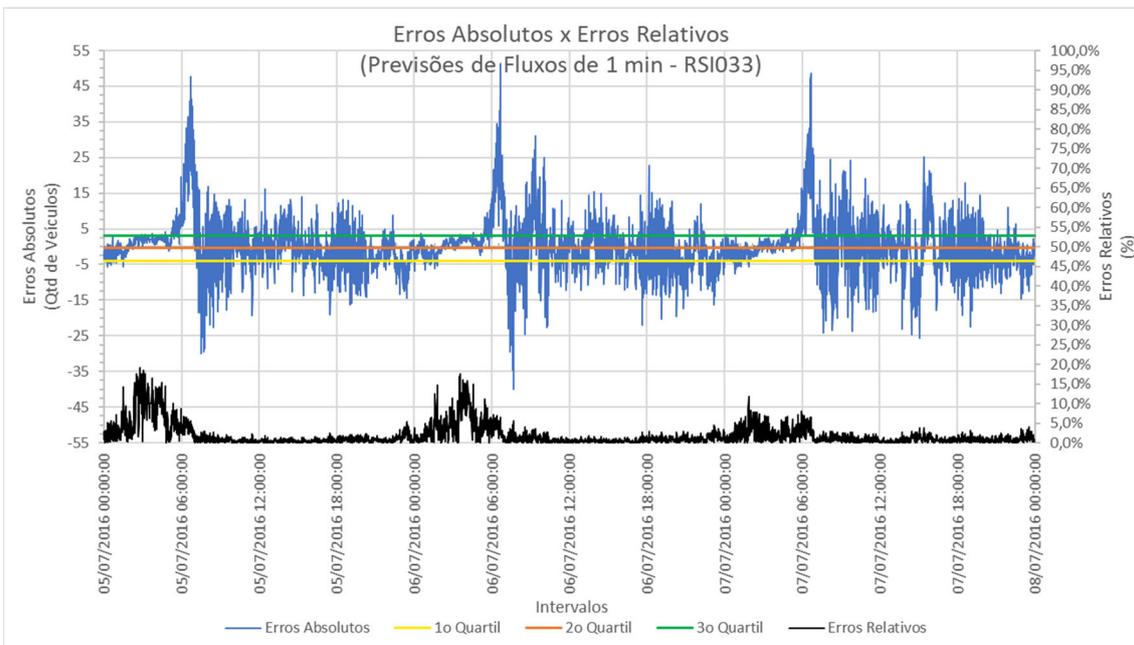


Figura 5.19: Erros absolutos e erros relativos das previsões de fluxos de 1 minuto (RSI033).

Depois, ainda com o propósito de avaliar a precisão do modelo, os erros médios absoluto (MAE em inglês), relativo (MRE em inglês) e a quadrático (RMSE em inglês) das suas previsões foram calculados e comparados com os resultados da bibliografia que apoiou este módulo. Yisheng *et al.* (2015) utilizaram dados reais para fazer as previsões de fluxos de 15 minutos e as grandezas desses dados são compatíveis com as grandezas dos fluxos empregados no presente trabalho, cujos patamares estão próximos à 250, 600, 900 e 1.200

veículos/hora/faixa, conforme a aproximação abordada. Nesse sentido, a Tabela 5.1 apresenta uma relação que valida a precisão do modelo deste trabalho em relação do modelo de Yisheng *et al.* (2015), especialmente no que tange ao MRE e RMSE.

Tabela 5.1: Comparativo entre os erros associados às previsões da literatura e deste trabalho

Previsão de Fluxo de tráfego a cada 15 minutos	MAE	MRE	RMSE
Yisheng <i>et al.</i> (2015)	34,1	6,75%	50,0
Deste trabalho	12,1	7,5%	18,0

Como este trabalho foi além das previsões de 15 minutos, realizando também previsões para 5 minutos e 1 minuto, a Tabela 5.2 abaixo destaca os erros associados às respectivas previsões. Cabe observar que todos os erros decresceram na medida em que os intervalos de previsão foram reduzidos desde o intervalo de 15 minutos com um erro médio absoluto de 12,1 até 3,4 para o intervalo de 1 minuto.

Tabela 5.2: Comparativo entre os erros associados às previsões de tráfego deste trabalho para outros intervalos de previsão

Intervalo das Previsões de Fluxo de tráfego	MAE	MRE	RMSE
5 minutos	6,3	3,73%	9,2
1 minutos	3,4	2,43%	5,2

Como essa redução dos erros se deve à aproximação cada vez maior entre as previsões e os dados reais de entrada, na medida em que os intervalos de previsão foram reduzidos, atribui-se essa aproximação cada vez maior entre entradas e resultados à precisão e aderência do modelo às condições propostas. Ademais, os fluxos previstos a cada 1 minuto são mais detalhados do que os fluxos previstos a cada 15 minutos. Então, a combinação de dados de entrada mais detalhados e um modelo preciso e aderente conduzem às melhores previsões.

Na sequência, o modelo para controle da rede de tráfego urbana em tempo real produziu planos semafóricos inteligentes com o objetivo de se adaptarem às condições reais da demanda provocada pelos fluxos de tráfego presentes nas aproximações das interseções da rede. Como exemplo, a Tabela 5.3 descreve parcialmente o plano semafórico inteligente resultante por meio de um extrato das ações tomadas pelo modelo entre as 06:35h e 06:39h para três dias úteis de trabalho no meio do mês de junho de 2016.

A referida tabela permite ressaltar que as ações são decididas a cada 10 segundos com um intervalo mínimo de 30 segundos para que elas sejam efetivamente adotadas. É possível perceber também que não existe uma regularidade entre as decisões tomadas em horários iguais entre dias consecutivos, tampouco em um mesmo dia, ainda que elas sejam tomadas em horários imediatamente sucessivos. Além disso, observa-se que decisões diferentes são tomadas para controlar interseções diferentes.

Ainda, na Tabela 5.3, “True” e “False” significam sinais verde e vermelho, respectivamente. E se referem aos semáforos da via arterial. Os sinais dos semáforos das vias coletoras que completam cada interseção operam com os sinais contrários, ou seja, se o sinal da via arterial é “True”, o sinal da via coletora é “False”. Contudo, a maximização do fluxo que rege a otimização considera a melhor solução para todas as vias da rede.

Continuando, foi preciso avaliar se os planos semaforicos inteligentes que resultaram da metodologia proposta por esse trabalho cumpriam o objetivo de se adaptarem às condições reais da demanda provocada pelos fluxos de tráfego. Por isso, como destacado anteriormente, esses planos foram empregados em micro simulações para controlar os fluxos de tráfegos coletados na rede deste estudo. A mesma quantidade de micro simulações foi realizada substituindo apenas os planos semaforicos inteligentes pelos planos semaforicos pré-existentes. Em cada micro simulação, o VISSIM acompanhou e mediu parâmetros de desempenho da rede, filas e atrasos. O Apêndice B descreve como os planos semaforicos foram modelados e implementados no VISSIM. A Tabela 5.4 destaca dois dos parâmetros de desempenho da rede, que são o atraso médio e a velocidade média, como exemplos.

Para fins de validação e apresentação desses resultados, também foram realizadas simulações com os planos semaforicos originais do departamento de trânsito local e gerados os mesmos parâmetros de desempenho da rede de tráfego. Posteriormente, os resultados dos dois casos, plano semaforico proposto e plano semaforico original, foram comparados em relação aos mesmos parâmetros de desempenho simulados.

Assim, a Tabela 5.5 e a Tabela 5.6 apresentam os percentuais de melhoria desses parâmetros medidos pelo simulador a partir da razão entre os resultados alcançados pelo modelo deste trabalho que é baseado em aprendizado por reforço profundo e o método do Sistema Progressivo ou Sincronizado, conhecido como Onda Verde, usado pelo órgão de trânsito local.

Tabela 5.3: Extrato do plano semaforizado otimizado para toda a rede no sentido da via arterial.

Interseção	353	289	353	289	353	289
Tempo	14/06/2016		15/06/2016		16/06/2016	
06:35:19	True	False	True	False	False	True
06:35:29	True	False	False	True	False	True
06:35:39	False	True	False	True	False	True
06:35:49	False	True	False	True	True	True
06:35:59	False	True	True	True	True	True
06:36:09	True	False	True	True	True	True
06:36:19	True	False	True	True	False	True
06:36:29	True	False	False	True	False	True
06:36:39	False	True	False	True	False	True
06:36:49	False	True	False	True	True	False
06:36:59	False	True	True	True	True	False
06:37:09	True	True	True	True	True	False
06:37:19	True	True	True	True	True	False
06:37:29	True	True	True	True	True	False
06:37:39	True	True	True	True	False	True
06:37:49	True	True	False	True	False	True
06:37:59	True	True	False	True	False	True
06:38:09	False	True	False	True	True	False
06:38:19	False	True	True	False	True	False
06:38:29	False	True	True	False	True	False
06:38:39	True	False	True	False	False	True
06:38:49	True	False	False	True	False	True
06:38:59	True	False	False	True	False	True

Tabela 5.4: Parâmetros de desempenho da rede obtidos por controle de tráfego com o plano semaforizado inteligente, conforme micro simulações

PARÂMETROS	ATRASSO MÉDIO	VELOCIDADE MÉDIA	ATRASSO MÉDIO	VELOCIDADE MÉDIA
INTERVALOS	18/05/2016		15/06/2016	
0 - 300s	16,52 s/veic.	41,35 km/h	17,05 s/veic.	41,18 km/h
300s - 600s	17,32 s/veic.	40,49 km/h	19,37 s/veic.	39,50 km/h
600s - 900s	14,28 s/veic.	42,24 km/h	18,37 s/veic.	40,41 km/h
900s - 1200s	23,13 s/veic.	37,93 km/h	22,82 s/veic.	38,21 km/h
1200s - 1500s	19,93 s/veic.	39,76 km/h	20,65 s/veic.	39,23 km/h
1500s - 1800s	22,01 s/veic.	37,84 km/h	26,05 s/veic.	36,63 km/h
1800s - 2100s	21,33 s/veic.	38,73 km/h	20,13 s/veic.	39,17 km/h
2100s - 2400s	34,72 s/veic.	32,74 km/h	32,49 s/veic.	33,91 km/h
2400s - 2700s	30,72 s/veic.	34,21 km/h	29,49 s/veic.	35,16 km/h
2700s - 3000s	33,08 s/veic.	33,42 km/h	34,52 s/veic.	33,51 km/h
3000s - 3300s	28,19 s/veic.	35,44 km/h	28,41 s/veic.	35,15 km/h
3300s - 3600s	31,56 s/veic.	34,17 km/h	33,74 s/veic.	33,39 km/h

Os percentuais de melhorias dos parâmetros que foram gerados por meio da metodologia desenvolvida neste trabalho devem ser interpretados como adequados sempre que aumentem as velocidades médias na rede ou diminuam os demais parâmetros registrados, incluindo: o atraso médio na rede e os comprimentos de filas nas aproximações dos semáforos.

Nesse sentido, os percentuais negativos representam redução e os positivos aumento da razão entre os parâmetros. Quando esses percentuais estiverem grafados com a cor azul ou vermelha serão respectivamente adequados ou inadequados de acordo com o comportamento desejado para o parâmetro.

Tabela 5.5: Melhorias obtidas pelos planos semafóricos adaptados em relação aos planos pré-existentes, conforme os resultados das simulações realizadas entre as 06:00 e 07:00h.

PARÂMETROS	SIMULAÇÕES						
	17/05/2016	18/05/2016	19/05/2016	14/06/2016	15/06/2016	16/06/2016	Média
PERFORMANCE DA REDE							
ATRASSO MÉDIO	-34,39%	-20,59%	-32,32%	-26,69%	-28,46%	-27,94%	-28,40%
ATRASSO TOTAL	-35,03%	-19,23%	-30,90%	-29,01%	-27,42%	-28,67%	-28,38%
VELOCIDADE MÉDIA	11,11%	6,78%	10,48%	8,54%	9,96%	9,45%	9,39%
TEMPO TOTAL DE VIAGENS	-13,58%	-6,78%	-11,33%	-11,35%	-10,84%	-10,58%	-10,74%
TOTAL DE VEÍCULOS NA REDE	-16,67%	-9,49%	-12,39%	-15,65%	-15,74%	-16,31%	-14,37%
FILAS							
COMPRIMENTO DE FILA	-54,36%	-25,79%	-42,44%	-46,95%	-42,27%	-43,19%	-42,50%
COMPRIMENTO DE FILA MÁXIMO	-40,20%	-21,65%	-34,44%	-40,16%	-33,29%	-37,70%	-34,57%

Tabela 5.6: Melhorias obtidas pelos planos semafóricos adaptados em relação aos planos pré-existentes, conforme os resultados das simulações realizadas entre as 07:00 e 08:00h

PARÂMETROS	SIMULAÇÕES						
	17/05/2016	18/05/2016	19/05/2016	14/06/2016	15/06/2016	16/06/2016	Média
PERFORMANCE DA REDE							
ATRASSO MÉDIO	-31,14%	-19,52%	-31,43%	-30,95%	-22,28%	-35,08%	-28,40%
ATRASSO TOTAL	-32,84%	-20,26%	-34,18%	-33,68%	-23,05%	-36,81%	-30,14%
VELOCIDADE MÉDIA	8,70%	5,70%	8,82%	9,07%	5,85%	9,82%	8,00%
TEMPO TOTAL DE VIAGENS	-10,15%	-5,91%	-9,83%	-9,48%	-7,59%	-10,50%	-8,91%
TOTAL DE VEÍCULOS NA REDE	-12,49%	-6,84%	-10,17%	-10,62%	-5,70%	-10,11%	-9,32%
FILAS							
COMPRIMENTO DE FILA	-41,02%	-26,22%	-42,20%	-41,44%	-30,71%	-45,81%	-37,90%
COMPRIMENTO DE FILA MÁXIMO	-32,69%	-23,78%	-30,35%	-29,94%	-22,63%	-35,14%	-29,09%

Cabe salientar que as médias das simulações apontam reduções da ordem de 28% para os atrasos na rede, bem como um aumento maior do que 9% na velocidade média na rede. Os comprimentos de filas foram reduzidos mais do que 42% e os comprimentos de fila máximos mais do que 34%. As simulações realizadas entre as 07:00h e 08:00h obtiveram resultados levemente menores em relação àqueles obtidos antes no intervalo entre as 06:00h e 07:00h. As exceções são o atraso total na rede e o atraso médio que superam os resultados anteriores. No entanto, as ordens de grandezas dos percentuais de redução ou aumento são semelhantes nos dois intervalos.

A Figura 5.20 compara os atrasos médios da rede, simulados a partir do plano semafórico do órgão de trânsito local e dos planos semafóricos inteligentes produzido pelo modelo proposto neste trabalho.

