

UNIVERSIDADE DE SÃO PAULO  
ESCOLA POLITÉCNICA  
DEPARTAMENTO DE TRANSPORTES

OLÍMPIO MENDES DE BARROS

**CARACTERIZAÇÃO DAS CONDIÇÕES DE TRÁFEGO EM TEMPO PRÓXIMO AO REAL PARA USO  
EM SISTEMAS DE PREVISÃO DE TRÁFEGO EM CIDADES DE GRANDE PORTE**

São Paulo  
2019



OLÍMPIO MENDES DE BARROS

**CARACTERIZAÇÃO DAS CONDIÇÕES DE TRÁFEGO EM TEMPO PRÓXIMO AO REAL PARA USO  
EM SISTEMAS DE PREVISÃO DE TRÁFEGO EM CIDADES DE GRANDE PORTE**

Trabalho apresentado à Escola Politécnica da  
Universidade de São Paulo para etapa de  
qualificação no programa para obtenção do  
título de Mestre em Engenharia.

Área de Concentração:

Transportes – Informações Espaciais

Orientador: Prof. Claudio Luiz Marte

São Paulo  
2019

Autorizo a reprodução e divulgação total ou parcial deste trabalho, por qualquer meio convencional ou eletrônico, para fins de estudo e pesquisa, desde que citada a fonte.

Catálogo na publicação  
Serviço de Biblioteca e Documentação  
Escola Politécnica da Universidade de São Paulo

Barros, Olímpio Mendes de

Caracterização das condições de tráfego em tempo próximo ao real para o uso em sistemas de previsão de tráfego em cidades de grande porte / Olímpio Mendes de Barros ; orientador, Cláudio Luiz Marte. – 2019. 116p.

Trabalho de Qualificação – Programa de Pós-Graduação em Engenharia de Transportes, Escola Politécnica, Universidade de São Paulo, São Paulo, 2019.

Versão Original

1. Engenharia de Transportes. 2. Predição de Tráfego. 3. Simulação de Tráfego.

Nome: Barros, Olímpio Mendes de

Título: Caracterização das condições de tráfego em tempo próximo ao real para o uso em sistemas de previsão de tráfego em cidades de grande porte

Trabalho apresentado à Escola Politécnica da Universidade de São Paulo para etapa de qualificação no programa para obtenção do título de Mestre em Engenharia.

Aprovado em:

Banca Examinadora

Prof. Dr. \_\_\_\_\_  
Instituição: \_\_\_\_\_  
Julgamento: \_\_\_\_\_

Prof. Dr. \_\_\_\_\_  
Instituição: \_\_\_\_\_  
Julgamento: \_\_\_\_\_

Prof. Dr. \_\_\_\_\_  
Instituição: \_\_\_\_\_  
Julgamento: \_\_\_\_\_



## RESUMO

BARROS, Olímpio Mendes de. **Caracterização das condições de tráfego em tempo próximo ao real para o uso em sistemas de previsão de tráfego em cidades de grande porte**. 2019. 116 f. Texto para Qualificação de Mestrado – Departamento de Transportes, Escola Politécnica, Universidade de São Paulo, São Paulo, 2019.

Com a crescente urbanização da população mundial, a Previsão de Tráfego de Curto Prazo tornou-se uma importante e necessária ferramenta na gestão do tráfego dos centros urbanos, seja por permitir a ação pró-ativa por parte dos gestores, seja por fornecer informações a outros sistemas ITS (Intelligent Transport Systems). Apesar do grande número de pesquisas publicadas, verificamos que apenas uma pequena porcentagem tem se focado em previsões de tráfego para mais de 1 hora e em redes urbanas de grande porte. Além disto, muitos desses estudos consideram que os dados recebidos já estão prontos para uso nas ferramentas de gestão, desprezando as falhas que ocorrem na obtenção dos dados e desconsiderando a relação espaço temporal que é característica ao tráfego no meio urbano. Esta pesquisa buscou analisar e propor uma metodologia que permita a organização, a preparação e a análise de diferentes fontes de dados, visando caracterizar as condições de tráfego, em tempo próximo ao real, com base na estimação das condições do fluxo do tráfego na rede urbana de uma grande cidade, apresentando-se como uma alternativa de previsão capaz de suprir esta necessidade dos gestores de centros urbanos. O modelo proposto envolve a utilização de ferramentas de reconhecimento de padrão na etapa de estimação da situação do tráfego e modelos de simulação de tráfego urbano para a etapa de previsão de tráfego. Os simuladores de tráfego, originalmente projetados para funções de planejamento, possuem hoje características que permitem seu uso em aplicações de tempo real, considerando as características espaciais, com o uso de mapas georreferenciados, e temporais, através da alocação dinâmica do tráfego na rede. Com base no modelo proposto, será possível a utilização de dados de diversas fontes, devidamente tratados e preparados com as características necessárias a sua utilização no sistema de simulação que fará a previsão para horizontes acima de 60 minutos.

Palavras-chave: Engenharia de Transportes. Previsão de Tráfego. Predição de Tráfego. Estimação do Estado do Tráfego. Simulação de Tráfego. Alocação Dinâmica de Tráfego.

### ABSTRACT

BARROS, Olímpio Mendes de. **Traffic conditions characterization, in near real time, for large cities traffic forecasting systems**. 2019. 116 f. Texto para Qualificação de Mestrado – Departamento de Transportes, Escola Politécnica, Universidade de São Paulo, São Paulo, 2019.

With the increasing urbanization in all world, Short-Term Traffic Forecasting has become an important and necessary tool for the traffic management in urban centers, either by allowing managers proactive actions, or by providing information to others ITS (Intelligent Transport Systems). Despite the large number of published texts in the literature, we verified that only a small percentage of them have been focused on traffic forecasting for over 1 hour [ahead] or on large urban networks. In addition, many of these studies consider that the data received are already prepared for use in an urban management scenario, neglecting the failures that occur in obtaining the data and disregarding the space-time relation that is characteristic to the urban environment traffic. This research sought to analyze and propose a methodology that allows the organization, preparation and analysis of different data sources, aiming to characterize the traffic conditions, in near real-time, based on the estimation of the urban network's traffic flow conditions of a large city, presenting itself as an forecasting alternative that is able to supplement this managing requirement of urban centers. The proposed model involves the use of pattern recognition tools in the stage of current traffic state estimation and urban traffic simulation models for the traffic prediction stage. Traffic simulators, originally designed for planning tasks, now are capable of providing real-time calculations, considering the spatial – using georeferenced maps – and temporal – through the dynamic traffic assignment in the network. Based on the proposed model, it will be possible to use properly treated and prepared data from different sources, with the necessary characteristics for its use in the traffic simulation system, which will forecast for over 60 minutes ahead.

Keywords: Transport Engineering. Traffic Prediction. Traffic Forecasting. Traffic State Estimation. Traffic Simulations. Dynamic Traffic Allocation.



**LISTA DE ABREVIATURAS**

ARIMA	Autoregressive Integrated Moving Average
AVL	Automatic Vehicle Location
BOM	Bilhete Ônibus Metropolitano
CET/SP	Companhia de Engenharia de Tráfego de São Paulo
DTA	Dynamic Traffic Assignment
GPS	Global Positioning System
IAG	Instituto de Astronomia, Geofísica e Ciências Atmosféricas da USP
IME	Instituto de Matemática e Estatística da USP
ITS	Intelligent Transport Systems
kNN	K-nearest neighbor
LMAG	Laboratório de Eletromagnetismo Aplicado da USP
MIT	Massachusetts Institute of Technology
OCR	Optical Character Recognition
OCR	Optical Character Recognition
OD	Origem / Destino
PMV	Painel de Mensagem Variável
RAM	Random Access Memory
SCOOT	Split Cycle and Offset Optimisation Technique
SIG	Sistemas de Informação Geográfica
SMT-SP	Secretaria de Mobilidade e Transportes do Município de São Paulo
SPTans	São Paulo Transportes
SSD	Solid-State Drive
SVR	Support Vector Regression
USP	Universidade de São Paulo
VANETs	Vehicular Ad-Hoc Networks



## 1 INTRODUÇÃO

A evolução dos sistemas ITS (Intelligent Transportat Systems) e seu uso em Cidades Inteligentes vem em resposta às novas demandas decorrentes do constante crescimento dos núcleos urbanos que tem ocorrido nas últimas décadas. Metrópoles e Megacidades são termos presentes nos mais diversos meios de comunicação.

Aplicativos de roteamento buscam indicar aos seus usuários as rotas de menor tempo e custo entre sua origem e destino e por vezes impactam no uso das vias da cidade, e, não raras vezes, resultam em congestionamentos em áreas onde antes estes não ocorriam.

Veículos autônomos e que se comunicam entre si via rede, conhecidos como VANETs (Vehicular Ad-Hoc Networks), e com sensores disponíveis nas vias devem chegar ao mercado de massa nos próximos anos, impactando a forma como vemos o automóvel e como nos movemos no meio urbano.

Gestores de cidades necessitam tomar decisões rápidas diante de situações complexas e para isso carecem de ferramentas de gestão robustas e confiáveis. Criar sistemas inteligentes que possam servir de base para essa nova realidade de cidades, também inteligentes, tornou-se uma necessidade. Os estudos voltados às Cidades Inteligentes (Smart Cities) estão presentes no dia a dia da comunidade científica, que incluem entre outros o avanço do uso de Internet das Coisas, comunicação em redes de alta capacidade e velocidade e a integração de sistemas e dados (BATTY et al., 2012).

Ferramentas de gestão que tenham a característica de prever, ainda que de modo aproximado, o que ocorrerá em decorrência de uma decisão são de extrema importância à gestão da mobilidade e devem se tornar cada vez mais presentes nas Centrais de Operação e Gestão das Cidades.

Nessa direção, surge a necessidade de sistemas que possam fornecer informações e se integrar a outros sistemas. Como exemplo e em posição de destaque, temos os sistemas que fazem a previsão da situação do tráfego de curto ou longo prazo.

Os estudos relacionados à previsão de tráfego ganharam força na última década, o que se comprova com a quantidade de Revisões Científicas (Review) publicadas sobre diversos aspectos desse tema: Previsão de Tráfego - Avanços e Desafios (LAÑA et al., 2018; VLAHOIANNI; KARLAFTIS; GOLIAS, 2014), Previsão de Tráfego Espaço-Temporal (ERMAGUN;

LEVINSON, 2017, 2018; GANG; SHOUHUI; XIAOBO, 2016; PAVLYUK, 2019), Previsão de Tráfego em Smart Cities (TASCIKARAOGLU, 2018; XIONG et al., 2012), Previsão de Tráfego em rodovias (OH et al., 2017), Projeto de Redes de Transporte mediante incertezas (CHEN et al., 2011), Locação de Sensores para Previsão de Tráfego (CASTILLO et al., 2015; GENTILI; MIRCHANDANI, 2018), Estimação da Densidade de Tráfego (T. DARWISH; K. ABU BAKAR, 2015), Alocação Dinâmica de Tráfego (AGHAMOHAMMADI; LAVAL, 2018; MITSAKIS; SALANOVA; GIANNOPOULOS, 2011; WANG et al., 2018), Métodos Estatísticos e Redes Neurais na Previsão de Tráfego (DE LUCA; GALLO, 2017; KARLAFTIS; VLAHOGIANNI, 2011), Previsão de Tráfego com uso de modelos Autorregressivos (PAVLYUK, 2017; SCHIMBINSCHI et al., 2017), Inteligência Artificial e *Big Data* em Sistemas de tráfego (VLAHOGIANNI, 2015) e Uso de Simuladores de Tráfego em Tempo Real (PELL; MEINGAST; SCHAUER, 2017).

A análise destas revisões indica que a maior parte do material científico publicado está relacionado às análises pontuais e a pequenos trechos de vias expressas. Boa parte sequer considera a questão espacial, ficando mais direcionada apenas à relação temporal. Apenas mais recentemente verificou-se o surgimento de estudos em redes urbanas, ainda assim a grande maioria aborda estudos de pequenas redes ou características específicas.

Estas revisões também apresentam uma grande concentração de estudos baseados nos dados históricos, com a aplicação de ferramentas de Inteligência Artificial e de análise de dados, os quais classificaremos mais adiante como métodos de Reconhecimento de Padrões. Muitos desses estudos publicados em revistas voltadas à computação e à Inteligência Artificial.

Para as previsões de longo prazo a abordagem que tem sido utilizada é baseada nas médias históricas como base de previsão para os dias seguintes. Esta abordagem pode ser útil na análise de cenários típicos para dias ou até semanas à frente. Esse tipo de previsão normalmente desconsidera fatores como o impacto das condições meteorológicas, os quais certamente impactam na capacidade e no uso das vias (GONÇALVES, 2018; HOU et al., 2013)

Conforme Vlahogianni, Karlaftis e Golias (2014), dentre os desafios existentes às pesquisas de ferramentas de previsão de tráfego estão: a previsão de tráfego em redes urbanas, a inclusão da dependência espaço temporal, a inclusão e consideração do impacto das intempéries e de incidentes, e a sinergia com os modelos teóricos de tráfego.

Os simuladores de tráfego foram introduzidos como ferramenta para as análises de previsão de tráfego mais recentemente. Seu uso se justifica por sua característica intrínseca

de utilizar uma base geográfica, incorporando assim a característica espacial do tráfego. Além disto, como veremos ao longo deste texto, sua estrutura possibilita a consideração de aspectos relativos ao impacto das intempéries e dos incidentes, respondendo assim a alguns dos desafios verificados na literatura até então.

## 1.1 MOTIVAÇÃO

Durante anos à frente da Central de Operações da CET/SP o autor se deparou com inúmeros desafios relativos à gestão da informação em tempo real que o levaram a pesquisar formas e ferramentas que pudessem otimizar os processos e parametrizar decisões. Na mesma direção, o orientador desta pesquisa durante suas atividades relacionadas com o tráfego rodoviário se deparou com demandas semelhantes relativas ao embasamento para a tomada de decisões.

Houve a junção das necessidades de gestão à possibilidade de se utilizar dados disponíveis de sensores e sistemas já implementados na Cidade de São Paulo.

Disto vislumbrou-se a possibilidade de transformação desses dados em informações com valor agregado e que possibilitassem a implementação de um sistema de previsão de tráfego.

## 1.2 OBJETIVO

Propor uma metodologia que permita a organização, a preparação e a análise de diferentes fontes de dados, visando caracterizar as condições de tráfego, em tempo próximo ao real, com base na estimação das condições do fluxo do tráfego na rede urbana de uma grande cidade.

## 1.3 QUESTÕES DE PESQUISA

- a) Como caracterizar as condições de tráfego no ambiente urbano?
- b) Como complementar as falhas de dados dos sensores em tempo próximo ao real?
- c) Como detectar a existência de incidentes imprevistos nas vias e como utilizar essa informação na ferramenta de previsão de tráfego?

- d) É possível definir padrões sazonais para o tráfego que sirvam de base para a melhoria da ferramenta de previsão?
- e) Como prever a situação do tráfego de uma grande cidade como São Paulo em tempo próximo ao real e para prazos acima de 30 minutos?

#### 1.4 ORGANIZAÇÃO

O presente texto está estruturado em 5 partes, iniciado pela Introdução, na qual apresentamos a motivação e os objetivos da pesquisa. Na segunda parte tratamos da vasta base teórica de nossos estudos, incluindo os conceitos envolvidos na pesquisa e a indicação de diversos trabalhos de previsão de tráfego já desenvolvidos. Na terceira parte é apresentada nossa proposta de solução para as questões apresentadas e na parte seguinte apresentamos os estudos preliminares já desenvolvidos com base nos dados disponíveis. Por fim são apresentadas as conclusões finais e as propostas de prosseguimento dos trabalhos.

## 2 BASE TEÓRICA

### 2.1 PREVISÃO DE TRÁFEGO

As previsões de tráfego podem ser classificadas de acordo com seu horizonte de previsão para curto (de poucos minutos a até 2 ou 3 horas) e longo prazo (vários dias à frente).

A previsão de curto prazo das condições do tráfego para um horizonte de minutos ou horas, feita em tempo próximo ao real, mostra-se viável como ferramenta de gestão integrada a diversas outras ferramentas de ITS, possibilitando melhor desempenho aos sistemas de coordenação semaforica, de programação e operação de veículos de transporte público, de informação aos usuários, de programação de frotas de transporte cargas e de roteamento de veículos, dentre outros.

A previsão de curto prazo também pode ser utilizada nos Centros de Gerenciamento Operacional na tomada de decisão em tempo próximo ao real, comparando cenários de alternativas operacionais para situações em andamento. (BARROS, 2014; SLOBODEN et al., 2012; VLAHOGIANNI; KARLAFTIS; GOLIAS, 2014).