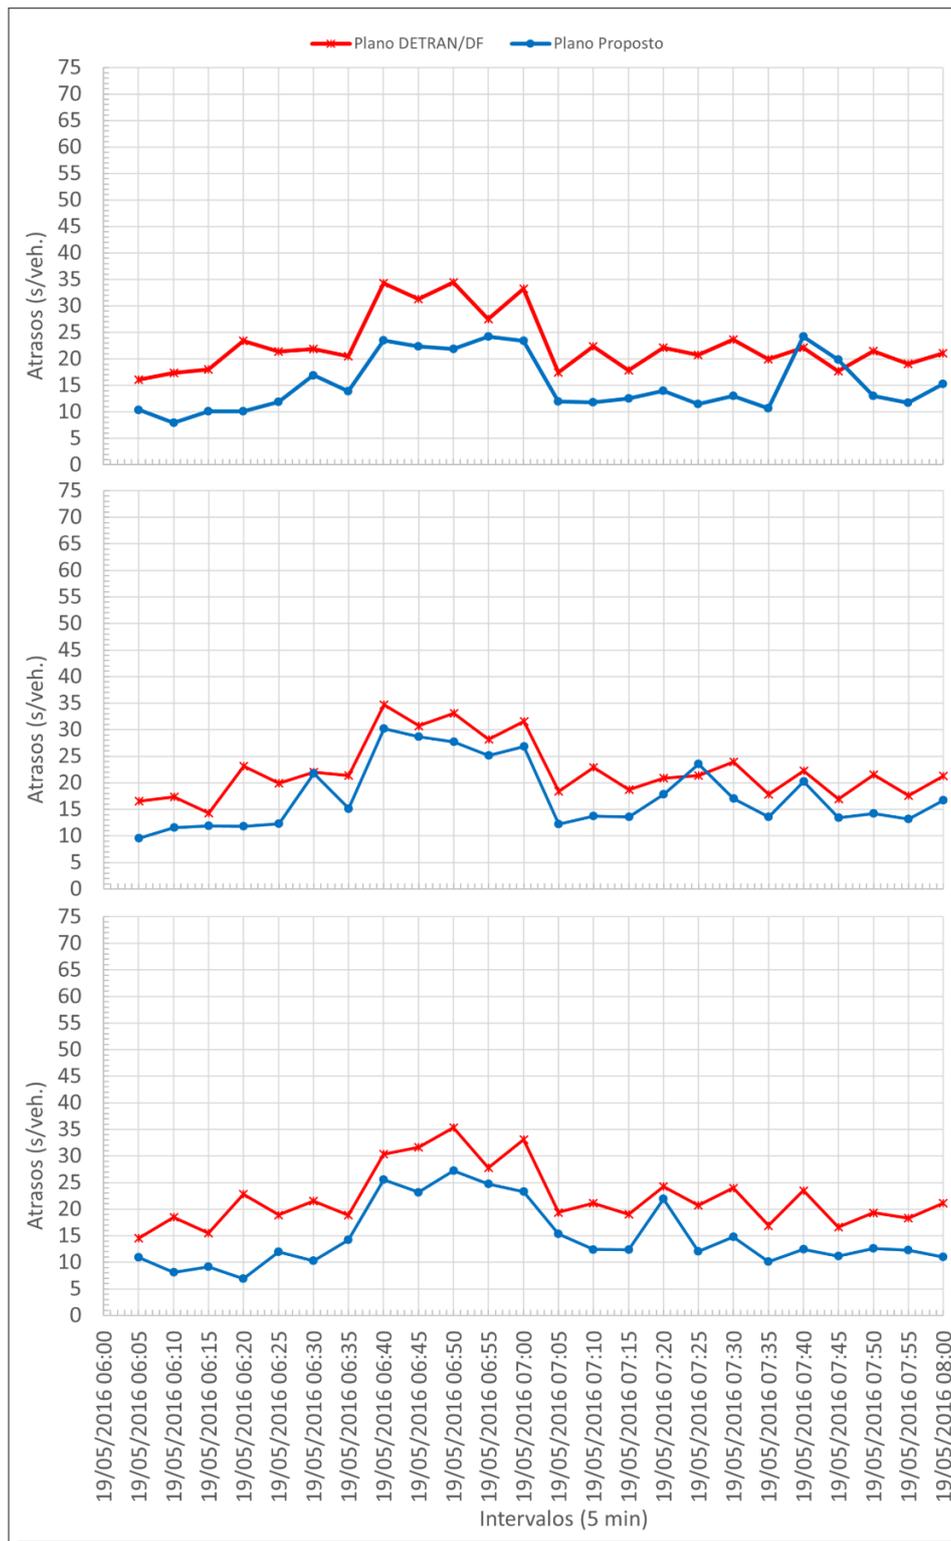


Figura 5.20: Comparação entre os atrasos médios na rede resultantes dos planos semafóricos definidos pelo DETRAN/DF e os planos baseados em inteligência artificial propostos nesta tese.

Na figura acima, observa-se que ocorreram 3 (três) atrasos do modelo proposto maiores do que aqueles simulados com os dados do DETRAN/DF. Então, a partir do banco de dados de fluxos coletados, encontrou-se aumentos pontuais e abruptos nessas medidas para as vias coletoras exatamente no dia 17 de maio de 2016, às 7:40h e 7:45h. Por isso,

para maximizar o fluxo da rede, o modelo diminuiu o tempo de verde na via arterial e, conseqüentemente, o atraso médio da rede aumentou.

O mesmo ocorreu no dia 18 de maio de 2016 às 7:25h da manhã, quando houve um aumento súbito e pontual dos fluxos na via coletora. Além disso, ao analisar em detalhes o conjunto de dados, foi mostrado que um dos sensores, o RSI017, falhou às 7:40h do dia 17 de maio de 2016, e não registrou nenhum fluxo naquele momento. Este fato certamente afetou ainda mais o resultado do modelo uma vez que o algoritmo considerou um fluxo 0 (zero) para aquele sensor e a outra decisão foi tomada imediatamente depois às 07:45h.

É importante comparar também os resultados obtidos neste trabalho com outras aplicações, como, por exemplo, com os principais sistemas adaptativos de controle de tráfego em tempo real em uso nos EUA (ZHAO e TIAN, 2012). A Tabela 5.7 apresenta estas comparações e, ao analisar os seus dados, pode-se ver que o modelo proposto atinge resultados bastante razoáveis quando comparado com os outros modelos. Em particular, os atrasos avaliados pelo modelo desenvolvido neste trabalho foram muito bons, variando de -36,8% a -19,2%.

Estudos adicionais devem avaliar formas de melhorar os intervalos das paradas obtidas, ainda que os resultados de quantidades de paradas obtidos pelo modelo proposto tenham sido bastante similares com o do SCATS, de acordo com a coluna Paradas da Tabela 5.7. Talvez, seja adequada uma análise de sensibilidade do modelo para as variáveis tempo mínimo de uma fase, tamanho do minilote de treinamento e quantidade de episódios.

Tabela 5.7: Comparações entre os desempenhos do modelo proposto e dos principais sistemas de controle de tráfego adaptativo em uso nos EUA.

Sistemas de Controle Adaptativo de Tráfego	Desempenho		
	Tempo de Viagem	Atrasos	Paradas
Modelo Proposto	- 13,6% a - 5,9%	- 36,8% a - 19,2%	- 26,1% a +9,3%
SCOOTs	- 29,0% a - 5,0%	- 28,0% a - 2,0%	- 32,0% a - 17,0%
SCATS	- 20,0% a - 0%	- 19,0% a +3,0%	- 24,0% a +5,0%
OPAC	- 26,0% a +10,0%	-	- 55,0% a 0%
RHODES	- 7,0% a +4,0%	- 19,0% a - 2,0%	-
ACS	- 12,0% a +7,0%	- 38,0% a +2,0%	- 35,0% a - 28,0%

Ainda, é importante observar os comportamentos dos fluxos de tráfego durante os planos semafóricos propostos por este trabalho em relação ao plano do departamento de trânsito local. A Figura 5.21 e Figura 5.22 a permitem observar essa relação. Como o modelo deste trabalho gera ciclos semafóricos variáveis, o ciclo semafórico do departamento de

trânsito local foi adotado como referência para fins de comparação no mesmo período. Enquanto a Figura 5.22 Figura 5.21 apresenta uma comparação da evolução dos fluxos na via arterial de acordo com os ciclos de cada interseção: 353 (RSI032 + RSI033) e 289 (RSI017 + RSI018), Figura 5.22 estabelece a comparação entre as vias arterial e coletora de uma mesma interseção (289).

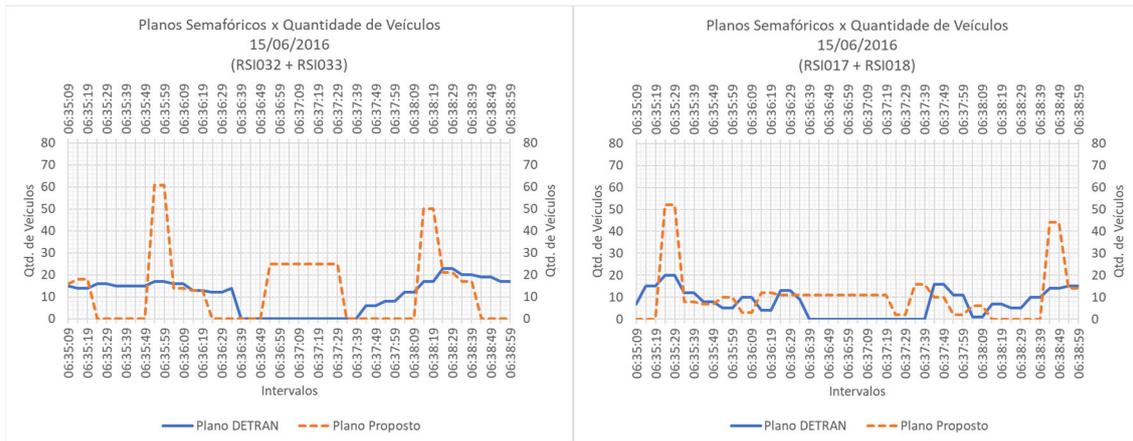


Figura 5.21: Comparação entre as quantidades de veículos e os ciclos dos planos semafóricos propostos e do DETRAN para a via arterial nas duas interseções.

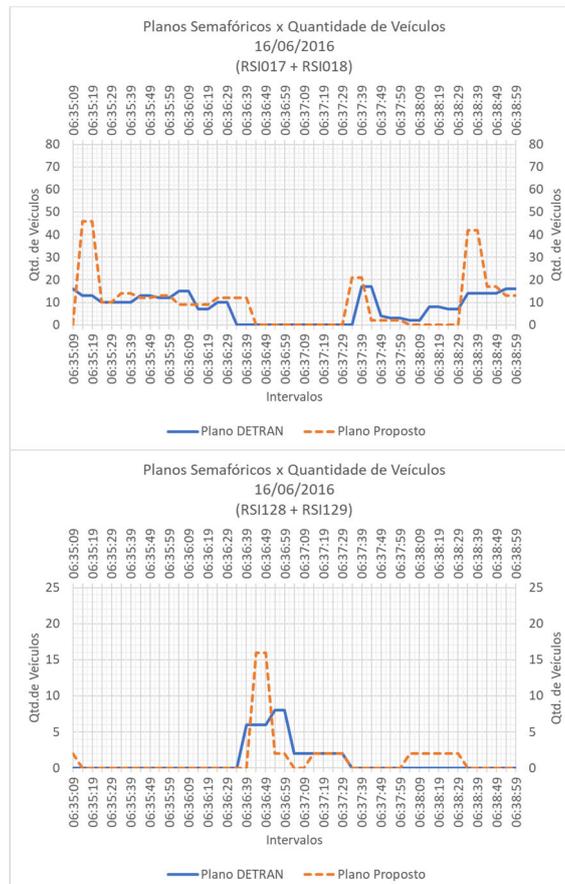


Figura 5.22: Comparação entre as quantidades de veículos e os ciclos dos planos semafóricos propostos e do DETRAN para as vias arterial e coletora de uma mesma interseção.

Além de ciclos variáveis e diferentes para cada interseção, os ciclos dos planos propostos aumentaram os fluxos dentro do mesmo tempo de ciclo do DETRAN. De acordo com a Figura 5.21, o fluxo cresceu 29% e 33% na via arterial nas duas interseções e, pela Figura 5.22, o aumento foi de 32% na via arterial e 28% na via coletora na interseção 289.

Então, a fim de agregar valor à análise dos resultados alcançados e considerando que a recompensa pelas ações integrou duas parcelas, sendo uma local que é referente à otimização dos fluxos nas interseções e outra interlocal referente também à otimização dos fluxos entre as interseções, buscou-se avaliar todos os resultados obtidos de uma variável para a rede e suas interseções, até o nível das aproximações. Nesse sentido, o comprimento de fila foi escolhido com variável para apresentar os resultados desta abordagem.

Por isso, as razões entre os resultados das simulações dos planos semaforicos proposto (inteligente) e pré-existente (do DETRAN) foram calculadas de forma que as variações se referem sempre aos resultados do plano pré-existente. Assim, os percentuais de variações negativas significam melhorias no desempenho da rede em relação aos comprimentos de filas, pois, nesse caso, esses percentuais indicam uma redução dos comprimentos de filas proporcionada pelo plano do modelo em relação à condição pré-existente. Por outro lado, os percentuais de variação positivos importam em aumento dos comprimentos de filas do modelo.

A Figura 5.23 e a Figura 5.24 apresentam respectivamente as correlações para a rede e cada uma das interseções. Essas correlações utilizam dados com intervalos de 5 minutos entre as 06:00 e 07:00h e 07:00 e 08:00h e foram feitas tanto para os comprimentos de filas – QLEN – quanto para os comprimentos de filas máximos – QLENMAX – conforme essas variáveis são denominadas pelo VISSIM. Nessas figuras, é possível identificar agrupamentos de pontos sobre os percentuais negativos (azuis) que demonstram redução dos comprimentos de filas e as áreas desses agrupamentos foram destacadas na cor amarela.

Vale destacar ainda que as regressões lineares ajustadas às correlações apresentam coeficientes angulares negativos, ou seja, a aplicação do modelo tende a proporcionar uma redução dos comprimentos de filas quando os fluxos aumentam, ainda que a regressão linear não ofereça o melhor ajuste aos pares das correlações.

Portanto, os percentuais adotados para expressar as variações dos comprimentos de filas foram correlacionados com os respectivos fluxos de tráfego em cada uma das aproximações que compõem as interseções da rede, permitindo observar que as nuvens de pontos das correlações se agrupam mais sobre as variações negativas (azuis) de comprimentos de filas para todo o espectro de fluxos e, por isso, existem mais ganhos do que perdas. Além disso, os coeficientes angulares negativos das regressões lineares indicam uma tendência de aumento dos ganhos do modelo na medida em que os fluxos também aumentam.

Aqui, é importante explicar que, embora a variável otimizada pelo modelo tenha sido o fluxo de tráfego, ao longo deste trabalho também foram apresentadas as melhorias da rede em relação a outras variáveis: atrasos, tempo de viagem e quantidade de paradas, como consequências da otimização dos fluxos. Portanto, os objetivos dessa correlação foram agregar a avaliação de mais uma variável como resultado e, apesar do grande agrupamento de pontos sobre os valores negativos (azuis) do eixo horizontal, facilitar a visualização de que existe uma tendência de redução dos comprimentos de filas em todos os espectros de fluxos, desde os mais baixos até os mais altos.