A Previsão de Tráfego de curto prazo pode ser classificada em dois tipos de abordagem (GENTILE; MESCHINI, 2011): Reconhecimento de Padrão e Interpretação Física do Fenômeno de Tráfego. De modo semelhante (VAN LINT; HOOGENDOORN; VAN ZUYLEN, 2005) classificam os sistemas de previsão em 3 grupos, sendo os dois primeiros uma subdivisão do grupo Reconhecimento de Padrão proposto por Gentile e Meschini (2011): Previsões On-Line ou Instantâneas, Previsões baseadas em dados dirigidos e Previsões Baseadas em Modelos. Assim temos:

- a) Reconhecimento de Padrão – baseada em inferência estatística, séries temporais, mineração de dados e/ou métodos de inteligência artificial, com base nos dados históricos. Busca identificar o padrão de tráfego de um dado link da rede, e com base na projeção de novas demandas estima a evolução futura.  
Este tipo de abordagem não é capaz de tratar situações inesperadas e não previstas e eventos atípicos, como acidentes, uma vez que os mesmos ocorrem de modo aleatório na rede e não são previamente registrados em quantidade suficiente para que o modelo possa se adaptar (GENTILE; MESCHINI, 2011; SEO et al., 2017b). Criar e treinar esse tipo de sistema para as situações atípicas significaria uma infundável sequência de

suposições e treinamentos de modelos e ainda assim seria possível a ocorrência de situações não definidas e treinadas previamente;

- b) Interpretação Física do Fenômeno de Tráfego – baseada na modelagem da interação entre demanda de viagem e a rede viária através da alocação do tráfego. Normalmente efetuada com o uso de simuladores de tráfego, que simulam a propagação do fluxo na rede, inclusive para os locais não monitorados em tempo real.

Nesta abordagem é possível efetuar previsões do tráfego também em situações não ocorridas anteriormente, efetuando ajustes:

- na capacidade (oferta), nos casos de acidentes, obras na via, inclusão de novas vias, manifestações;
- na demanda, em decorrência de eventos na via ou em locais de concentração de público (estádios, casas de show) ou da criação/fechamento de empreendimentos geradores de tráfego (shopping-centers, condomínios residenciais e comerciais, etc.) efetuando a redistribuição do fluxo pela rede com base nessas premissas. (GENTILE; MESCHINI, 2011; SEO et al., 2017b).

Certamente, propostas de soluções híbridas tem surgido ao longo do tempo, mostrando-se promissoras ao utilizar as melhores características de cada solução (ALLSTRÖM et al., 2016; GLIŠOVIĆ et al., 2016; TSELENTIS; VLAHOGIANNI; KARLAFTIS, 2015; VAN LINT; HOOGENDOORN; VAN ZUYLEN, 2005).

### **2.1.1 Estimação do Estado do Tráfego ou Previsão de Tráfego?**

Por vezes a expressão Estimação do Estado do Tráfego tem sido utilizada como sinônimo de Previsão de Tráfego em momento futuro, ao “estimar” a situação futura. Em nossa aplicação procuraremos separar os dois conceitos, conforme sugerido por Van Lint, Hoogendoorn e Van Zuylen (2005). Assim:

- a) A Estimação do Estado do Tráfego consiste em determinar a situação do tráfego em determinado local num determinado momento e está normalmente relacionada à determinação da situação presente do tráfego (ALFREDO NANTES et al., 2016; GRUMERT; TAPANI, 2018; KAWASAKI et al., 2016; LI et al., 2014; SEO et al., 2017a). Esta é a etapa na qual ocorre o tratamento dos dados vindos de diversas fontes com o objetivo de caracterizar o tráfego. São incluídos



principalmente estudos com uso de sensores ITS e dados de posicionamento de celulares e de veículos;

- b) A Previsão de Tráfego consiste em determinar condições em que o tráfego, numa determinada via ou rede viária, estarão após algum tempo, podendo ser de curto ou longo prazo, conforme já descrito (BOLSHINSKY; FRIEDMAN, 2012; ERMAGUN; LEVINSON, 2018; FUSCO et al., 2015; FUSCO; COLOMBARONI; ISAENKO, 2016; LAÑA et al., 2018; MENA-YEDRA; GAVALDÀ; CASAS, 2017; NUZZOLO et al., 2016; TSELENTIS; VLAHOIANNI; KARLAFTIS, 2015; VLAHOIANNI; KARLAFTIS; GOLIAS, 2014). Os estudos de Previsão de Tráfego são baseados nas situações presente e passada do tráfego, obtidas nos estudos de Estimação do Estado do Tráfego.

A estimação e os estudos de previsão estão relacionados às características do tráfego. Na literatura acadêmica foi possível verificar estudos relativos a: velocidade e tempo de percurso (ALLSTRÖM et al., 2016; CHEN; CHIEN, 2001; CHEN; OSORIO, 2014; CIPRIANI et al., 2014; GENTILI; MIRCHANDANI, 2018; HIRIOTAPPA et al., 2017; LADINO et al., 2017; TANG et al., 2017; TETTAMANTI; HORVÁTH; VARGA, 2014; WANG; PAPAGEORGIOU; MESSMER, 2006), densidade (LAURA MUIIOZ et al., 2003; QIU et al., 2010; T. DARWISH; K. ABU BAKAR, 2015; WADDOO et al., 2016), fluxo (CASTILLO et al., 2015; GIACOMO COMO, 2017; MEIER; WEHLAN, 2001; STATHOPOULOS; KARLAFTIS, 2003) e nível de serviço (SAHA et al., 2016).

Boa parte dos estudos de Previsão verificados partem do princípio que os dados de Estimação estão disponíveis e que não existe a necessidade de tratar lacunas ou falhas. Em alguns casos é indicada a necessidade de uma fase inicial de tratamento dos dados para preparação, todavia não fazem menção da metodologia a ser empregada no tratamento de falhas. Na mesma direção muitos dos estudos de previsão, especialmente aqueles baseados em Reconhecimento de Padrão, trabalham com a situação média e desconsideram as situações atípicas.

Conforme apontado em estudos anteriores (BLIEMER et al., 2014; HABTEMICHAEL; CETIN, 2016; HEILMANN et al., 2014; LI et al., 2014, 2015; LI; LI; LI, 2013; LI QU et al., 2009; SERNEELS; VERDONCK, 2008; VAN LINT; HOOGENDOORN; VAN ZUYLEN, 2005; WANG; MAO, 2019; XING et al., 2015), existe a necessidade de tratar essas lacunas e falhas nos dados para possibilitar o correto funcionamento do modelo de previsão.

Da mesma forma, nos trabalhos de previsão estão naturalmente incluídos os estudos do impacto de incidentes (ASAKURA et al., 2017; BAIOCCHI et al., 2015; BURGHOUT;

KOUTSOPOULOS; ANDREASSON, 2010; DIA; THOMAS, 2011; FHWA OFFICE OF HIGHWAY INFORMATION MANAGEMENT, 1998; PAN et al., 2013; PARK; OH, 2015; R.X.ZHONG et al., 2017; WANG; QI; JIANG, 2018) e de condições meteorológicas (GONÇALVES, 2018; HOU et al., 2013; TANISHITA; VAN WEE, 2017; TSELENTIS; VLAHOGIANNI; KARLAFTIS, 2015).

Os sistemas de previsão de tráfego estão apoiados em dois principais pilares: a Demanda e a Oferta. Para a aplicação de modelos de estimação e de previsão de tráfego em tempo próximo ao real existe a necessidade objetiva de atualização de dados também em tempo com essa característica. Nesse sentido, tanto a oferta, que é caracterizada pela capacidade disponível do sistema (rede viária disponível, planos semaforicos, quantidade de ônibus disponível, capacidade do transporte por meio ferroviário, etc.), como a demanda dos usuários pelo transporte individual e coletivo, devem ser mantidas atualizadas.

A maior parte dos estudos de previsão, incluídos nas revisões já citadas, tem se dedicado à análise da variação da demanda. Pouco tem se tratado da variação da oferta, eventualmente por se tratar de item mais estável com relação à demanda, especialmente em se considerando que grande parte dos estudos disponíveis se dedicaram à análise de trechos de vias expressas.

## 2.2 DEMANDA

A demanda por mobilidade é algo inerente ao ser humano desde sua origem. Nos centros urbanos essa demanda se caracteriza pela necessidade de se deslocar entre os locais de residência, trabalho, estudos, compras e lazer. Os estudos dessa matéria são realizados principalmente com base nas pesquisas de Origem e Destino, das quais resultam as Matrizes OD (Origem/Destino) que são compostas pelas quantidades de viagens com origem em cada sub-região de estudo e destino em outra.(ORTÚZAR; WILLUMSEN, 2011)

O uso do rastreamento de celulares também tem sido estudado como base para a elaboração de Matrizes OD (CAMUS; CANTARELLA; INAUDI, 1997b; HORANONT et al., 2013; MD. SHAHADAT IQBAL et al., 2014).