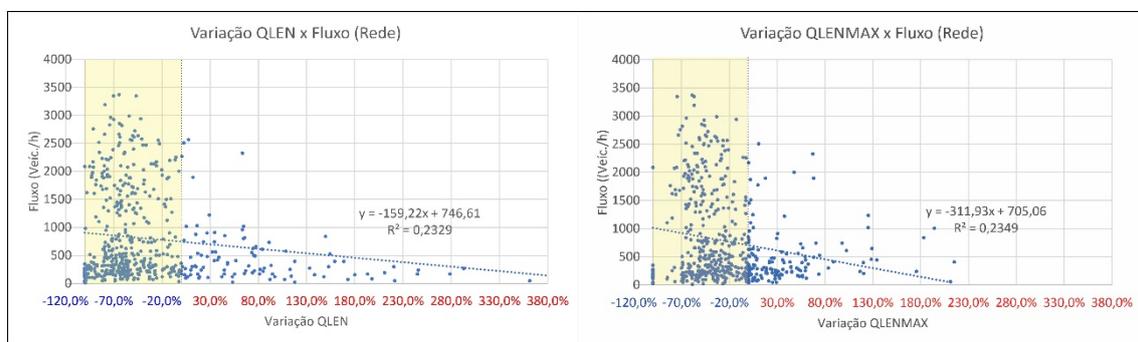


Figura 5.23: Correlações entre os fluxos de tráfego e as variações dos comprimentos de filas (QLEN) e comprimentos de filas máximos (QLENMAX) resultantes do modelo, considerando toda a rede de trânsito.

Um procedimento análogo foi aplicado posteriormente para cada aproximação. As interseções foram discretizadas para apresentar os comportamentos resultantes dos comprimentos de filas em cada uma de suas aproximações. A Figura 5.25 e a Figura 5.26 destacam as correlações dos comprimentos de fila com o fluxo para as aproximações que se conectam em cada interseção.

Isolando-se os resultados das aproximações, identificadas nos gráficos pelos códigos de seus detectores de laços indutivos, observa-se por meio dos coeficientes angulares das regressões que, na direção dos fluxos predominantes que coincide com a via arterial, as

aproximações semaforizadas no sentido de maior demanda do tráfego (RSI018 e RSI033) tendem a predominar sobre as aproximações nos sentidos opostos que são menos solicitadas pelo tráfego de veículos. As grandezas negativas dos coeficientes angulares das correlações dos sensores RSI018 e RSI033 representam a preponderância deles em relação aos coeficientes angulares bem menores ou positivos.

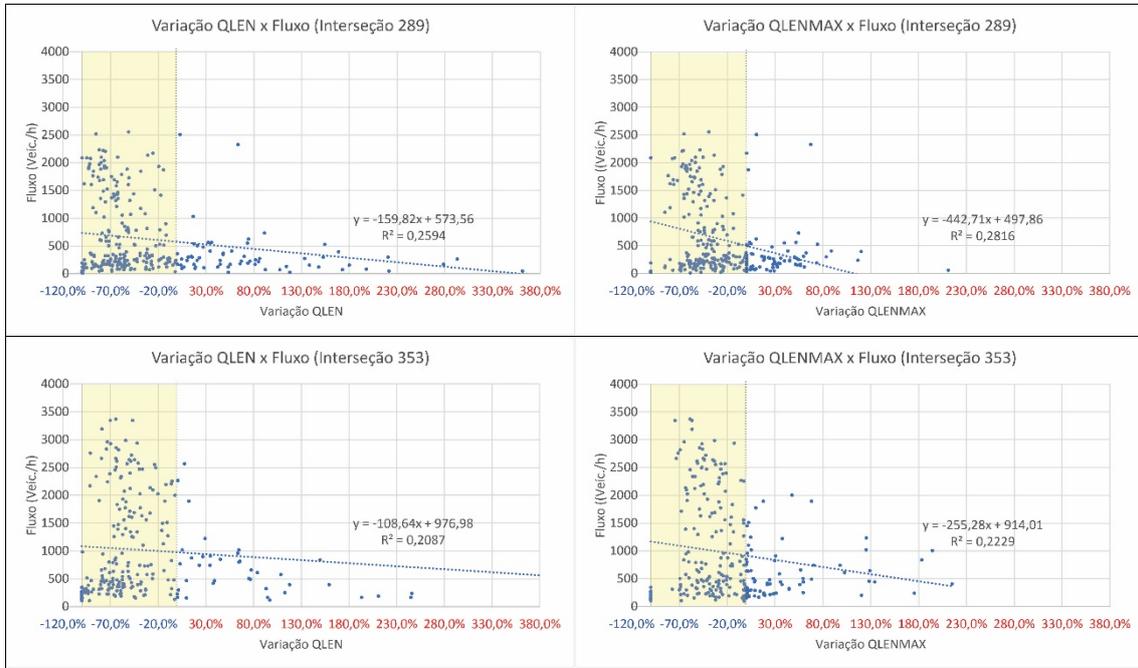


Figura 5.24: Correlações entre os fluxos de tráfego e as variações dos comprimentos de filas (QLEN) e comprimentos de filas máximos (QLENMAX) resultantes do modelo, considerando os resultados obtidos para toda a rede de trânsito.

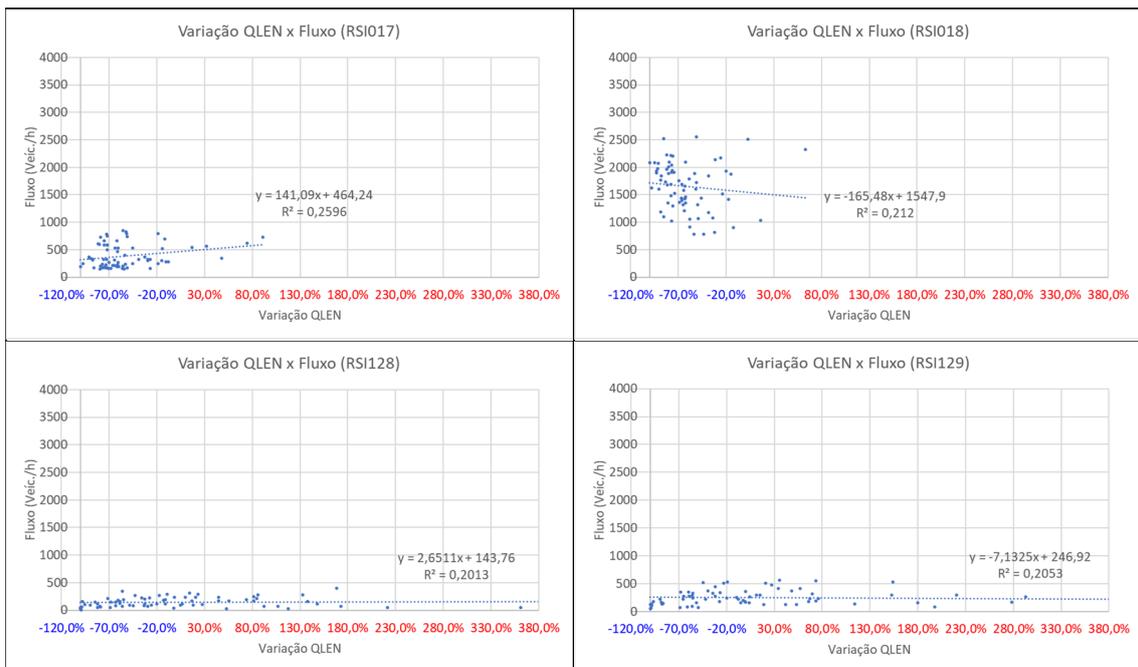


Figura 5.25: Correlações entre os fluxos de tráfego e as variações dos comprimentos de filas (QLEN) a partir dos resultados do modelo para as aproximações da interseção 289.

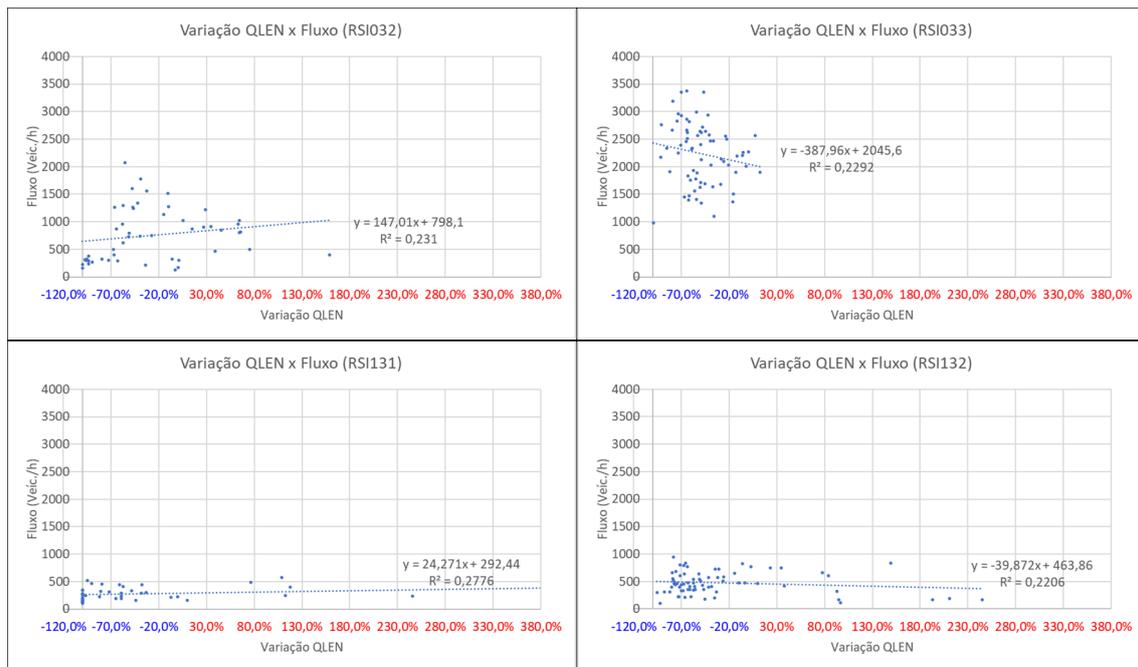


Figura 5.26: Correlações entre os fluxos de tráfego e as variações dos comprimentos de filas (QLEN) a partir dos resultados do modelo para as aproximações da interseção 353.

Conclui-se que, diante de fluxos mais elevados em um sentido, os respectivos comprimentos de filas tendem a diminuir enquanto os comprimentos de filas no sentido oposto são sacrificados na medida em que o método aceita reprimir os seus fluxos menores e, conseqüentemente, aumentar um pouco os comprimentos das filas nesse sentido. Na outra direção das interseções, sobre a qual as vias coletoras estão alinhadas, os fluxos são relevantemente inferiores. Portanto, o efeito do modelo é menor e percebe-se variações muito pequenas, ora a tendência é a redução ora o aumento dos comprimentos de filas.

6 CONCLUSÕES E RECOMENDAÇÕES

De acordo com a bibliografia consultada, as estratégias e os sistemas tradicionais para sincronizar uma série de semáforos e garantir que a maior quantidade possível de motoristas cruze uma sucessão de sinais verdes não atendem às condições dos horários de pico. Em parte, essas estratégias estão sujeitas às limitações dos seus modelos de tráfego e às dificuldades de parametrizar adequadamente suas programações, além da ausência de recursos mais avançados, principalmente em países em desenvolvimento como o Brasil.

Os sistemas comerciais de controle adaptativo de tráfego em tempo real como o SCOOT e o SCATS dependem fortemente dos seus modelos de tráfego. Além disso, não existe diferença entre o desempenho do SCOOT e o de uma estratégia de tempo fixo quando a utilização da via atinge aproximadamente 80% de sua capacidade máxima. E, como já foi destacado anteriormente, o SCATS depende de uma base de dados predeterminada com uma biblioteca de planos de duração de verdes e de defasagens para cada interseção, além de planos de defasagens e parâmetros de controle para cada subsistema que são selecionados de acordo com as condições de tráfego.

Além disso, a literatura corrente aponta em consenso que o tráfego urbano cresce além da capacidade dos estados ajustarem as suas infraestruturas viárias, principalmente porque não é possível aumentar a infraestrutura indefinidamente para atender à demanda desse crescimento, que também provoca problemas sanitários, ambientais e econômicos recorrentes. A literatura aponta também que o surgimento das cidades inteligentes vem ao encontro das soluções dessas questões com base em tecnologias e serviços de geração e comunicação de dados associadas a uma infraestrutura inteligente.

Portanto, é preciso modernizar a abordagem do controle de tráfego urbano para otimizar a infraestrutura disponível e subsidiar o desenvolvimento dos conceitos e tecnologias que suportarão as cidades inteligentes. Nesse contexto, este trabalho se apoiou no estado da arte para associar tecnologias avançadas de inteligência artificial e propor um modelo inteligente de controle adaptativo de tráfego urbano em tempo real suportado por dados básicos de fluxo de tráfego coletados por sensores comumente encontrados na maioria das cidades, inclusive em muitas cidades brasileiras com mais de 100.000 habitantes.

Este modelo é independente de parâmetros e de modelos de simulação de tráfego. Basicamente, ele aprende o comportamento da rede de tráfego, antecipa os fluxos em intervalos de curta duração e otimiza os planos semaforicos da rede de forma centralizada. A previsão dos fluxos é apoiada por *Reinforcement Learning* e a otimização dos planos semaforicos é apoiada por *Deep Reinforcement Learning*.

A primeira etapa do modelo baseada em *Reinforcement Learning* conseguiu aprender adequadamente o comportamento da rede de tráfego em todos os dias e horários para todas as aproximações da rede, abrangendo um espectro bastante amplo e elástico desde as menores medidas de fluxo até as mais altas de forma aderente às sucessivas variações do tráfego. As avaliações dos fluxos resultantes dessas previsões realizadas por meio das medidas dos erros absoluto médio (MAE), relativo médio (MRE) e quadrático médio (RMSE) demonstram a eficácia e eficiência das previsões, especialmente na medida em que os intervalos das previsões foram reduzidos.

Observa-se que o comportamento da rede de tráfego varia bastante ao longo do dia. Os fluxos de tráfego das aproximações monitoradas pelos sensores RSI128, RSI129, RSI131 e RSI132 são baixos enquanto os dos sensores RSI017, RSI018, RSI032 e RSI033 são altos. Nas aproximações dos sensores RSI033 e RSI132, os picos dos fluxos de tráfego ocorrem no início da manhã. Nas aproximações dos sensores RSI017, RSI128, RSI032 e RSI131, os picos ocorrem no início da noite. Nas demais aproximações (RSI018 e RSI128), o comportamento é mais difuso embora os picos de fluxo ocorram no período da tarde.

Portanto, essa alternância de comportamentos e os valores das medidas de erros demonstram uma boa performance da generalização do modelo e das suas previsões, afastando a possibilidade de *underfitting* e *overfitting*. O ajuste bem aderente do aprendizado aos dados de treinamento ou calibração e da previsão aos dados de teste ou validação possuem erros baixos, sendo consistentes apesar da variação do comportamento.

A segunda etapa do modelo, baseado em aprendizado por reforço profundo, proposto por este trabalho guarda semelhanças com o trabalho de Li *et al.*, 2016. Entretanto, a introdução de uma nova expressão para o cálculo da recompensa total e o emprego do fluxo de tráfego como o seu parâmetro de maximização agregaram avanços consideráveis à forma

de controlar o tráfego urbano por meio de planos semaforicos adaptados às condições reais do fluxo.