A definição da matriz OD para a Cidade de São Paulo, historicamente tem sido feita com base em pesquisa domiciliar do Metrô. Essa matriz tem servido de base para as simulações de tráfego de diversas empresas, sempre com foco no planejamento e leva em conta apenas os dias úteis.

Novas tecnologias e dados estão disponíveis atualmente. Uma das novas formas de se obter a matriz OD tem sido a utilização dos dados de rastreamento de celulares (CALABRESE; LORENZO, 2011). Esta metodologia permite a análise e obtenção de matrizes OD com grande granulometria, tendo em vista a quantidade de celulares hoje utilizada pela população. Também é possível através dessa metodologia a avaliação da Origem e Destino de pessoas que comparecem a eventos (CALABRESE et al., 2010), o que possibilita maior qualidade na definição de alterações na matriz OD em decorrência desses eventos. Todavia, este tipo de dado não estava disponível para nossa pesquisa, motivo pelo qual não foi utilizado.

Outra forma de se obter uma matriz OD que indique as alterações ocorridas ao longo dos dias, em dias especiais e também para detectar as alterações ocorridas ao longo do tempo, decorrentes de mudanças na ocupação do solo, disponibilidade de residências e empregos, etc, é a utilização de informações provenientes de sensores ITS. São dois os principais tipos de sensores que podemos utilizar:

- a) Sensores que identificam veículos através da sua placa e que com isso possibilitam verificar que um mesmo veículo trafegou de um ponto a outro (KIM et al., 2016; ZHU et al., 2016a, 2016b, 2017). Todavia esta metodologia está restrita à distribuição dos sensores pela rede. (CAMUS; CANTARELLA; INAUDI, 1997a; ZHU et al., 2016a, 2017);
- b) Bilhetes de transportes como o bilhete único do Município de São Paulo e o bilhete BOM, utilizado no transporte metropolitano, os quais, em conjunto com a caracterização da rede de transportes, possibilitam inferir o deslocamento da população que se utiliza de transporte público. A própria SPTrans já tem avaliado este tipo de uso no caso dos ônibus urbanos municipais com base no Bilhete Único Municipal.

No futuro poderemos utilizar dados de sistemas de compartilhamento de bicicletas e patinetes como o Tembici e Yellow, disponíveis na Cidade de São Paulo, e dados dos veículos rastreados e veículos autônomos.

Embora não seja necessária a atualização da matriz em tempo real, verificamos um estudo que propõe a previsão da OD da próxima hora (WOO; TAK; YEO, 2016) com uso de *k*-nearest neighbors (*k*-NN).

Cabe aqui destacar que o tema de pesquisa e determinação de matrizes de Origem e Destino, pelos diversos métodos já citados, está além do escopo de nosso trabalho, de modo que utilizaremos matrizes já existentes ajustadas para os diversos casos citados no capítulo 3.

### **2.2.1 Sazonalidade e outras variações da Demanda**

A sazonalidade do tráfego ao longo dos meses do ano, com redução do fluxo nos meses de férias escolares, dos dias da semana, com redução da demanda aos finais de semana e também ao longo das horas do dia, com concentração da demanda nos horários de pico da manhã e da tarde, já é conhecida e estudada na engenharia de tráfego (STATHOPOULOS; KARLAFTIS, 2001).

Os dias úteis são a base normalmente utilizada para a matriz OD nos estudos de planejamento de tráfego. Por outro lado, a elaboração de matrizes OD nos dias de finais de semana e feriados são bem menos frequentes. Para os estudos de previsão de tráfego a diferença dos dias úteis para os demais deve ser considerada.

Especificamente a sazonalidade ocorrida ao longo das horas do dia interessa aos sistemas de previsão de tráfego em tempo real (CHEN et al., 2012; MUSSONE, 2017; YANG et al., 2016). No capítulo 4, de análise dos dados, apresentaremos algumas informações relativas ao Município de São Paulo.

A alteração da demanda decorrente da implantação de polos geradores de tráfego também vem sendo avaliada pelos gestores urbanos visando estudos de projetos e intervenções no sistema viário e de transportes. Os sistemas de previsão devem se apropriar das informações geradas nas análises de polos geradores a fim de aumentar sua acurácia, uma vez que os mesmos alteram a Matriz OD pois, em geral, geram e atraem volumes consideráveis de viagens.

Já a análise da demanda, decorrente de eventos, é menos utilizada nos sistemas de previsão. Todavia, esta é uma das grandes fontes de demanda de direcionamento do tráfego numa grande cidade como São Paulo, onde existem diversos centros de exposições, grandes casas de show e 4 grandes estádios de futebol, capazes de receber milhares de pessoas em dias de eventos.

Quanto à definição da Origem das viagens relacionadas aos grandes eventos e das rotas utilizadas, como já citado, hoje verifica-se a possibilidade de utilização de dados de rastreamento de celulares.


Outras situações também imprevistas podem alterar a Demanda por viagens de modo pontual e temporário, como a ocorrência de manifestações nas vias, de greves nos sistemas de transportes públicos, ou ainda a ocorrência de chuvas intensas. Todas essas situações podem alterar o planejamento dos indivíduos alterando também seu desejo (demanda) por realizar um deslocamento.

Existem ainda, embora mais raras, situações atípicas e não planejadas que podem afetar e reprimir de forma generalizada a Demanda por mobilidade de toda uma cidade, alterando comportamentos e a utilização histórica do viário. Exemplos disso foram: a) a greve nacional dos caminhoneiros ocorrida no mês de maio de 2018, com duração de 11 dias, com grande impacto na demanda de mobilidade ocasionada pela falta de combustível nos postos de distribuição; b) greve da Polícia Militar no Estado do Espírito Santo, com impacto objetivo na segurança pública e que, por consequência, gerou o fechamento do comércio e a suspensão de aulas nas escolas por diversos dias.

O acompanhamento do tráfego em tempo real pode também indicar variações em relação à situação cotidiana, servindo como detectores de eventuais alterações pontuais de demanda resultantes de fatores exógenos.

Uma característica relevante é o modo de deslocamento utilizado pela população ao longo do dia. Enquanto nos picos os deslocamentos por transporte público e particular são a maioria, no horário do almoço o deslocamento a pé se sobressai, provavelmente em decorrência dos deslocamentos de trabalhadores entre suas empresas e locais de refeição próximos. A Figura 1 apresenta a distribuição horária de viagens, obtida com base na matriz OD 2012 do Metrô.

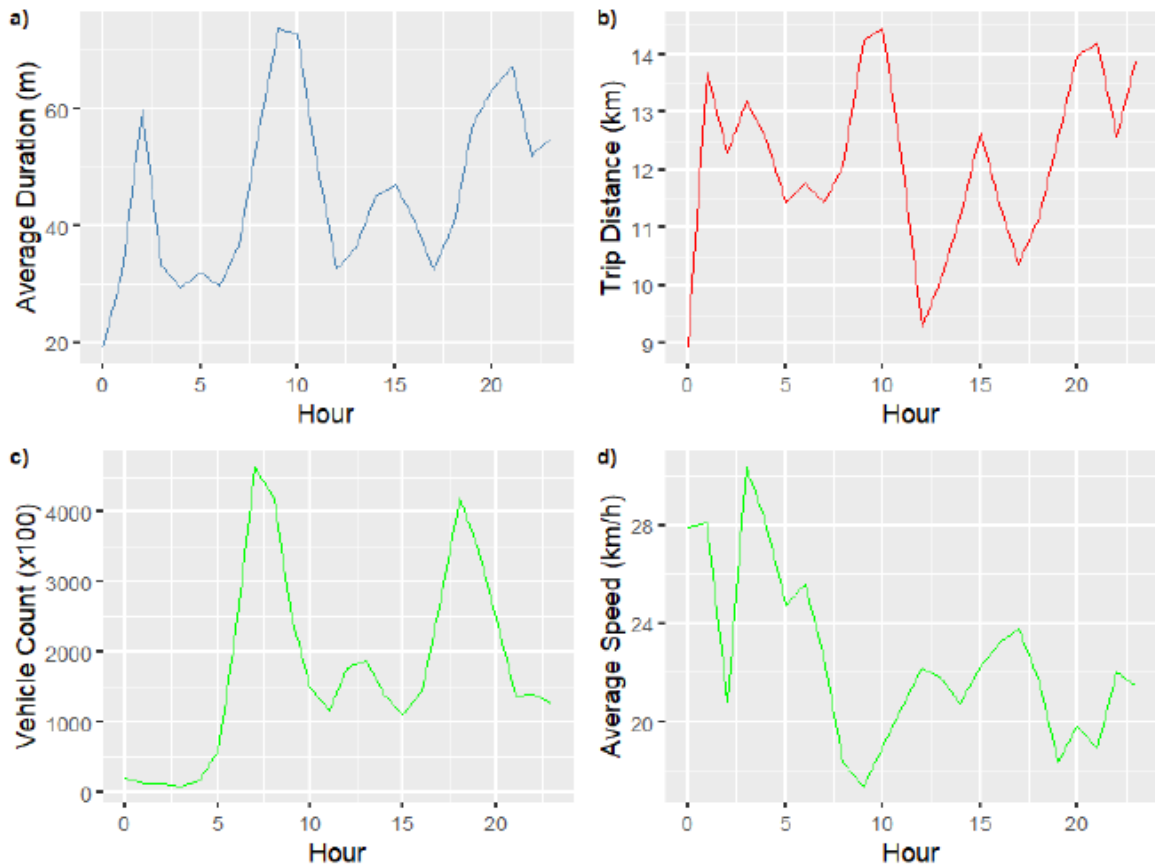
Figura 2.1 – Distribuição horária de Viagens na Cidade de São Paulo



Fonte: Santana (2019)

A característica do fluxo, obtida com base na matriz OD 2012, é apresentada na Figura 2 e, como era de se esperar, os volumes de viagens são maiores nos picos e a velocidade é maior na madrugada. A duração da viagem está relacionada com o volume de viagens, todavia com um atraso de cerca de 2 horas, ou seja, primeiro a demanda aumenta e vai sobrecarregando a rede (SANTANA, 2019). Com a rede sobrecarregada, mesmo com o decréscimo da demanda as viagens duram um tempo maior devido à velocidade de trajeto. A distância das viagens efetuadas está relacionada com o movimento dos picos, principalmente por incluir as viagens casa/trabalho, todavia, neste caso, as viagens realizadas na madrugada, embora em volume muito menor, também se apresentam com extensões acima da média.

Figura 2.2 – Distribuição horária das Características das Viagens na Cidade de São Paulo: a) Tempo de Duração da Viagem; b) Distância percorrida na viagem; c) Fluxo; d) Velocidade Média.



Fonte: Santana (2019)

### 2.2.2 Escolhas de Rota – Aplicativos e Veículos Autônomos

A demanda se concretiza através do uso das vias e sistemas de transportes. Esse uso depende de escolhas feitas pelos usuários, de modo que usuários de veículos individuais têm maior flexibilidade na escolha de trajetos, enquanto usuários do transporte coletivo devem optar por um modal e pelas rotas e trajetos disponíveis no sistema.

Num momento em que os veículos autônomos estão se tornando realidade, não podemos nos olvidar de considerar fatores como a metodologia de escolha de rota que será implementada em seus algoritmos. Existe a necessidade de aprimorar as informações e modelos de tráfego de modo a permitir o melhor desempenho desse novo tipo de veículo.

(CONCEIÇÃO; ROSSETTI, 2016). Uma possibilidade é de que os algoritmos dos veículos autônomos busquem traçar rotas que representem “menor custo”.

Cabe aqui considerar o significado da expressão “menor custo”. Na área de planejamento e operação do tráfego, a qual, embora inclua, não se restringe unicamente à visão monetária do deslocamento (custos de combustível, aquisição e manutenção do veículo, tarifas do transporte público, pedágios, etc). Outros fatores como a distância percorrida, o tipo de via utilizada, a segurança de tráfego e o “custo do tempo” dispendido num trajeto das pessoas, em cada modo de transporte, devem certamente ser considerados.

Devemos também considerar que atores diferentes terão visões diferentes de custo. De um lado os gestores urbanos de sistemas de transportes e tráfego buscam a otimização do custo generalizado para toda a população, como no uso de macromodelos de simulação de tráfego - utilizados para o planejamento do tráfego a longo prazo. De outro lado, o indivíduo leva em conta principalmente o seu custo individual de mobilidade, como ocorre com o uso de sistemas de indicação de rotas como Waze, Here, Tomtom e Google,<sup>1</sup> que operam buscando indicar as rotas de menor custo (tempo) aos seus usuários e com isto desconsideram o impacto de suas escolhas no custo (tempo) dos demais indivíduos. Decisões focadas na visão individual por vezes geram um efeito inverso ao indivíduo que se vê numa via de pouca capacidade e congestionada por decorrência do acúmulo de veículos direcionados pelo aplicativo (UOL, 2016).

Também devemos considerar que, como consequência direta da escolha automatizada de rotas de menor custo, diversas vias locais poderão sofrer com o acúmulo de tráfego de passagem, desconsiderando sua característica como espaço de convivência e interação entre vizinhos. Isto se agrava no caso das rotas serem de menor tempo e com ajuste durante o trajeto.

Outro aspecto na definição automatizada de rotas é que quando baseada apenas na situação do momento inicial da viagem, deixa de considerar as alterações temporais que ocorrem nos fluxos e na ocupação das vias gerando estimativas de tempo de viagem normalmente equivocadas, especialmente para os trajetos mais longos.

Alguns roteadores efetuam ajustes durante o trajeto ao “perceberem” alterações ocorridas na situação do tráfego na rede. O ideal seria que se utilizassem de sistemas de

---

<sup>1</sup> [www.waze.com/pt-BR](http://www.waze.com/pt-BR) ; [wego.here.com/traffic/brazil/sao-paulo](http://wego.here.com/traffic/brazil/sao-paulo) ; [www.tomtom.com/pt\\_br/drive/tomtom-traffic/](http://www.tomtom.com/pt_br/drive/tomtom-traffic/) ; [www.google.com.br/maps/](http://www.google.com.br/maps/)



previsão de curto prazo para efetuar o roteamento de menor custo, já considerando as alterações passíveis de previsão durante o trajeto.

Na mesma direção, (KIM et al., 2016) avaliaram a utilização de um algoritmo baseado na previsão do tráfego para o roteamento dinâmico de veículos, sendo que neste caso eles indicam que tal sistema deveria ser gerido por um controlador central de rotas. Os resultados mostraram que mais da metade do benefício desta solução é atingida mesmo quando apenas 30% dos usuários a utilizam. Isto mostra o potencial da ferramenta que utilizasse de modo conjunto a previsão de tráfego e a simulação de trajetos de menor custo.

A escolha de rotas também é afetada pela experiência do usuário. Shao et al. (2006) indicaram que em sua jornada diária o usuário opta por rotas conhecidas, pois sente maior confiabilidade no tempo de trajeto. Isto ocorre mesmo quando o tempo de trajeto é um pouco maior do que em rotas alternativas, indicadas por aplicativos de roteamento. Assim, concluem que, o usuário apenas altera sua rota com base na indicação de um aplicativo se o tempo de percurso usual estiver muito acima da média diária.

Devemos ainda considerar que o uso de um sistema de previsão de tráfego centralizado poderia oferecer análises de rotas de menor custo global, ao considerar o custo de todos os usuários da rede. Integrando-se o sistema de previsão de tráfego com os equipamentos de campo esse sistema poderia enviar informações aos usuários da via através de sistemas de comunicação Veículo x Infraestrutura, possibilitando a orientação decorrente de situações inesperadas e da reordenação do tráfego. Os veículos autônomos também poderão se utilizar dessa ferramenta, obtendo e repassando informações diretamente da rede e de servidores remotos, podendo efetuar a revisão de rotas ao longo do trajeto.

### 2.3 OFERTA

Muitos sistemas de previsão de curto prazo, principalmente os baseados em Reconhecimento de Padrão, consideram a “Oferta” como um ente invariável e sempre disponível. Apenas alguns poucos estudos buscam incluir o impacto da alteração da oferta causada por condições climáticas e acidentes (CASTRO-NETO et al., 2009; SALAMANIS et al., 2017; VAN LINT; HOOGENDOORN; VAN ZUYLEN, 2005) e também Fei et al, 2011 e Min, Wynter 2011 apud (VLAHOGIANNI; KARLAFTIS; GOLIAS, 2014)),.

A Oferta é caracterizada pela capacidade da rede viária disponível. Características como largura, declividade, tipo de pavimento e uso do solo lindeiro à via devem ser consideradas na definição inicial da capacidade de uma via. (TRANSPORTATION RESEARCH BOARD, 2016)

Os simuladores utilizam-se de mapas digitais que representam essa rede, com seus links e nós. Os links são os trechos de via e devem ser caracterizados a fim de possibilitar a definição de sua capacidade e das características que definem a relação entre fluxo, velocidade e densidade, possibilitando assim análises de tempo de percurso e outros custos associados. Os nós, são os encontros de dois ou mais links e podem ser ou não dotados de sistema de controle como placas “Pare” e “Dê a Preferência” ou semáforos.