Independentemente da dimensão observada, seja a rede, a interseção ou a aproximação, os resultados obtidos são bastante promissores. Todos os parâmetros da rede de trânsito sofreram redução pela aplicação do modelo proposto em relação à condição pré-existente. Em média, as velocidades médias na rede aumentaram 9%, os atrasos e os comprimentos de filas foram reduzidos mais do que 28% e 42% no período de maior demanda do tráfego, respectivamente. Nas situações em que a demanda provocada pelo tráfego era menor, os percentuais de melhoria também foram expressivos e bem próximos dos percentuais anteriores, demonstrando que a configuração definida para determinar a recompensa total agregou valor ao modelo proposto.

A observação dos gráficos das aproximações da via arterial, identificadas pelos códigos dos detectores RSI017, RSI018, RSI032 e RSI033, permite constatar que a abordagem proposta sacrifica os sentidos com menor demanda de tráfego (RSI017 e RSI032) com o aumento do comprimento de filas, a fim de melhorar a fluidez no sentido oposto, que possui fluxos de tráfego maiores (RSI018 e RSI033). Isto evita o aumento de filas nessas aproximações, melhorando o desempenho da rede diante de condições dinâmicas e reais. Além disso, a análise dos gráficos das aproximações das vias coletoras, identificadas pelos detectores RSI128, RSI129, RSI131 e RSI132, demonstra que esse comportamento de sacrifício e benefício entre sentidos de fluxos menores e maiores não ocorre somente diante de demandas de tráfego elevadas, pois ocorre também na presença de fluxos baixos.

Este modelo melhora então o desempenho da rede diante de um espectro amplo de fluxos de tráfego, independentemente da grandeza deles, porque demonstrou-se capaz de perceber e decidir tanto em níveis de fluxos de tráfego elevados quanto em níveis de fluxos baixos. Analisando estes mesmos resultados, as decisões tomadas por esta abordagem para privilegiar sentidos mais demandados não prejudicam os demais sentidos e garantem um aumento da performance das aproximações, isoladamente ou não.

A abordagem proposta por este trabalho independe de um modelo de tráfego como destacado acima e proporciona bons resultados diante de demandas maiores e menores sobre a rede de trânsito. Portanto, esta abordagem é capaz de perceber as variações do fluxo e

decidir qual direção ou sentido devem ser privilegiados em detrimento dos demais. Isto garante condições de tráfego melhores sem prejudicar qualquer um dos sentidos preteridos, beneficiando tanto as interseções quanto à rede para todos os parâmetros observados.

Além disso, o modelo proposto demonstrou a capacidade de responder adequadamente, controlando o tráfego mesmo na ausência de dados, como mostrado no registro das 7:40h da manhã de 17 de junho de 2016 (Figura 5.20). Como o algoritmo aplicado trata do controle de tráfego em tempo real, é possível assumir que alguns sensores possam falhar em um determinado momento. Portanto, mais pesquisas devem ser realizadas tentando mitigar estas possíveis falhas dos sensores ao aplicar a ferramenta desenvolvida.

Certamente, o emprego de dados coletados no campo agregou realidade à aplicação do modelo, o que é importante devido ao comportamento intrínseco aos eventos reais e à consistência dos resultados obtidos. Por exemplo, o modelo proposto demonstrou a capacidade de responder adequadamente, controlando o tráfego mesmo diante da ausência repentina e momentânea de dados, como mostrado no registro das 7:40h da manhã de 17 de junho de 2016 (Figura 5.20). Como o algoritmo aplicado trata do controle de tráfego em tempo real, é possível assumir que alguns sensores possam falhar em um determinado momento.

Como já foi citado, o modelo desenvolvido não depende de um modelo de tráfego nem de vários parâmetros de tráfego que precisam ser rotineiramente calibrados. Este modelo baseado em Aprendizado por Reforço e Aprendizado por Reforço Profundo utiliza dados reais para prever e definir o estado da rede apenas com dados de fluxo de tráfego, integrando duas interseções em uma rede de forma centralizada, o que ainda não havia sido feito por pesquisas anteriores, até onde a revisão bibliográfica sistematizada alcançou.

É preciso acrescentar que uma das principais contribuições deste trabalho é a simplicidade de implementar o seu modelo operacionalmente devido às tecnologias já disponíveis. Essas tecnologias permitem, além da contagem de veículos em tempo real, a disponibilidade imediata de dados para os diversos atores e entidades do sistema de trânsito, especialmente com o desenvolvimento de cidades inteligentes e dos veículos autônomos, que tornará a infraestrutura inteligente em uma realidade. Isso beneficiará muito os modelos baseados em Aprendizado por Reforço Profundo devido a sua simplicidade e sensibilidade diante de mudanças rápidas e inesperadas.

Finalmente, recomenda-se que outras pesquisas utilizando o *Reinforcement Learning* para produzir previsões de tráfego em intervalos de tempo ainda menores do que aqueles realizados neste trabalho sejam conduzidas porque não houve tempo hábil para ajustar o algoritmo desenvolvido aqui, tampouco para gerar e validar esses novos dados. Considerando os excelentes resultados obtidos, é provável que a diferença entre previsões sucessivas de tráfego de 1 minuto realizadas, por exemplo, a cada 10, 20 e 30 segundos produzam previsões consistentes para esses novos intervalos.

Ainda, seria muito interessante aplicar este novo modelo em um conjunto de dados maior sem tantas lacunas na série temporal, criticando os resultados alcançados em relação aos resultados obtidos com modelos de mercado. Por isso, recomenda-se que este método baseado em aprendizado por reforço profundo extrapole o ambiente de simulação e seja aplicado em uma rede experimental que requeira em princípio uma otimização, ou não. Para isto deve-se considerar principalmente a vasta disponibilidade de detectores de laços indutivos no Brasil ou em outros países e a facilidade que este modelo tem para usar dados reais e independentes da fonte de coleta. O avanço tecnológico também é importante, traduzido em especial pela capacidade de processamento computacional cada vez maior e mais acessível.

REFERÊNCIAS BIBLIOGRÁFICAS

ABDULHAI, B.; Pringle, R. e KARAKOULAS, G. J., Reinforcement Learning for True Adaptive Traffic Signal Control, *Journal of Transportation Engineering*, 129(3), pp.: 278-285, 2003.

ALAM, Javed; PANDEY, M. K. An integrated traffic light control system using RFID technology and fuzzy logic. *International Journal on Emerging Technologies, NCETST*, Issue 8, v. 1, p. 420-430, 2017.

ALSHIEKH, M., BLOEM, R., EHLERS, R., KÖNIGHOFER, B., NIEKUM, S., TOPCU, U. Safe reinforcement learning via shielding. In: *Thirty-Second AAAI Conference on Artificial Intelligence*. 2018.

ANDRADE, M. Estudos de elementos de controladores semafóricos fuzzy com aplicação para operação em rede aberta. Tese de doutorado, Publicação T.TD-002 A/2009, Departamento de Engenharia Civil e Ambiental, Faculdade de Tecnologia, Universidade de Brasília, DF, pp. 236, 2009.

ANDRADE, Michelle. Estudo para aprimoramento da operação de controladores semafóricos fuzzy. Dissertação de Mestrado, Publicação T.DM-012 A/2004, Departamento de Engenharia Civil, Faculdade de tecnologia, Universidade de Brasília, DF, pp. 137, 2004.

BAZZAN, A. L. C., A distributed approach for coordination of traffic signal agents. *Autonomous Agents and Multi-Agent Systems*, v. 10, n. 1, p. 131-164, 2005.

BEHZADAN, V., HSU, W. Analysis and improvement of adversarial training in DQN agents with adversarially-guided exploration (AGE). *arXiv preprint arXiv:1906.01119*, 2019.

BENGIO, Y.; GOODFELLOW, I.; COURVILLE, A. *Deep learning*. Massachusetts, USA: MIT press, 2017.

BHASKAR, L.; SAHAI, A.; SINHA, D.; VARSHNEY, G.; JAIN, T. Intelligent traffic light controller using inductive loops for vehicle detection. *Proceedings of 1st*

International Conference on Next Generation Computing Technologies, Dehradun, India, 4-5 September 2015; IEEE, 2015.

BONETTI JR, W.; PIETRANTONIO, H. Utilização de semáforos atuados pelo tráfego. Relatório Técnico, USP, setembro de 2001.

BOTVINICK, M., RITTER, S., WANG, J. X., KURTH-NELSON, Z., BLUNDELL, C., HASSABIS, D. Reinforcement learning, fast and slow. *Trends in cognitive sciences*, v. 23, n. 5, p. 408-422, 2019.

BRASIL. "Lei nº 9.503 de 23 de setembro de 1997. Institui o Código de Trânsito Brasileiro." (1997).

CAI, Chen; WONG, Chi Kwong; HEYDECKER, Benjamin G. Adaptive traffic signal control using approximate dynamic programming. *Transportation Research Part C: Emerging Technologies*, v. 17, n. 5, p. 456-474, 2009.

CHANG, Gang *et al.* A summary of short-term traffic flow forecasting methods. In: *ICCTP 2011: Towards Sustainable Transportation Systems*. 2011. p. 1696-1707.

CHANG, H. *et al.* Dynamic near-term traffic flow prediction: system oriented approach based on past experiences. *IET Intelligent Transport Systems*, v. 6, n. 3, p. 292-305, 2012.

CHEN, C., ZHANG, Chun-Yang. Data-intensive applications, challenges, techniques and technologies: A survey on Big Data. *Information Sciences*. 275. 314-347. 10.1016/j.ins.2014.01.015, 2014.

CHEN, Guo-hua; LIU, Qi-fei; LIAO, Xiao-lian. Traffic circle design based fuzzy control method. *Fuzzy Information and Engineering Volume 2*, p. 1621-1627, 2009.

CHEN, Shukai; SUN, Daniel Jian. An Improved Adaptive Signal Control Method for Isolated Signalized Intersection Based on Dynamic Programming. *IEEE Intelligent Transportation Systems Magazine*, v. 8, n. 4, p. 4-14, 2016.

CHEN, X. L., CAO, L., LI, C. X., XU, Z. X., LAI, J. Ensemble network architecture for deep reinforcement learning. *Mathematical Problems in Engineering*, v. 2018, 2018.

COX, Wendell. Demographia World Urban Areas. 13th Annual Edition ed. St. Louis: Demographia. Disponível: <http://www.demographia.com/db-worldua.pdf>. Data de acesso: 25 de abril de 2017.

DE SOUZA, A. M. e VILLAS, L. A., A new Solution based on Inter-Vehicle Communication to Reduce Traffic jam in Highway Environment. IEEE Latin America Transactions, v. 13, n. 3, p. 721-726, 2015.

DENATRAN, Frota de Veículos 2016. url: <http://www.denatran.gov.br/index.php/estatistica/261-frota-2016>, acessado em 30 set 2016.

DER-DF. Sistema Rodoviário do Distrito Federal. Relatório, Secretaria de Estado de Mobilidade, DF, pp. 187, 2016.

DERVISOGLU, G.; GOMES, G.; KWON, J.; HOROWITZ, R. e VARAIYA, P. Automatic Calibration of The Fundamental Diagram and Empirical Observations on Capacity. Transportation Research Board 88th Annual Meeting, TRB, Washington/DC, USA, v. 15, 2009

DETRAN/DF, Frota de Veículos Registrados no Distrito Federal. url: http://www.detrans.df.gov.br/images/08_agosto_2016_frota.pdf, acessado em 25 set 2016.

DIMITRIOU, Loukas; TSEKERIS, Theodore; STATHOPOULOS, Antony. Adaptive hybrid fuzzy rule-based system approach for modeling and predicting urban traffic flow. Transportation Research Part C: Emerging Technologies, v. 16, n. 5, p. 554-573, 2008.

DUNKEL, Jürgen *et al.* Event-driven architecture for decision support in traffic management systems. Expert Systems with Applications, v. 38, n. 6, p. 6530-6539, 2011.

DUTRA, Cristiane Biazzone. Avaliação da eficiência de métodos de coordenação semafórica em vias arteriais. 2005. Dissertação de Mestrado. Universidade de São Paulo, Escola de Engenharia de São Carlos, Departamento de Transportes, pp. 203, 2005.

FLECK, Julia L.; CASSANDRAS, Christos G.; GENG, Yanfeng. Adaptive quasi-dynamic traffic light control. *IEEE Transactions on Control Systems Technology*, v. 24, n. 3, p. 830-842, 2016.

GAO, Kaizhou *et al.* Optimizing urban traffic light scheduling problem using harmony Search with ensemble of local search. *Applied Soft Computing*, v. 48, p. 359-372, 2016.

GAO, Y., XU, H., LIN, J., YU, F., LEVINE, S., DARRELL, T. Reinforcement learning from imperfect demonstrations. *arXiv preprint arXiv:1802.05313*, 2018.

GARCÍA-NIETO, José; ALBA, Enrique; OLIVERA, A. Carolina. Swarm intelligence for traffic light scheduling: Application to real urban areas. *Engineering Applications of Artificial Intelligence*, v. 25, n. 2, p. 274-283, 2012.;

GARCIA-NIETO, Jose; OLIVERA, Ana Carolina; ALBA, Enrique. Optimal cycle program of traffic lights with particle swarm optimization. *IEEE Transactions on Evolutionary Computation*, v. 17, n. 6, p. 823-839, 2013.

GARTNER, N. H., Area traffic control and network equilibrium. MIT, Working Paper, 26 pp., 1975.

GARTNER, Nathan H.; STAMATIADIS, Chronis; TARNOFF, Philip J. Development of advanced traffic signal control strategies for intelligent transportation systems: Multilevel design. *Transportation Research Record*, n. 1494, p. 98-105, 1995.

GONG, Y., ABDEL-ATY, M., CAI, Q., RAHMAN, M. S. Decentralized network level adaptive signal control by multi-agent deep reinforcement learning. *Transportation Research Interdisciplinary Perspectives*, v. 1, p. 100020, 2019.

GOTTELAND, J.-B.; DURAND, Nicolas. Genetic algorithms applied to airport ground traffic optimization. In: *Evolutionary Computation, 2003. CEC'03. The 2003 Congress on*. IEEE, 2003. p. 544-551.

GRUNITZKI, R.; BAZZAN, A. L. C., Combining Car-to-Infrastructure Communication and Multi-Agent Reinforcement Learning in Route Choice, 9th International

Workshop on Agents in Traffic and Transportation e 25th International Joint Conference On Artificial Intelligence, 2016.

GU, Z.; SABERI, M.; SARVI, M. e LIU, Z. A Big Data Approach for Clustering and Calibration of Link Fundamental Diagrams for Large-Scale Network Simulation Applications. *Transportation Research Part C: Emerging Technologies*, 2017.

GUAN, Deyong; YANG, Zhaosheng. Signal Timing Optimization for Urban Traffic Adaptive Control System. In: *Traffic and Transportation Studies (2002)*. 2002. p. 871-876.

HAND, D. J.; MANNILA, H. e SMYTH, P. *Principles of Data Mining*. Ed. MIT Press, Cambridge, MA, USA, 2001.

HAWI, R., OKEYO, G.; KIMWELE, M. Techniques for Smart Traffic Control: Na In-depth, *International Journal of Computer Applications Technology and Research*, v. 4, n. 7, p. 566-573, 2015.

HE, G., YANG, D., SHEN, K. Improving DQN Training Routines with Transfer Learning. 2019.