Embora em ritmo muito inferior ao da demanda, a oferta numa rede urbana, como a de São Paulo, varia constantemente como decorrência de diversas situações que geram impactos de média e longa duração:

- Locais: alteração do sentido circulação das vias, alteração na regulamentação de estacionamento, implantação de semáforos, alteração da geometria viária em pontos específicos, implantação de projetos de sinalização em geral, etc.;
- Regionais: implantação de Polo Gerador de Tráfego, construção de uma nova estação de trem ou metrô, bloqueio ou inauguração de uma via arterial;
- Estruturais: implantação de novas redes de transportes, implantação de novas linhas de trem e metrô, implantação de rede cicloviária, alteração do limite de velocidade em diversas vias simultaneamente, inclusão de novos meios como compartilhamento de patinetes e bicicletas, aplicação de restrições ao tráfego como áreas de proibição ao tráfego de caminhões, rodízio do uso de veículos com base na placa (existente em São Paulo) e pedágio urbano dentre outros.

Outros fatores influenciam a capacidade por curtos períodos, como as alterações de planos semaforicos, a regulamentação de estacionamento ao longo da via em determinados horários e a densidade do tráfego.

Com relação à regulamentação de estacionamento, devemos considerar que inúmeras vias têm estacionamento liberado nos horários de menor fluxo e proibido nos horários de pico, exatamente para aumentar a capacidade de escoamento da via.

A situação do tráfego, caracterizada pela densidade, velocidade e fluxo, impacta diretamente na capacidade do sistema viário e também deve ser acompanhada. Vias com alta densidade operam em Níveis de Serviço ruins (TRANSPORTATION RESEARCH BOARD, 2016),

impactando negativamente a capacidade do trecho. Em casos críticos verifica-se o congestionamento do trecho, situação em que a capacidade momentânea tende a valores muito baixos, com velocidades próximas a zero.

O impacto de uma via em outra é direto, de modo que em situações de volumes de fluxo acima do limite de fluxo livre, os trechos de via passam a ter baixa capacidade em decorrência da alta densidade. A consequência é popularmente conhecida como congestionamento. Assim, veículos provenientes de outros trechos que tentam adentrar no trecho sobrecarregado não conseguem ou o fazem com certa dificuldade e, portanto, o fluxo fica retido nesse trecho a montante.

Em seus estudos, Park et al. (2017) indicam que carros conectados podem resultar em uma solução ao tráfego intenso pois propiciam maior uniformidade do fluxo e com isto maior volume de veículos que podem utilizar um mesmo trecho de via. O controle de velocidade e aceleração dos veículos propicia maior uniformidade no fluxo e menor risco de acidentes. No entanto, situações próximas à capacidade da via são pouco afetadas por esta solução. Destaca-se que este tipo de abordagem é adequada aos veículos autônomos, já que possuem “inteligência” que lhes permite “conversar” com os demais veículos e com a infraestrutura e com isto identificar a necessidade e oportunidade de ajustar sua velocidade automaticamente.

No tocante às alterações nos tempos semafóricos devemos considerar que o aumento ou redução dos tempos de verde de uma aproximação impactam diretamente na capacidade de escoamento do tráfego do link correspondente. Por outro lado, o ajuste nos tempos semafóricos é feito de modo a atender à demanda de tráfego e, portanto, visualiza-se uma situação de duplo impacto, onde demanda e capacidade interferem entre si, motivo pelo qual os modelos de previsão de tráfego devem considerar as alterações nas programações semafóricas que ocorrem ao longo do dia.

Assim, o sistema de previsão de tráfego deve estar abastecido das informações das programações semafóricas e, no caso de redes de “semáforos inteligentes”<sup>2</sup>, este abastecimento de informação deve ser feito em tempo real, através de integração entre os sistemas, mantendo a informação de capacidade da rede de acordo com a situação fática de campo.

---

<sup>2</sup> Semáforos inteligentes: são semáforos que trabalham ajustando os tempos de ciclo e de distribuição de fases com base na atuação, contagem da demanda

A situação ideal seria aquela em que, por processo iterativo, a previsão consideraria a informação do sistema de semáforos e este por sua vez efetuaría ajustes minimizando o impacto previsto no sistema de previsão (SHAFIEI; SABERI, 2018). Propostas que integram diversos algoritmos ou sistemas têm sido avaliadas com bons resultados (MIRCHANDANI; LI; ZHOU, 2017). Pela complexidade de implementação desta integração trocando e efetuando ajustes em tempo real nos dois sistemas, nossos estudos estarão restritos à inclusão da programação básica dos semáforos da rede.

### **2.3.1 Impacto de Fatores Externos**

No tocante à capacidade do sistema temos que a rede de vias, como meio físico, sofre o impacto de incidentes, obras, eventos e intempéries entre outros. Como fontes de atualização de dados temos as informações das equipes operacionais de campo que operam o tráfego, informações obtidas através de redes sociais e que são inseridas nos sistemas pelas equipes das Centrais Operacionais, dados de sistemas meteorológicos e dados de alertas do Waze.

Exemplos disso foram: a) a queda de viaduto da Marginal Pinheiros em novembro de 2018, interditando por completo a utilização das 4 faixas de rolamento da pista expressa de uma das principais vias estruturais da cidade; b) A colisão de dois caminhões com a explosão de um deles, que causou a interdição do Viaduto Santo Amaro em ambos os sentidos, por 6 meses, e a criação de novos acessos e semáforos para desvios em 2016.

O impacto negativo das condições meteorológicas, em especial de chuva e neblina deve ser considerado de modo a ajustar temporariamente a capacidade da rede. Como exemplo verificamos que o transporte coletivo é afetado pela presença de chuva, tendo sua velocidade média reduzida (GONÇALVES, 2018).

## **2.4 RELAÇÕES BÁSICAS DO TRÁFEGO**

O diagrama fundamental do fluxo de tráfego foi apresentado por Greenshields em 1933 no 13º Encontro Anual do Highway Research Board. O diagrama, composto por 3 gráficos inter-relacionados, propõe uma relação linear entre fluxo e densidade e relações parabólicas entre a velocidade e o fluxo e entre a velocidade e a densidade.

Esse diagrama vem sendo estudado ao longo dos 85 anos que se seguiram e diversas adaptações, com maior ou menor detalhamento, foram apresentadas em textos científicos. Em 2008 ocorreu um Simpósio em comemoração aos 75 anos do diagrama de Greenshields reunindo diversos desses estudos (TRB, 2011a).

A Figura 2.3 foi apresentada no citado Simpósio comemorativo (RAKHA; GAO, 2010a) e mostra as variações do diagrama fundamental inicial que são utilizadas por alguns microssimuladores de tráfego.

Figura 2.3 – Diagramas da Relação Fundamental do Fluxo de Tráfego utilizados em microssimuladores de tráfego

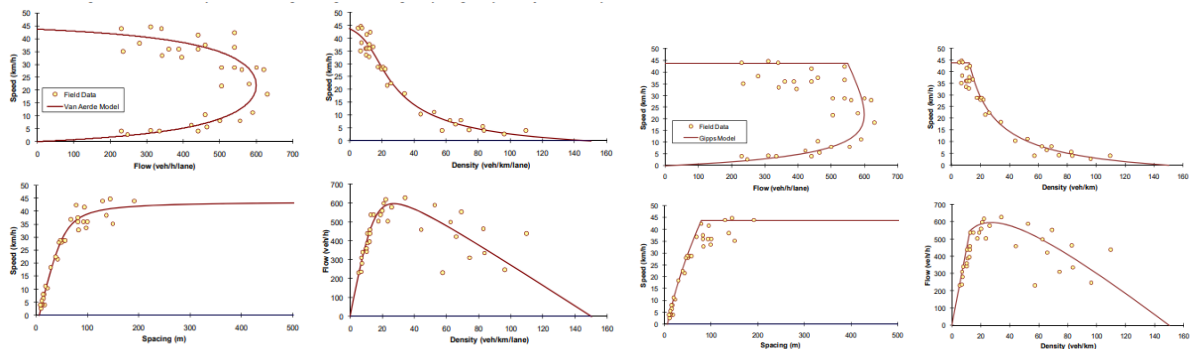


Figure 7: Sample Calibration of the Van Aerde Model

a) Van Aerle / Integration

Figure 2: Example Illustration of Gipps Model Calibration

b) Gipps / Aimsun2

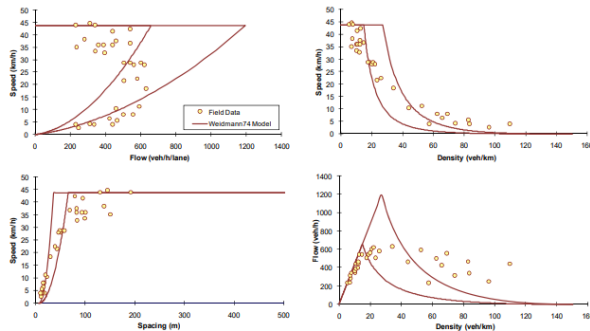


Figure 3: Sample Calibration of the Wiedemann74 Model

c) Windermann 74 / Vissim

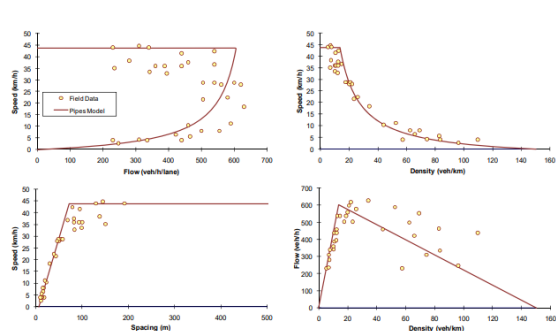


Figure 1: Example Illustration of Pipes Model Calibration

d) Pipes / Corsim

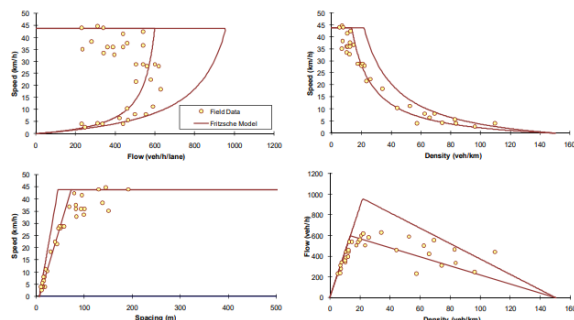


Figure 6: Sample Calibration of the Fritzsche Model

e) Friezch / Paramics

Para cada modelo da Figura 2.3 são apresentados 4 gráficos dispostos em sentido horário e que relacionam respectivamente Velocidade x Fluxo, Velocidade x Densidade, Velocidade x Espaçamento e Fluxo x Densidade. Os gráficos apresentados mostram pontos de uma mesma base de dados, tornando possível a comparação visual de sua aderência e representação dos dados originais. Os autores concluem que os modelos a) e b) são mais flexíveis e representam melhor o comportamento dos motoristas.

Por outro lado, como nosso objetivo é trabalhar com um sistema de previsão de tráfego em tempo próximo ao real, onde o desempenho computacional é importante, precisamos de sistemas que sejam mais rápidos que o tempo real, em outras palavras, sistemas capazes de simular 1 hora da situação futura em poucos minutos ou segundos, para tal podemos utilizar estratégias que minimizem o volume de cálculos otimizando o processamento.

Uma das formas de otimização é a linearização do modelo (BURGHOUT; KOUTSOPOULOS; ANDREASSON, 2010). No estudo os autores compararam o tempo de processamento de um mesmo simulador utilizando ora o modelo linear ora o modelo não linear para a representação da relação fluxo x densidade. Como resultado obtiveram um ganho de 33% no tempo de processamento. Em contrapartida o desvio quadrático médio passou de 0,035 para 0,038, ou seja um pequeno aumento no erro para um grande ganho em processamento.

Uma vez que os tipos de dados disponíveis em cada sistema ITS é dependente do tipo de sensor utilizado, as informações obtidas também diferem, assim, enquanto um sensor é capaz de apenas contar veículos outro é capaz de definir a velocidade dos mesmos. Assim, o uso das relações básicas nos permitem uniformizar as informações das diversas origens e tipos, visando sua inserção em outros sistemas.

## 2.5 ANÁLISE ESPAÇO -TEMPORAL

Nos estudos de Previsão de tráfego a análise relacional de espaço e tempo é primordial, haja vista que o tráfego tem essa característica de comportamento, alterando-se ao longo do tempo e dependente dos espaços por onde ocorre.

Também é importante considerar as sazonalidades que ocorrem ao longo do tempo e seu impacto na previsão. Assim, os horários de maior demanda de tráfego, como os horários de pico ou a situação de demanda de fluxo em rodovias em início de feriados, devem ser vistos.

Do mesmo modo, não se pode prever o fluxo sem ter em conta a situação no instante anterior, uma vez que a distribuição da demanda varia em decorrência dos mais variados fatores.

As análises dos estudos de impacto espaço temporal nos sistemas de previsão de tráfego mostram que existem técnicas diversas para sua abordagem. Os modelos de Simulação de Tráfego são inerentemente dotados de análise espacial e, quando utilizados com a aplicação de Alocação Dinâmica do Tráfego, conforme descrito no item 2.6.1, incluem também a característica temporal. Já os sistemas de Reconhecimento de Padrão precisam se utilizar de técnicas específicas para atender essa característica. Para uma revisão do tema sugerimos as revisões apresentadas por (GANG; SHOUHUI; XIAOBO, 2016; PAVLYUK, 2019).

## 2.6 INTERPRETAÇÃO FÍSICA DO FENÔMENO DE TRÁFEGO - SIMULAÇÃO DE TRÁFEGO

Os Simuladores de Tráfego começaram a ser desenvolvidos na década de 1950 e buscam representar a utilização das vias pelos veículos e demais usuários a fim de possibilitar o planejamento de situações futuras e análises de novos projetos e soluções de controle de tráfego. (PORTUGAL, 2005)

Segundo Portugal (2005), os Modelos de Simulação computacional, de modo geral, consistem em representações matemáticas da realidade, sendo que os modelos de simulação de tráfego são aqueles que tratam de simular as situações e condições de tráfego de uma via, cruzamento ou rede viária.

Os Modelos de Simulação de Tráfego podem ser classificados de diversas formas. A principal classificação está relacionada com sua abordagem e resolução. Quanto maior a resolução maior a complexidade do modelo. (BURGHOUT; KOUTSOPOULOS; ANDREASSON, 2006a; PORTUGAL, 2005; SLOBODEN et al., 2012)

- a) Macro modelo – O fluxo é tratado como fluído e o modelo segue a base das leis da hidrodinâmica e as equações usadas descrevem o fenômeno das ondas de choque do tráfego. O fluxo é tratado de modo indivisível. Assim, os modelos são mais simples e seu processamento mais rápido. São utilizados nos estudos de planejamento de longo prazo e em grandes redes.
- b) Meso modelo – Modelos de resolução intermediária, onde os usuários podem ser identificados individualmente, mas a dinâmica do tráfego é estudada de modo agregado, onde os pelotões possuem velocidade e comportamento uniforme.

Trabalham com base na Teoria da Dispersão de Tráfego. Estes modelos tem recebido grande atenção nas pesquisas dos últimos anos, e tem servido de base para diversos modelos de simulação que trabalham integrados com sistemas em tempo real.

- c) Micro modelo – De resolução detalhada, tanto quanto necessário à análise pretendida, baseia-se no comportamento individual dos usuários, especialmente no tocante à interação entre os mesmos (carro seguidor e mudança de faixas). Utilizado nas análises de trechos de via e pequenas áreas, simulando o comportamento dos usuários com relação às alterações nos sistemas de controle como semáforos e rotatórias.
- d) Multi-Resolução – Tem sido usado mais recentemente e consiste na utilização conjunta e integrada das 3 abordagens anteriores. De modo geral a manipulação dos padrões de viagens é feita em nível macroscópico, o comportamento do usuário é analisado no modelo mesoscópico e em resolução microscópica são avaliados os impactos das estratégias de controle de intersecções.

Para a simulação de Cidades inteligentes é necessário modelar os veículos individualmente para analisar e modelar cenários. Contudo, não é necessário modelar os detalhes de interação entre veículos como ocorre nos microssimuladores, além da capacidade de modelar grandes redes viárias e um grande número de atores (SANTANA, 2019), de modo que os mesossimuladores se mostram mais adequados à essa tarefa.

O uso dos simuladores de tráfego como ferramenta de previsão de tráfego de curto prazo foi verificado em diversos textos científicos, dentre os quais podemos citar (BEN-AKIVA et al., 2002; BURGHOUT, 2005; BURGHOUT; KOUTSOPOULOS; ANDREASSON, 2010; GENTILE; MESCHINI, 2011; KUCHARSKI; KOSTIC; GENTILE, 2017; LU et al., 2015; PELL; MEINGAST; SCHAUER, 2017; XU; KONG; LIU, 2012). As simulações de curto prazo atingem em geral até 60 minutos, mas existem indicações de previsões para até 120 min.