HENDERSON, P., ISLAM, R., BACHMAN, P., PINEAU, J., PRECUP, D., MEGER, D. Deep reinforcement learning that matters. In: *Proceedings of the AAAI conference on artificial intelligence*. 2018.

HCM. *Highway Capacity Manual*. Transportation Research Board, Washington, DC, USA, 2000.

HCM. *Highway Capacity Manual*. Transportation Research Board, Washington, DC, USA, 2010.

HOLMES, B. When shock waves hit traffic: What turns a fast-moving stream of cars into a stagnant pool of frustrated motorists? Bob Holmes talks to the traffic engineers who are beginning to crack the gridlock, *NewScientist.com*, 1994, acessado em 25 set 2016.

ITF. *Big Data and Transport: Understanding and assessing options*. Corporate Partnership Board Report, 2015.

JADERBERG, M., CZARNECKI, W. M., DUNNING, I., MARRIS, L., LEVER, G., CASTANEDA, A. G., GRAEPEL, T. *et al.* Human-level performance in 3D multi-player games with population-based reinforcement learning. *Science*, v. 364, n. 6443, p. 859-865, 2019.

JEONG, Young-Seon *et al.* Supervised weighting-online learning algorithm for short-term traffic flow prediction. *IEEE Transactions on Intelligent Transportation Systems*, v. 14, n. 4, p. 1700-1707, 2013.

JIANG, Xiaomo; ADELI, Hojjat. Dynamic wavelet neural network model for traffic flow forecasting. *Journal of transportation engineering*, v. 131, n. 10, p. 771-779, 2005.

JIANG, Z. e HUANG, Y. X. Parametric Calibration of Speed–Density Relationships in Mesoscopic Traffic Simulator with Data Mining. *Information Sciences*, v. 179, n. 12, p. 2002-2013, 2009.

JIANG, Z.; SHUBIN, L. I. e XIAOQING, L. I. U. Parameters Calibration of Traffic Simulation Model Based on Data Mining. *Journal of Transportation Systems Engineering and Information Technology*, v. 12, n. 6, p. 28-33, 2012.

JIN, Junchen; MA, Xiaoliang; KOSONEN, Iisakki. An intelligent control system for traffic lights with simulation-based evaluation. *Control Engineering Practice*, v. 58, p. 24-33, 2017.

JONER, S. e VOLPI, N. M. P., Sincronização de Semáforos: Modelo Matemático para uma Aplicação ao Tráfego de Curitiba. *Holos*, v. 2, p. 3-18, 2013.

JOO, H.; AHMED, S. H.; LIM, Y. Traffic signal control for smart cities using reinforcement learning. *Comput. Commun.* 2020, 154, pp. 324-330.

KAEDI, Marjan; MOVAHHEDINIA, Naser; JAMSHIDI, Kamal. Traffic signal timing using two-dimensional correlation, neuro-fuzzy and queuing based neural networks. *Neural Computing and Applications*, v. 17, n. 2, p. 193-200, 2008.

KARLAFTIS, Matthew G.; VLAHOGIANNI, Eleni I. Statistical methods versus neural networks in transportation research: Differences, similarities and some insights. *Transportation Research Part C: Emerging Technologies*, v. 19, n. 3, p. 387-399, 2011.

KIANFAR, J. e EDARA, P. A Data Mining Approach to Creating Fundamental Traffic Flow Diagram. *Procedia-Social and Behavioral Sciences*, v. 104, p. 430-439, 2013.

KIM, D., JEONG, O. Cooperative traffic signal control with traffic flow prediction in multi-intersection. *Sensors*, v. 20, n. 1, p. 137, 2020.

KUMAR, Vadrevu S. V. S. R. Pavan; KUMARI, M. Kamala. A novel application of adaptive traffic control system for India. *International Journal of Science, Engineering and Technology Research (IJSETR)*, v.5, Issue 7, July 2016.

LEAL, Samara Soares. Controle Ativo da Temporização Semafórica de Interseções. Centro Federal de Educação Tecnológica de Minas Gerais, Dissertação de Mestrado, pp. 96, 2016.

LEANDRO, Carlos Henrique Pires, Procedimento multicriterial para estruturação e caracterização de sistemas centralizados de controle do tráfego urbano. Dissertação de Mestrado, Instituto Militar de Engenharia, RJ, 2001.

LEE, Jinwoo; SHALABY, Amer; ABDULHAI, Baher. Optimized strategy for integrated traffic and transit signal control. *Efficient Transportation and Pavement Systems: Characterization, Mechanisms, Simulation and Modeling*, 2008.

LESHEM, Guy; RITOV, Ya'acov. Traffic flow prediction using adaboost algorithm with random forests as a weak learner. In: *Proceedings of World Academy of Science, Engineering and Technology*. 2007. p. 193-198.

LI, J., GAO, L., SONG, W., WEI, L., SHI, Y. Short term traffic flow prediction based on LSTM. In: *2018 Ninth International Conference on Intelligent Control and Information Processing (ICICIP)*. IEEE, 2018. p. 251-255.

- LI, J. e Zhang, H. M. Fundamental Diagram of Traffic Flow: New Identification Scheme and Further Evidence from Empirical Data. *Transportation Research Record*, v. 2260, n. 1, p. 50-59, 2011.
- LI, L., YISHENG, LV; WANG, F. Traffic signal timing via deep reinforcement learning. *IEEE/CAA Journal of Automatica Sinica*, v. 3, n. 3, p. 247-254, 2016.
- LI, Y. Deep reinforcement learning: An overview. arXiv preprint arXiv:1701.07274, 2017.
- LIU, Y., ZHANG, L., WEI, Y., WANG, Z. Energy Efficient Training Task Assignment Scheme for Mobile Distributed Deep Learning Scenario Using DQN. In: 2019 IEEE 7th International Conference on Computer Science and Network Technology (ICCSNT). IEEE, 2019. p. 442-446.
- LIU, G., WU, R., CHENG, H. T., WANG, J., OOI, J., LI, L., CHI, E. *et al.* Data Efficient Training for Reinforcement Learning with Adaptive Behavior Policy Sharing. arXiv preprint arXiv:2002.05229, 2020.
- LUNA, M. S. Sobre o Fluxo de Saturação: Conceituação, Aplicação, Determinação e Variação. Dissertação de Mestrado, Programa de Mestrado em Engenharia de Transportes, Universidade Federal do Ceará, Fortaleza, CE, 2003.
- LOPES, Luiz Carlos Ferreira. Método de Otimização das Defasagens de Corredores Arteriais. Tese de Doutorado, Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia de Transportes, RJ, pp. 154, 2010.
- LOUREIRO, Carlos Felipe Grangeiro; GOMES, M. J. T. L.; LEANDRO, Carlos Henrique Pires. Avaliação do desempenho nos períodos de pico do tráfego de interseções semaforizadas com controle centralizado em tempo fixo e real. In: Anais do XVI Congresso de Pesquisa e Ensino em Transportes. 2002. p. 365-376.
- MCKENNEY, Dave; WHITE, Tony. Distributed and adaptive traffic signal control within a realistic traffic simulation. *Engineering Applications of Artificial Intelligence*, v. 26, n. 1, p. 574-583, 2013.

MEDEIROS, F.C.; LUNA, M.S e LOUREIRO, C.F.G. Controle de Tráfego em Área de Fortaleza: Uma Nova Experiência na Gerência do Trânsito. Anais do 13º Congresso Brasileiro de Transporte e Trânsito – ANTP (CD-Rom), Porto Alegre, RS, 2001.

MIN, Wanli; WYNTER, Laura. Real-time road traffic prediction with spatio-temporal correlations. *Transportation Research Part C: Emerging Technologies*, v. 19, n. 4, p. 606-616, 2011.

MNIH, V., KAVUKCUOGLU, K., SILVER, D., RUSU, A. A., VENESS, J., BELLEMARE, M. G., GRAVES, A., RIEDMILLER, M., FIDJELAND, A. K., OSTROVSKI, G., PETERSEN, S., BEATTIE, C., SADIK, A., ANTONOGLU, I., KING, H., KUMARAN, D., WIERSTRA, D., LEGG, S., HASSABIS, D. Human-level control through deep reinforcement learning. *nature*, v. 518, n. 7540, p. 529-533, 2015.

MOUSAVI, S. S., SCHUKAT, M., HOWLEY, E. Traffic light control using deep policy-gradient and value-function-based reinforcement learning. *IET Intell. Transp. Syst.* 2017, 11.7, pp. 417-423.

NACHUM, O., GU, S., LEE, H., LEVINE, S. Data-Efficient Hierarchical Reinforcement Learning. *Advances in Neural Information Processing Systems*, v. 31, p. 3303-3313, 2018.

NAGABANDI, A., KAHN, G., FEARING, R. S., LEVINE, S. Neural network dynamics for model-based deep reinforcement learning with model-free fine-tuning. In: 2018 IEEE International Conference on Robotics and Automation (ICRA). IEEE, 2018. p. 7559-7566.

NAIR, A., MCGREW, B., ANDRYCHOWICZ, M., ZAREMBA, W., ABBEEL, P. Overcoming exploration in reinforcement learning with demonstrations. In: 2018 IEEE International Conference on Robotics and Automation (ICRA). IEEE, 2018. p. 6292-6299.

NEWELL, G. F., *Theory of Highway Traffic Signals*. UC Berkeley, Research Report, 456 pp., 1989.

NGUYEN, T. T., REDDI, V. J. Deep reinforcement learning for cyber security. arXiv preprint arXiv:1906.05799, 2019.

NULI, Sadguna; MATHEW, Tom V. Online coordination of signals for heterogeneous traffic using stop line detection. *Procedia-Social and Behavioral Sciences*, v. 104, p. 765-774, 2013.

OLIVEIRA NETO, F. M. *et al.* Atualização de Planos de Tempo-Fixo com Base em Dados Históricos de Sistemas Centralizados de Controle de Tráfego. In: *Anais do XX Congresso de Pesquisa e Ensino em Transportes, ANPET*. 2006.

OLIVEIRA, D.; BAZZAN, A. L. C., Emergence of traffic lights synchronization. In: *Proceedings 20th European Conference on Modelling and Simulation*. Germany. 2006.

OLIVEIRA, D.; BAZZAN, A. L. C., Swarm intelligence applied to traffic lights group formation. *Anais do VI Encontro Nacional de Inteligência Artificial (ENIA)*, p. 1003-1112, 2007

ORTÚZAR, J. D.; WILLUMSEN, L. G., *Modelling Transport*, Editora John Wiley & Sons Ltd., 4a ed., 2011.

OSTP. The national artificial intelligence research and development strategic plan. Report Paper, National Science and Technology Council of USA, 2016.

PAPAPANAGIOTOU, E.; BUSCH, F. Extended observer for urban traffic control based on limited measurements from connected vehicles. *IEEE Trans. Intell. Transp. Syst.* 2020, 21.4, pp. 1664-1676.

PIETRANTONIO, H.; BONETTI JR, W. Semáforos atuados pelo tráfego - Utilização, Parametrização, Monitoração e Análise de Desempenho. Paper Relatório técnico, USP, Dezembro de 2007.

PIETRANTONIO, H. Engenharia de Tráfego: Introdução à Teoria do Fluxo de Tráfego. Escola Politécnica da Universidade de São Paulo – Departamento de Engenharia de Transportes. Disponível em: <<http://sites.poli.usp.br/d/ptr5803/ET2-Teoria.pdf>>. Acesso em: 01 fev. 2017, 2017.

PORCHE, Isaac; LAFORTUNE, Stéphane. Adaptive Look-ahead Optimization of Traffic Signals*. *Journal of Intelligent Transportation System*, v. 4, n. 3-4, p. 209-254, 1999.

PROPER, Allen T.; MACCUBBIN, Robert Pearce; GOODWIN, Lynette C. Intelligent transportation systems benefits: 2001 Update. Report Paper, United States Department of Transportation, 2001.

PROTHMANN, Holger *et al.* Organic traffic light control for urban road networks. *International Journal of Autonomous and Adaptive Communications Systems*, v. 2, n. 3, p. 203-225, 2009.

QADRI, S. S. M.; GÖKÇE, M. A.; ÖNER, E. State-of-art review of traffic signal control methods: challenges and opportunities. *ETRR 2020*, 12.1, pp. 1-23.

RAMOS, G. O; BAZZAN, A. L. C., On Estimating Action Regret and Learning From It in Route Choice, 9th International Workshop on Agents in Traffic and Transportation e 25th International Joint Conference On Artificial Intelligence, 2016.

RASHEED, F.; YAU, K. L. A.; NOOR, R. M.; WU, C.; LOW, Y. C. Deep Reinforcement Learning for Traffic Signal Control: A Review. *IEEE Access*, 2020, Accepted.

ROLNICK, D., AHUJA, A., SCHWARZ, J., LILICRAP, T. P., WAYNE, G. Experience replay for continual learning. arXiv preprint arXiv:1811.11682, 2018.

ROSYADI, A. R.; WIRAYUDA, T. A. B.; AL-FARABY, S. Intelligent traffic light control using collaborative Q-Learning algorithms. In: *Information and Communication Technology (ICoICT)*, 2016 4th International Conference on. IEEE, 2016. p. 1-6.

SEGETH-DF. Mapas do Sistema Viário do Distrito Federal. Secretaria de Estado de Gestão do Território e Habitação. Disponível: <http://www.segeth.df.gov.br/component/content/article/284-mapas/281-mapas.html>, acessado em 17 de abril de 2017, 2016.

SHELBY, Steven. Single-intersection evaluation of real-time adaptive traffic signal control algorithms. *Transportation Research Record: Journal of the Transportation Research Board*, n. 1867, p. 183-192, 2004.

SHEPHERD, Simon. Traffic control in over-saturated conditions. *Transport Reviews*, v. 14, n. 1, p. 13-43, 1994.;

SMITH, Stephen F. *et al.* SURTRAC: scalable urban traffic control. *TRB Annual Meeting*, 2013.

SOUZA JR., P. S. F. Procedimento para a concepção de controladores semafóricos *fuzzy* com o uso de algoritmo genético. Dissertação de Mestrado. Publicação T.DM-002 A/2010, Departamento de Engenharia Civil e Ambiental, Faculdade de Tecnologia, Universidade de Brasília, DF, p. 143, 2010.

STATHOPOULOS, Anthony; KARLAFTIS, Matthew G. A multivariate state space approach for urban traffic flow modeling and prediction. *Transportation Research Part C: Emerging Technologies*, v. 11, n. 2, p. 121-135, 2003.

STEFANELLO, F., Silva, B. C.; BAZZAN, A. L. C. Using Topological Statistics to Bias and Accelerate Route Choice: preliminary findings in synthetic and real-world road networks, 9th International Workshop on Agents in Traffic and Transportation e 25th International Joint Conference On Artificial Intelligence, 2016.

SUN, L. e ZHOU, J. Development of Multiregime Speed-Density Relationships by Cluster Analysis. *Transportation Research Record*, v. 1934, p. 64-71, 2005.

SUNKARI, Srinivasa R.; ENGELBRECHT, Roelof J.; BALKE, Kevin N. Evaluation of advance coordination features in traffic signal controllers. Department of Transportation, FHWA/TX-05/0-4657-1, USA, 2004.

SUTTON, R. S., BARTO, A. G. Reinforcement learning: An introduction. MIT press, 2018.

TAKANO, Y., INOUE, H., THAWONMAS, R., HARADA, T. Self-Play for Training General Fighting Game AI. In: 2019 Nicograph International (NicoInt). IEEE, 2019. p. 120-120.

TAN, H.; WU, Y.; SHEN, B.; JIN, P. J.; RAN, B. Short-term traffic prediction based on dynamic tensor completion. *IEEE Transactions on Intelligent Transportation Systems*, v. 17, n. 8, p. 2123-2133, 2016.

TAN, M.; WONG, S. C.; XU, J.; GUAN, Z. e ZHANG, P. An aggregation approach to short-term traffic flow prediction. *IEEE Transactions on Intelligent Transportation Systems*, v. 10, n. 1, p. 60-69, 2009.

TAN, P.; STEINBACH, M., KARPATNE, A. e KUMAR, V. *Introduction to data mining*. (2a ed.). Ed. Pearson, London, England, 2018.

VAN HASSELT, H., GUEZ, A., SILVER, D. Deep reinforcement learning with double Q-learning. In: *Proceedings of the AAAI conference on artificial intelligence*. 2016.

VAZ, A. M. Estudos das Funções de pertinência para conjuntos fuzzy utilizados em Controladores Semafóricos Fuzzy. Dissertação de mestrado, Publicação T.DM – 005^a/2006. Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, DF, pp. 158, 2006.

VILANOVA, Luís M. O Controle dos Semáforos em Tempo Real: a experiência de São Paulo. *Boletim Técnico*, São Paulo, SP: Companhia de Engenharia de Tráfego, 2005.

VLAHOGIANNI, Eleni I.; KARLAFTIS, Matthew G.; GOLIAS, John C. Optimized and meta-optimized neural networks for short-term traffic flow prediction: A genetic approach. *Transportation Research Part C: Emerging Technologies*, v. 13, n. 3, p. 211-234, 2005.

WANG, Z., SCHAUL, T., HESSEL, M., HASSELT, H., LANCTOT, M., FREITAS, N. Dueling network architectures for deep reinforcement learning. In: *International conference on machine learning*. PMLR, 2016. p. 1995-2003.

WEN, W. A dynamic and automatic traffic light control expert system for solving the road congestion problem. *Expert Systems with Applications*, v. 34, n. 4, p. 2370-2381, 2008.

WENG, X. X.; DU, G. L. Hybrid elman neural network model for short-term traffic prediction. In: Proceedings of the 8th IASTED International Conference on Control and Applications. 2006. p. 281-284.

WITTEN, I. H.; FRANK, E.; HALL, M. A. e PAL, C. J. Data Mining: Practical machine learning tools and techniques (3a ed.). Ed. Morgan Kaufmann, Burlington, MA, USA, 2011.

YANG, Jinkui; ZHANG, Liguu; CHEN, Yangzhou. Pattern-based short-term traffic forecasting under urban heterogeneous conditions. In: ICCTP 2010: Integrated Transportation Systems: Green, Intelligent, Reliable. 2010. p. 2057-2064.

YANG, Z., HUANG, H., YAO, D.; ZANG, Y. Cooperative Driving Model for Non-Signalized Intersections Based on Reduplicate Dynamic Game, 19th IEEE Intelligent Transportation Systems Conference, 2016.

YAO, Z., WANG, Y., XIAO, W., ZHAO, B., PENG, B. A two-level rolling optimization model for real-time adaptive signal control. Algorithms, v. 12, n. 2, p. 38, 2019.

YE, H., LI, G. Y., JUANG, B. H. F. Deep reinforcement learning based resource allocation for V2V communications. IEEE Transactions on Vehicular Technology, v. 68, n. 4, p. 3163-3173, 2019

YISHENG, LV *et al.* Traffic flow prediction with big data: a deep learning approach. IEEE Transactions on Intelligent Transportation Systems, v. 16, n. 2, p. 865-873, 2015.

YU, Xiao-Hua. An integrated model for signalized traffic intersection control. In: Control Applications, 2005. CCA 2005. Proceedings of 2005 IEEE Conference on. IEEE, 2005. p. 1427-1430.

YUAN, Y. DAAMEN, W., DUIVES, D.; HOOGENDOORN, S. Comparison of three algorithms for real-time pedestrian state estimation – supporting a monitoring dashboard for large-scale events, 19th IEEE Intelligent Transportation Systems Conference, 2016.

ZENG, G. Application of Big Data in Intelligent Traffic System. IOSR Journal of Computer Engineering, v. 17, n. 1, p. 01-04, 2015.

ZHANG, Yunlong; XIE, Yuanchang; YE, Zhirui. Development and Evaluation of a Multi-Agent Based Neuro-Fuzzy Arterial Traffic Signal Control System. Work, v. 473700, p. 00092, 2007.

ZHAO, Yi; TIAN, Zong. An overview of the usage of adaptive signal control system in the United States of America. In: Applied Mechanics and Materials. Trans Tech Publications, p. 2591-2598, 2012.

ZHENG, Weizhong; LEE, Der-Horng; SHI, Qixin. Short-term freeway traffic flow prediction: Bayesian combined neural network approach. Journal of transportation engineering, v. 132, n. 2, p. 114-121, 2006.

ZIAT, A. Leroy, B., BASKIOTIS, N. e DENOYER, L., Joint Prediction of Road-Traffic and Parking Occupancy Over a City With Representation Learning, 19th IEEE Intelligent Transportation Systems Conference, 2016.

7 APÊNDICE A

Identificar o fluxo de saturação tem grande relevância para informar ao usuário o momento em que uma determinada via passará do regime livre para o congestionado, permitindo que ele planeje a sua rota. Então, considerando inicialmente que este parâmetro pudesse ser essencial, assim como é para diversos modelos de controle de tráfego, ou mesmo útil em alguma medida, este trabalho buscou desenvolver um modelo automatizado para promover a calibração dos parâmetros fundamentais de tráfego.

7.1 REVISÃO DA LITERATURA

De acordo com Sun e Zhou (2005), a segmentação dos dados coletados em fluxo livre e congestionado é realizada de forma exógena com base no melhor palpite do pesquisador e não existe um procedimento universalmente recomendado para determinar a ocupação crítica que define essa segmentação em um conjunto de dados de tráfego (Kianfar e Edara, 2013).

Os erros nas estimativas dos parâmetros de tráfego podem estar associados aos conceitos empregados (Shanteau, 1988, *apud* Luna, 2003), à aplicação dos métodos de determinação dos parâmetros (Teply e Jones, 1991, *apud* Luna, 2003) e à aderência dos modelos e métodos tradicionais ao fenômeno (Tarko e Tracz, 2000, *apud* Luna, 2003). Neste contexto, Kianfar e Edara (2013) indicam que um procedimento que não dependa completamente do julgamento dos pesquisadores pode permitir mais consistência para os resultados do estudo ou do modelo.

Luna (2003) aponta que os métodos para escolha de um plano semaforístico têm basicamente em comum a modelagem de formação e descargas de filas acumuladas da fase vermelha do ciclo e, posteriormente, desmanchadas em sua fase verde de acordo com a taxa de saturação, que, no caso do SCOOT, não é medida pelo sistema, mas fornecida como um parâmetro fixo.

Segundo ele, é evidente que os resultados são influenciados pelo valor do fluxo de saturação adotado, independentemente da técnica ou ferramenta usada na abordagem de interseções semaforizadas, e uma pequena variação no valor desse parâmetro pode resultar em grandes variações no tempo de ciclo e na alocação de tempos de verde, especialmente

nas situações de operação próximas à capacidade da interseção (TEPLY e JONES, 1991, apud LUNA, 2003).

Em um dos trabalhos mais citados, Dervisoglu *et al.* (2009) sugerem uma estrutura para calibrar o diagrama de ocupação versus fluxo em uma seção rodoviária. O objetivo do estudo era calibrar um modelo de transmissão celular para uma seção rodoviária, utilizando uma regressão linear ajustada aos dados de ocupação e fluxo com velocidades acima de 88 km/h, visando a criar o ajuste de fluxo livre. Depois, os pesquisadores empregaram a definição de capacidade do Manual de Capacidade Rodoviária (HCM, 2000) para determinar a capacidade dos segmentos das vias estudadas. Em seguida, tomando o maior fluxo registrado como a capacidade máxima da via, eles a projetaram horizontalmente sobre a reta de regressão que ajustou o fluxo livre para determinar a ponta do diagrama de ocupação e fluxo, identificando a ocupação crítica. Para concluir a estrutura, uma técnica de regressão quantílica aproximada foi usada para criar o ajuste de ocupação e fluxo supercrítico. Finalmente, a estrutura sugerida foi aplicada aos dados dos sensores de tráfego da rodovia *Interstate* 880 na área da Baía de São Francisco, na Califórnia.

Jiang e Huang (2009) abordaram a calibração de parâmetros do relacionamento velocidade versus densidade usando técnicas de mineração de dados e propuseram um novo algoritmo de agrupamento hierárquico baseado no método *k-means*. Os pesquisadores descrevem que combinando o *k-means* com a classificação aglomerativa hierárquica propuseram um novo algoritmo capaz de reduzir os erros inerentes ao estágio inicial da classificação hierárquica aglomerativa, que resultou em um desempenho de agrupamento melhor. Eles utilizaram densidades e fluxos como variáveis para melhorar a precisão da calibração paramétrica. Essa nova abordagem foi testada com dados capturados por sensores do terceiro anel rodoviário de Pequim. Os resultados do teste mostraram que o desempenho do algoritmo proposto foi melhor do que as soluções existentes.

Li e Zhang (2011) apresentaram um método para criar e calibrar um diagrama densidade versus fluxo. Primeiro, com base nas características das flutuações das séries temporais, os dados de tráfego são particionados em fluxo livre e fluxo congestionado. Depois, uma técnica de princípio mínimo foi usada para identificar estados de equilíbrio seguidos pela aplicação de uma técnica mista de otimização de números inteiros para criar ajustes lineares de densidade e fluxo por partes. O objetivo do procedimento de otimização foi obter

ajustes com desvio absoluto mínimo. A metodologia sugerida foi aplicada em três rodovias localizadas na Califórnia e, segundo os autores, os seus resultados aderiram muito bem aos princípios da engenharia de tráfego.

Ainda explorando as estruturas de calibração de parâmetros associados à densidade e ao fluxo de tráfego, Jiang *et al.* (2012) empregaram um volume maior de informações detectadas em uma rodovia para melhorar a precisão no processo de calibração de parâmetros usados no modelo de simulação de tráfego. Neste contexto, a mineração de dados foi usada para calibrar a velocidade dos veículos e, além disso, o trabalho propôs uma nova regressão ponderada localmente com base no agrupamento hierárquico aglomerativo. Primeiro, as amostras de treinamento foram agrupadas e, depois, o algoritmo de agrupamento hierárquico aglomerativo foi usado para estabelecer uma árvore de classificação para cada agrupamento de restrições. Em seguida, o método do k-vizinho mais próximo foi empregado para classificar novas amostras no melhor agrupamento ajustado. Finalmente, a velocidade do veículo foi estimada. De acordo com os autores, os testes com uma quantidade enorme de dados de campo demonstraram que o algoritmo proposto teve um bom desempenho na precisão e eficiência da estimativa dos parâmetros.

Kianfar e Edara (2013) pesquisaram a aplicação de técnicas de agrupamento no particionamento dos dados do fluxo de tráfego em regimes de fluxo livre e congestionado. Assim, propuseram uma estrutura de agrupamento baseada nas variáveis fundamentais do fluxo de tráfego e compararam três técnicas de agrupamento: Hierárquico, *k-means* e Modelo de Misturas de Gaussianas. Os autores aplicaram as técnicas de agrupamento citadas em todas as combinações possíveis formadas pelas variáveis: fluxo, velocidade e ocupação. Segundo eles, os resultados indicaram que o agrupamento é um meio efetivo para classificar os regimes de fluxo dos dados de tráfego visando a criar os diagramas fundamentais de fluxo de tráfego e os modelos macroscópicos de tráfego. Considerando as combinações entre as variáveis, os melhores resultados do agrupamento foram alcançados usando apenas a velocidade e a velocidade com a ocupação como variáveis de entrada. Além disso, de acordo com o coeficiente de *Silhouette* que representa um índice de validação da consistência dos agrupamentos, os pesquisadores destacam que o desempenho das técnicas de agrupamento *k-means* e hierárquico são comparáveis entre si e superam o Modelo de Misturas de Gaussianas.

Mais recentemente, Gu *et al.* (2017) propuseram uma metodologia de agrupamento de dois estágios baseados em big data para calibrar os diagramas fundamentais de tráfego nas conexões em redes de vias expressas. Basicamente, sob o estado de tráfego normal, o primeiro estágio captura as variações dos diagramas fundamentais das conexões em vários dias e, a partir dessas variações, as conexões são agrupadas no segundo estágio. Dois métodos, ou seja, o algoritmo *k-means* combinado com o agrupamento hierárquico e o agrupamento hierárquico modificado baseado na distância de Fréchet, são aplicados no primeiro estágio para obter a matriz de parâmetros do diagrama fundamental de tráfego para cada conexão. As matrizes calibradas são inseridas no segundo estágio em que o agrupamento hierárquico modificado é reempregado como uma abordagem estática, resultando em vários agrupamentos de conexões. Para considerar ainda mais as variações dos diagramas fundamentais das conexões, a abordagem estática é estendida pela modificação da medida de similaridade por meio da análise de componentes principais. O agrupamento de séries temporais multivariadas resultante modela as distribuições dos parâmetros dos diagramas fundamentais como uma abordagem dinâmica. A estrutura proposta é aplicada na rede de autoestradas de Melbourne usando dados coletados de um ano. Os resultados mostraram que: vias com atributos físicos similares não resultam necessariamente em conexões com diagramas fundamentais similares, a abordagem do método hierárquico tem melhor desempenho no agrupamento dos diagramas fundamentais das conexões em relação à abordagem do método particional e a metodologia proposta ajuda a compreender melhor a distribuição espacial conexões com diagramas fundamentais semelhantes e as variações e distribuições dos parâmetros dos diagramas fundamentais associados.

A revisão da literatura supracitada demonstra que o *data mining*, apoiado nas técnicas de agrupamento, tem boa aderência na classificação dos fluxos de trânsito, principalmente devido ao emprego das técnicas *k-means* e agrupamento hierárquico. A consistência da técnica de agrupamento *k-means*, inclusive as de suas adaptações com outros métodos, induz à consolidação do seu emprego como ferramenta de classificação desse fluxo de acordo com os seus estados possíveis.

7.2 LEVANTAMENTO DO FLUXO DE SATURAÇÃO EM CAMPO

Conforme citado anteriormente, Luna (2003) e Oliveira Neto *et al.* (2006) destacam a importância do fluxo de saturação para a definição e atualização dos planos semaforicos

pelos métodos tradicionais, bem como o esforço necessário para produzir essa informação mediante a coleta de dados de campo, que requerem a detecção da formação e descarga das filas durante o ciclo semafórico. No entanto, os dados coletados pelos equipamentos de fiscalização eletrônica veicular utilizados neste trabalho não permitem a visualização desse processo de formação e descarga de filas.

Portanto, inicialmente, optou-se por utilizar os dados disponíveis para verificar o comportamento gráfico do fluxo no período de pico previamente identificado e, a partir da associação do método de Shanteau (1988, *apud* SANTOS, 2007) e do *Highway Capacity Manual* (TRB, 2000), definir o fluxo de saturação na aproximação da interseção.

De acordo com Santos (2007), Shanteau (1988) mediu o fluxo de saturação graficamente por meio de uma curva de acumulação de descarga da fila de veículos. No seu método, os eixos das ordenadas e das abcissas representam respectivamente as quantidades e os tempos acumulados de cada veículo. Se as filas se dissipam em regime de saturação, o gráfico indicará um trecho retilíneo cujo coeficiente angular definido pela razão entre a variação da quantidade de veículos (ΔN) e variação de tempo (Δt) é o fluxo de saturação.

O modelo de estimação do fluxo de saturação do *Highway Capacity Manual* (TRB, 2000) despreza os 4 primeiros veículos que passam sobre a linha de retenção a fim de evitar o efeito da reação desses primeiros motoristas ainda sob a influência da inércia no momento em que a luz verde do semáforo acende. Assim, esse modelo considera efetivamente os veículos que passam a partir do quinto veículo até o último veículo da fila que passa sobre a linha de retenção, sendo esse último veículo da fila aquele que parou no limiar do início da luz verde do semáforo. É recomendado que seja utilizado 15 ciclos com filas de mais de 8 veículos para a realização dos cálculos, pelo menos.

A Figura 7.1 exemplifica os gráficos produzidos a partir de uma amostra dos dados disponíveis para verificar e representar os segmentos retilíneos descritos por Shanteau (1988). A amostra foi extraída de três dias distintos no período entre as 6:45 e as 7:15h. Foram 10 conjuntos de dados extraídos de cada dia: terça-feira, quarta-feira e quinta-feira. Ainda que, de uma forma geral, raramente os pontos iniciais caracterizem uma reação lenta dos motoristas diante da luz verde do semáforo, ou seja, ainda que a reação dos primeiros motoristas seja praticamente imediata e os veículos vençam a inércia rapidamente logo após o início da luz verde, os dados foram ajustados por regressões lineares

desprezando os 4 primeiros veículos de cada luz verde do semáforo ou, de acordo com o caso, todos os pontos iniciais desalinhados com o segmento retilíneo subsequente.

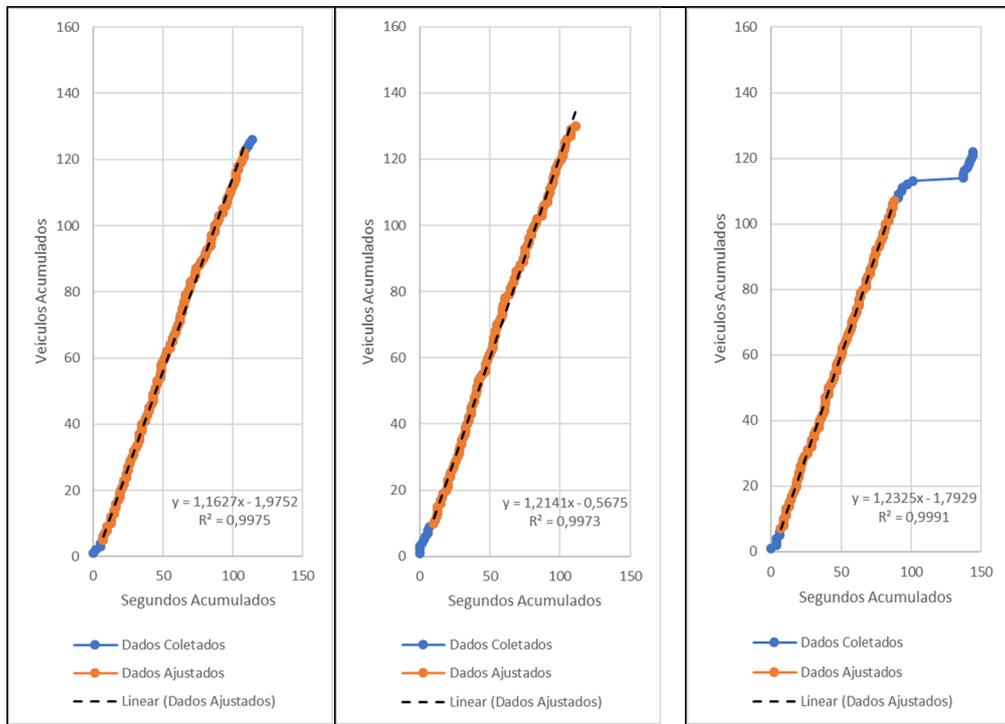


Figura 7.1: Exemplos gráficos de descargas de filas de veículos acumulados representadas em segmentos retilíneos

Desta forma, os fluxos de saturação foram medidos pelo coeficiente angular das regressões lineares ajustadas ($\Delta N/\Delta t$) e convertidos em veículos por hora pela equação (7.1) abaixo.

$$S = 3.600 \times \Delta N/\Delta t \tag{7.1}$$

A Tabela 7.1 apresenta as trinta medições do fluxo de saturação feitas a partir da amostra de dados descrita acima, cuja média é 1.448 veículos. Com 95% de confiança pelo teste de Kolmogorov-Smirnov, esses dados aderem à uma Distribuição Normal (Figura 7.2:) e a medida do fluxo de saturação igual a 1.311 veículos por hora é um extremo fora do intervalo de confiança da distribuição com 95% de probabilidade.

Tabela 7.1: Medidas de Fluxo de Saturação feitas a partir dos dados disponíveis.

1.470	1.542	1.424	1.395	1.560	1.431	1.414	1.443	1.418	1.428
1.457	1.349	1.460	1.472	1.468	1.427	1.415	1.419	1.552	1.340
1.513	1.549	1.527	1.471	1.311	1.435	1.507	1.408	1.349	1.479

Excluindo-se essa medida têm-se que o fluxo de saturação mais provável por essa análise é 1.452 veículos por hora por faixa.

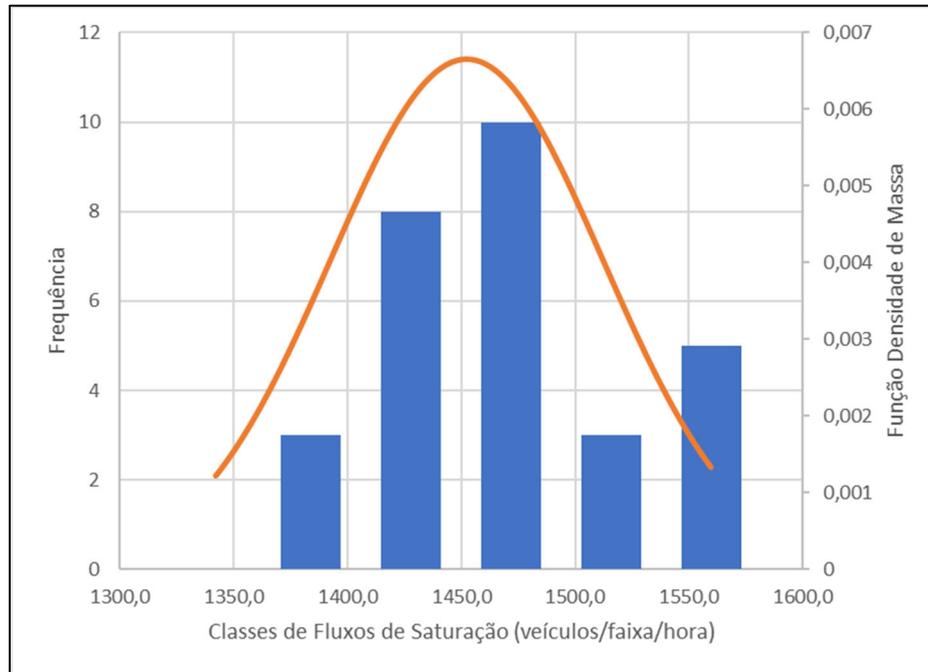


Figura 7.2: Histograma de medidas de fluxo de saturação *versus* distribuição normal ajustada para uma amostra de dados dos equipamentos de fiscalização eletrônica

Entretanto, ainda com o propósito de validar os resultados desta *calibração de parâmetros fundamentais de tráfego*, optou-se pela realização de uma nova amostragem independente dos dados coletados pelos equipamentos de fiscalização eletrônica veicular. Portanto, procedeu-se a uma campanha de campo com pesquisadores para aferir o fluxo de saturação na aproximação da interseção. Então, durante o período compreendido entre os dias 21 a 23 de novembro e 05 a 07 de dezembro de 2017, foi realizada uma pesquisa nas interseções da área de estudo para medir essa variável, sendo a equipe de campo formada por militares do Exército Brasileiro cedidos pelo 11º Depósito de Suprimentos – 11º DSup.

Os militares foram devidamente capacitados para atuarem como pesquisadores de campo mediante instrução específica (Figura 7.3). A equipe, constituída por 08 (oito) pesquisadores e 01 (um) coordenador, realizou a medição diariamente entre 06:45 e 07:15h a fim de abranger o horário de pico matinal (Figura 7.4).



Figura 7.3: Equipe de pesquisa sendo instruída

A equipe de pesquisa foi posicionada em duplas próximas às linhas de retenção de cada via da interseção sob o regime de saturação. O primeiro pesquisador ficou encarregado de observar o último veículo que entrou na fila no limiar da luz verde do semáforo enquanto o segundo pesquisador ficou responsável por observar a abertura do semáforo e cronometrar os tempos de cada veículo que passava pela linha de retenção desde a abertura do semáforo até o último veículo da fila, apontado pelo primeiro pesquisador.



Figura 7.4: Pesquisadores em campo

Dessa forma, após esse registro, pode-se aferir que, em média, as filas são formadas por 24 veículos por faixa e o tempo de descarga total delas é 64 segundos. A Tabela 7.2 resume os fluxos de saturação medidos de acordo com o método do *Highway Capacity Manual* (TRB, 2000) e destaca o respectivo desvio-padrão e a média da amostra.

Tabela 7.2: Fluxos de saturação medidos em veículos por faixa por hora

1.440	1.440	1.543	1.500	1.440	1.309	1.309	1.385	1.440	1.385
1.500	1.425	1.520	1.400	1.335	1.391	1.396	1.380	1.400	1.440

1.457	1.286	1.274	1.467	1.423	1.271	1.385	1.425	1.440	1.467
1.423	1.385	1.391	1.467	1.315	1.575	1.350	1.335	1.396	1.482
1.482	1.482	1.482	1.440	1.333	1.350	1.394	1.350	1.389	1.520
1.440	1.520	1.333	1.440	1.357	1.389	1.396	1.440	1.425	1.553
Desvio-padrão:			69,43 veíc./fx./h						
Média:			1.415,12 veíc./fx./h						

As medidas acima foram ajustadas a uma distribuição normal de acordo com o gráfico da Figura 7.5 e, portanto, existe a probabilidade de 68,3% do fluxo de saturação estar compreendido entre as medidas 1.346 e 1.485 veículos por faixa por hora, sendo 1.415 veíc./h/fx. o fluxo de saturação médio.

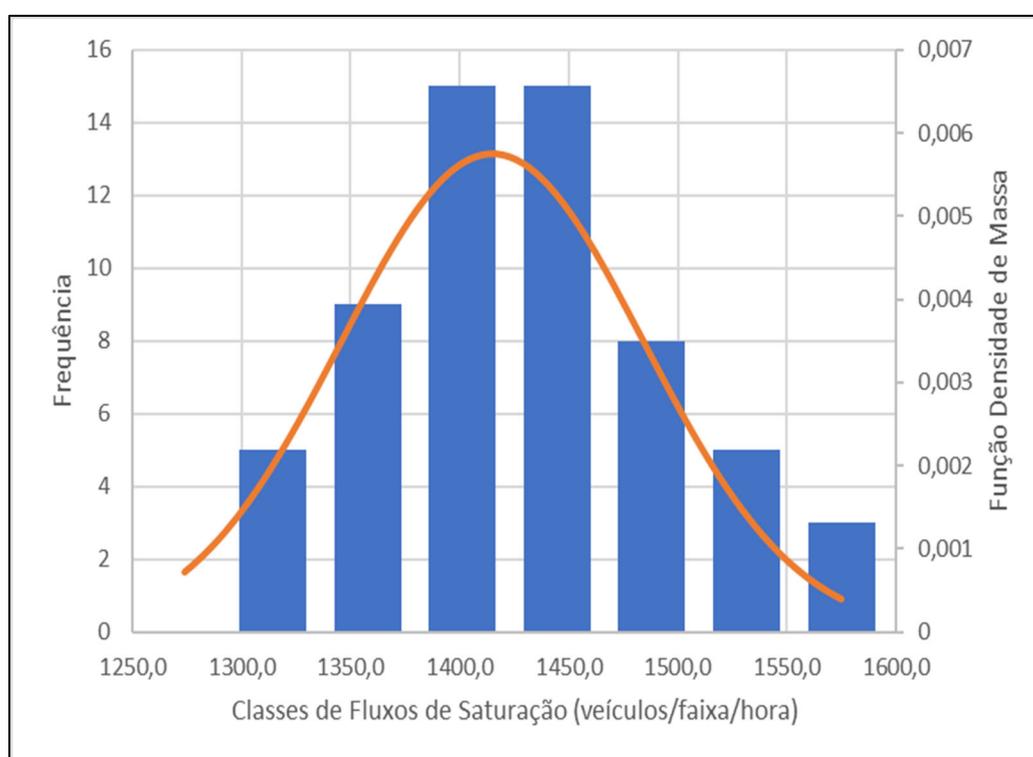


Figura 7.5: Histograma de medidas de fluxo de saturação *versus* distribuição normal ajustada para a amostra de dados coletados pelos pesquisadores de campo

Ainda, é possível observar que o levantamento do fluxo de saturação em campo comprova o resultado obtido por meio da análise preliminar que foi realizada anteriormente com os dados do DETRAN mediante o método de Shanteau (1988, *apud* SANTOS, 2007). Desta forma, resta comprovado que o levantamento de campo é consistente e que os resultados alcançados são compatíveis entre si. A propósito, o fluxo de saturação derivado dos dados do DETRAN (1.452 veíc./h/fx.) tem 70,23% de probabilidade de acordo com a curva de densidade de probabilidade acumulada proveniente do levantamento de campo.

7.3 CALIBRAÇÃO DE PARÂMETROS FUNDAMENTAIS DE TRÁFEGO

Os fluxos foram medidos a partir do acúmulo de cada veículo registrado por unidade de tempo em veículos por faixa por hora. Assim, cada veículo registrado possui um fluxo associado a ele, considerando-o e os veículos que passaram imediatamente antes dele de acordo com o período de acúmulo, por exemplo: 1 minuto, 5 minutos, 15 minutos etc. A velocidade média foi calculada de forma análoga, ou seja, a velocidade média de um veículo registrado seria a média das velocidades dele e dos demais veículos que compõem o pelotão imediatamente anterior, dentro do período de acúmulo.

Então, por meio da velocidade média calculada, a densidade do tráfego associada a um veículo registrado no mesmo período de acúmulo foi determinada considerando que essa densidade seria igual a quantidade de veículos que cabem no intervalo de tempo em que esse veículo registrado percorreria 1 km. Então, por exemplo, se a velocidade média do veículo for 35 km/h, ele percorrerá 1 km em 102,86 segundos (t_{1km}) e a densidade de tráfego (ρ) associada a ele será igual à quantidade de veículos que passaram antes dele nesses 102,86 segundos (n veículos(t_{1km})), incluindo ele. A Figura 7.6 representa esse raciocínio a fim de tentar facilitar a sua compreensão.

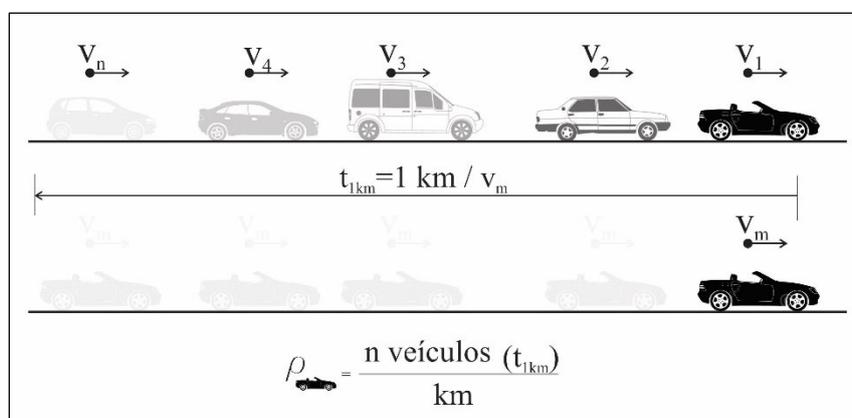


Figura 7.6: Raciocínio de cálculo da densidade de tráfego

Desta forma, a cada veículo registrado pelos sensores foi calculado um fluxo, uma velocidade média e uma densidade de tráfego, formando-se pares ordenados de acordo com as combinações possíveis: (densidade, fluxo), (velocidade, fluxo) e (velocidade, densidade), que passaram a ser agrupados e classificados na sequência. A Figura 7.7a exemplifica um dos gráficos criados a partir desses pares ordenados: densidade e fluxo, nesse caso.

Depois, os pontos foram classificados por meio do método *k-means* e das variáveis escolhidas para formar os *clusters* conforme o estado em que os pontos foram classificados. Então, por meio da variável densidade ou por uma combinação possível entre as variáveis existentes, tal como: densidade com velocidade, os agrupamentos são formados a fim de gerar os gráficos fundamentais: Densidade x Fluxo, Velocidade x Fluxo e Velocidade x Densidade com os pontos classificados. A Figura 7.7 compara o mesmo conjunto de dados de acordo com dois cenários distintos: sem qualquer classificação (a) e com *clusters* ou agrupamentos (b). Esses *clusters* representam cada um dos dois estados possíveis do fluxo em apreço, ou seja, eles agrupam os dados com características comuns como fluxo livre ou congestionado, criando um limite entre esses dois estados.

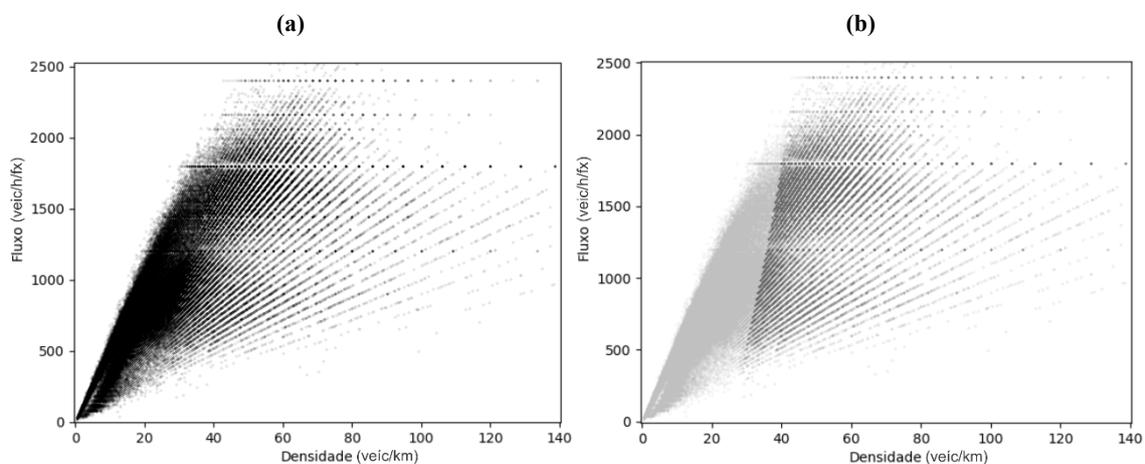


Figura 7.7: Comparação entre os gráficos Densidade x Fluxo sem (a) e com agrupamentos (b).

Como se trata de uma seção urbana, não se pode esperar um cone estreito para representar o fluxo livre no gráfico fundamental Densidade x Fluxo, assim como ocorre nos trabalhos de Dervisoglu *et al.* (2009) e Kianfar e Edara (2013), mas sim um arranjo diferente com um cone mais amplo, variando desde os valores bem menores até os mais elevados dessas variáveis e formando uma nuvem de pontos mais espalhada em todo o espectro de velocidades permitidas na via.

Em seguida, ajustou-se uma regressão linear a cada um dos *clusters* ou regimes de fluxos, definindo uma interseção entre as duas retas resultantes (Figura 7.8). Essa interseção caracteriza um ponto de comportamento comum entre as duas regressões, ou seja, um comportamento comum entre o fluxo livre e o congestionado. E, como qualquer reta que passa pela origem do gráfico Densidade x Fluxo representa fisicamente um conjunto de pontos com mesma velocidade, a reta que liga a origem dos eixos ao ponto de interseção das

regressões define a velocidade crítica em que ocorre a transição entre os estados de fluxo livre e congestionado (Figura 7.9a).

Como a fronteira entre os *clusters* define a mudança de características entre os fluxos livre e congestionado, o ponto de interseção entre essa fronteira e a reta da velocidade crítica define também o ponto crítico da densidade e do fluxo, ou seja, o fluxo de saturação. Nesse caso, é possível extrair os valores críticos das variáveis pela projeção do ponto crítico nos respectivos eixos. A Figura 7.9b destaca a representação final dessa solução analítica com a fronteira entre os *clusters*, a reta da velocidade crítica e a interseção entre esses elementos, definindo o fluxo de saturação.

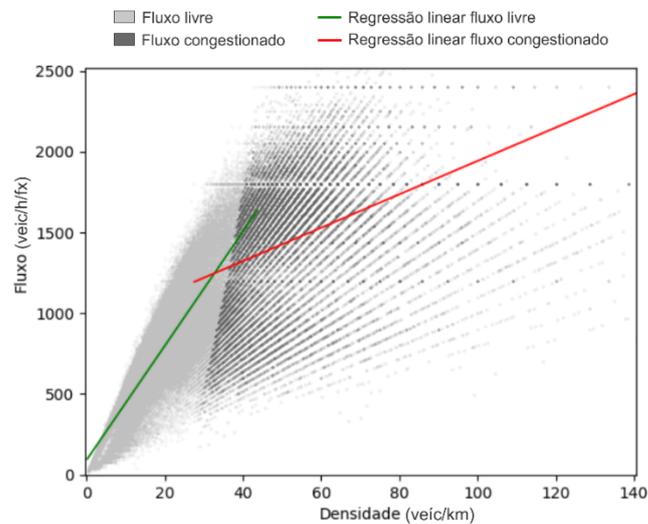


Figura 7.8: Regressões lineares ajustadas aos *clusters* de fluxos livre e congestionado

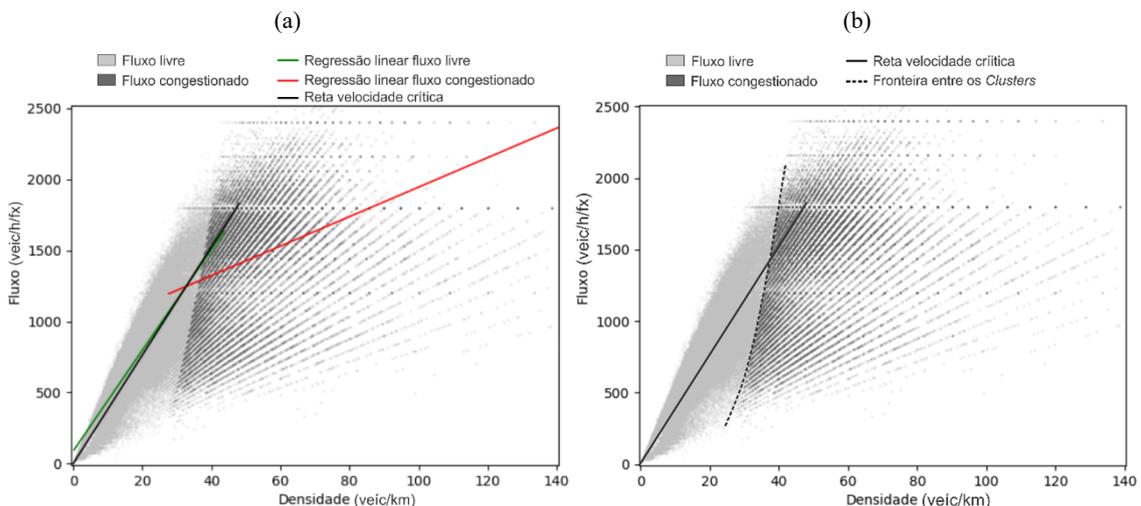


Figura 7.9: Determinação da reta velocidade crítica (a) e do ponto crítico (b).

7.4 VALIDAÇÃO DOS RESULTADOS

O método adotado nesse apêndice se baseia na *clusterização* dos dados em dados de fluxo livre e de fluxo congestionado. Assim, o resultado é afetado de acordo com a variável de classificação escolhida, obtendo-se resultados menos ou mais acurados conforme a combinação dessas variáveis. Por meio do coeficiente *Silhouette*, a Tabela 7.3 destaca a acurácia da *clusterização* realizada para todas as combinações entre as variáveis.

Tabela 7.3: Coeficientes *Silhouette* para cada combinação entre as variáveis de classificação

VARIÁVEIS	Densidade	Fluxo	Velocidade
Densidade	0,677	0,664	0,654
Fluxo	-	0,662	0,587
Velocidade	-	-	0,566
Todas		0,660	

A Figura 7.10 apresenta o resultado deste modelo proposto para a calibração dos parâmetros fundamentais de tráfego, destacando o fluxo de saturação, a velocidade e a densidade do tráfego associadas à ele: 1.430 veic./h/fx., 38 km/h e 37,63 veic./km/fx, respectivamente.

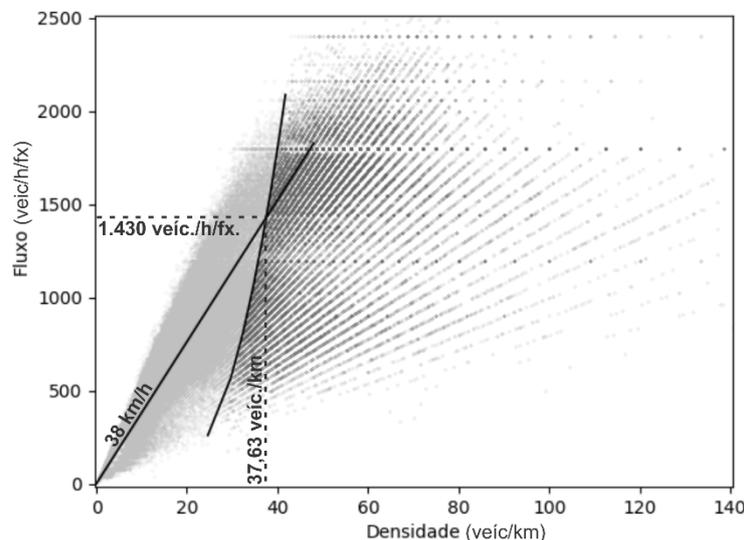


Figura 7.10: parâmetros de tráfego calibrados com a indicação da transição entre os regimes de fluxo livre e congestionado

A Tabela 7.4 indica a variação de resultados a partir de calibrações conduzidas por meio de combinações diferentes entre as variáveis de classificação, que envolvem a densidade do tráfego e possuem coeficientes muito próximos nos dois casos.

Tabela 7.4: Parâmetros fundamentais de tráfego calibrados automaticamente em função das variáveis de classificação

Variáveis de Clusterização	Fluxo (veíc./h/fx.)	Densidade (veíc./km)	Velocidade (km/h)	% Capacidade	Coefficiente <i>Silhouette</i>
Densidade	1.374,38	36,20	37,97	76,35	0,677
Densidade e Velocidade	1.430,00	37,63	38,00	79,45	0,654

Por fim, cabe destacar que os resultados obtidos na fase de levantamento do fluxo de saturação em campo e pela metodologia proposta acima, baseada em clusterização: 1.415, 1.430 e 1.452 veíc./h/fx, são compatíveis entre si e, portanto, consistentes.

8 APÊNDICE B

Como descrito neste trabalho, as simulações dos planos semaforicos foram realizadas por meio do software PTG VISSIM. Por isso, considerando que os planos semaforicos propostos por meio do modelo desta tese são completamente variáveis, adaptando-se de acordo com a demanda do fluxo de tráfego, foi necessário utilizar uma ferramenta avançada do referido software e, também, pouco conhecida dos seus usuários, uma linguagem de programação própria denominada VAP (*Vehicle Actuated Programing*) ou Programação Atuada por Veículos em tradução livre.

Portanto, o objetivo deste Apêndice é explicar como os planos semaforicos foram modelados e implementados no simulador PTV VISSIM a fim de oferecer uma iniciação sobre essa ferramenta poderosa.

Trata-se de uma linguagem que constitui um módulo fornecido pela fabricante do software para a elaboração de programações atuadas, assim como as programações usadas em corredores com priorização do transporte público a exemplo de BRT's e VLTs.

Basicamente, a ideia para modelagem e implementação foi gerar uma atuação nos semaforos concordantes com as mudanças de fase do algoritmo de otimização semaforica desenvolvido. Assim, a instrução semaforica era avaliada segundo a segundo, no período de 3.600 segundos ou 1 (uma) hora em uma variável do tipo *array*. Outros intervalos de tempo também poderiam ser implementados, variando apenas o tamanho desse *array*.

Então, cada estado do semaforo foi modelado mediante um *array* de (zeros) e 1 (uns) para cada plano semaforico e as mudanças de estados nesses planos foram feitas pela variação entre 0 (zeros) e 1 (uns) no respectivo *array*, de acordo com o instante em segundos que a simulação alcançava. Em princípio, essa abordagem permite avaliar qualquer resultado de programação semaforica de um algoritmo exógeno no simulador VISSIM sem que seja necessário inserir explicitamente esse algoritmo nesse simulador. Na sequência, é apresentado um exemplo de algoritmo desenvolvido em linguagem VAP para implementar um dos planos semaforicos utilizados na modelagem do cruzamento 289 com os dados do dia 16/06/2016 para o período das 06:00 às 07:00.


```
IF PROGRAMACAO[CONTADOR] = 1 THEN
  IF Current_state(2,red) THEN
    Sg_green(1)
  END;
  Sg_red(2);
ELSE
  IF Current_state(1,red) THEN
    Sg_green(2)
  END;
  Sg_red(1);
END.
```