Dentre os simuladores disponíveis no mercado, alguns se propõem a trabalhar com Previsão de Tráfego de Curto Prazo, sendo possível destacar: Optima (MESCHINI; GENTILE, 2009; PTV GROUP, 2017), Mezzo (BURGHOUT; KOUTSOPOULOS; ANDREASSON, 2006a), Renaissance (WANG; PAPAGEORGIU; MESSMER, 2006), Adarules (MENA-YEDRA; GAVALDÀ; CASAS, 2017), Dynasmart (BURGHOUT; KOUTSOPOULOS; ANDREASSON, 2010), Dyrbusrt (NUZZOLO et al., 2016) e DinaMIT (SESHADRI, 2011)



### 2.6.1 Alocação Dinâmica do Tráfego

A alocação da Demanda nos modelos de simulação de tráfego consiste em distribuir a demanda de viagens, prevista para a rede viária, ao longo do tempo. A previsão de tráfego está intimamente ligada à Alocação Dinâmica do Tráfego (DTA – Dynamic Traffic Assignment) e ao estado do tráfego e do sistema viário (SLOBODEN et al., 2012).

A Alocação Dinâmica do Tráfego tem sido aplicada de modo mais amplo nas últimas décadas e consiste em considerar o impacto do tempo no sistema, de modo que a variação da demanda ao longo do tempo é utilizada. Ela também consiste em verificar o impacto causado pelos usuários ao longo do tempo, de modo que usuários que ingressam na rede num momento posterior são afetados pelos seus antecessores (BARROS, 2018).

Conforme já descrito em item anterior, a demanda a ser alocada no modelo é geralmente obtida em pesquisas de Origem e Destino e pode eventualmente ser acrescida de outras informações relacionadas a demandas localizadas e sazonais como, por exemplo, aquelas causadas por eventos públicos de grande porte e movimentos direcionados às estradas nas saídas de feriados. Até mesmo situações imprevistas, como a concentração de pessoas em algum evento, podem ser incluídas na tabela de Destinos e com isso o modelo pode passar a considerar essa situação já no passo seguinte.

Assim, a demanda prevista pode variar não apenas com base na sazonalidade, mas também com base em situações previstas e até mesmo imprevistas. A maior parte dos modelos atualmente disponíveis pode trabalhar tanto com análises Estáticas (quando a dimensão tempo não é relevante) como Dinâmicas (necessária aos Modelos de Previsão de Tráfego).

## 2.7 RECONHECIMENTO DE PADRÃO

Bolsshinsky & Friedman (2012) apresentaram um resumo das técnicas de Previsão de Tráfego, destacando e comparando as técnicas de Reconhecimento de Padrão, servindo de base para aprofundamento nessas abordagens: Séries Temporais ARIMA (Sigla em inglês para Auto Correlação Integrada com Médias Móveis) e suas variações, Kalman Filter, Redes

Neurais, Análise por vizinhança (kNN), abordagem Bayesiana, ATHENA<sup>3</sup>, Markov Chain, Média Histórica, Regressão não Paramétrica, Regressão Linear, Lógica Fuzzy, Híbridos, entre outros métodos. O trabalho conclui que devem ser usadas técnicas híbridas na montagem de um modelo de previsão de tráfego.

Além das técnicas citadas no trabalho acima também localizamos trabalhos com o uso de Support Vector Regression (SVR)(CASTRO-NETO et al., 2009; LU; NI; WASHBURN, 2015; YAO; FANG; ZHANG, 2015), Análise de Componente Principal (JIANG et al., 2015; KUANG; AN; JIANG, 2015; LI QU et al., 2009; SERNEELS; VERDONCK, 2008; XING et al., 2015) e Wavelets (SUN; LENG; GUAN, 2015; ZHU et al., 2018).

Especificamente, com relação às Séries Temporais, verificamos nas diversas revisões já citadas no primeiro capítulo que o uso de ARIMA e suas variações e de Redes Neurais têm se mostrado como as alternativas mais viáveis. A Auto Correlação e a funcionalidade das Médias Móveis das séries temporais de tráfego já foi demonstrada por diversos autores (PAVLYUK, 2017; SCHIMBINSCHI et al., 2017), indicando variações relativas à espaço e tempo que por sua vez otimizam os resultados encontrados.

Embora o uso de técnicas de Inteligência Artificial e Redes Neurais possua processamento mais rápido e “leve” durante a etapa de previsão, esta abordagem implica em processamentos longos e pesados durante seu treinamento e preparo e por serem do tipo “caixa preta” dificultam a análise intuitiva dos resultados (SEO et al., 2017b). Por sua vez, (VAN LINT; HOOGENDOORN; VAN ZUYLEN, 2005) afirmam desenvolver um modelo “caixa branca” baseado em redes neurais com base na forma escolhida para o treinamento do modelo.

O uso desse tipo de ferramenta está baseado na disponibilidade de dados anteriores para treinamento dos modelos de Redes Neurais ou para a análise dos fatores de calibração do modelo ARIMA. Em ambos os casos apenas situações já vivenciadas são passíveis de reprodução e previsão, e existe a necessidade de treinamento do usuário para sua aplicação, uma vez que a mudança nos parâmetros e na abordagem utilizada podem interferir diretamente no resultado.

---

<sup>3</sup> ATHENA: A METHOD FOR SHORT-TERM INTER-URBAN MOTORWAY TRAFFIC FORECASTING  
<https://trid.trb.org/view/376928>

Cabe destacar que no caso do uso das técnicas de Reconhecimento de Padrão o sistema sempre precisa ser retreinado, o que só pode ser feito após o fato consumado, por exemplo, somente após a implantação de um novo polo gerador e após a verificação do impacto causado durante algum tempo é que é possível retreinar o modelo com novos valores para ajustá-lo.

Os sistemas de previsão de tráfego com o uso de Reconhecimento de Padrão de curto prazo, no geral têm sido apresentados para horizontes de 5, 10 e 15 min. Alguns estudos se apresentam com soluções para até no máximo 60 minutos, sempre com base na situação dos últimos momentos (LAÑA et al., 2018; VLAHOGIANNI; KARLAFTIS; GOLIAS, 2014). As previsões de longo prazo são baseadas em dados históricos, podendo atingir diversos dias à frente considerando a situação média do dia típico.

## 2.8 SOLUÇÕES HÍBRIDAS

Diversos estudos de soluções híbridas podem ser encontrados na bibliografia, unindo diferentes soluções de Reconhecimento de Padrão (GUO; POLAK; KRISHNAN, 2018; LOPEZ-GARCIA et al., 2016; SHANG et al., 2016; YAO; FANG; ZHANG, 2015; ZOU et al., 2015). Outros buscaram soluções híbridas com os diversos níveis de simulação (BURGHOUT; KOUTSOPOULOS; ANDREASSON, 2006b; MIRCHANDANI; LI; ZHOU, 2017).

E ainda alguns poucos autores que buscaram a solução híbrida de previsão de tráfego, envolvendo Modelos de Simulação e Estimação através do Reconhecimento de Padrão. Em ambos os casos a Estimação ocorreu com base em Redes Neurais e estava relacionada a uma única via.

Em seus estudos Allström et al. (2016) propuseram o uso híbrido de métodos paramétricos e não paramétricos para a elaboração de uma solução de Previsão de Curto Prazo da Estimação do Tráfego e do Tempo de Viagem em Rodovias (Highways). A solução adotada utilizou as Redes Neurais como método não paramétrico e o modelo paramétrico baseou-se na transmissão entre células com base na velocidade (base de alguns meso e macro simuladores de tráfego).

De modo semelhante Van Lint, Hoogendoorn e Van Zuylen (2005) apresentam uma abordagem do tratamento de dados perdidos baseada em previsão Espaço Temporal com Redes Neurais. Afirmam, todavia, que seus estudos estão baseados numa análise de redes

neurais “caixa branca” pois fazem a análise dos dados e o treinamento do modelo de modo controlado.

Como melhor descrito no próximo capítulo, em nosso trabalho, propomos uma abordagem híbrida, com o uso de reconhecimento de padrões para a etapa de estimação e de modelos de tráfego na etapa de previsão.

## 2.9 NECESSIDADE DE DADOS EM TEMPO REAL

Para garantir a acurácia necessária, os sistemas de previsão de curto prazo devem considerar a situação atualizada do tráfego. Para ser útil um sistema de previsão de tráfego deve estar baseado em informações distribuídas pela rede, de modo a prover informações relativas às diversas rotas e suas alternativas, devendo ser obtidas o mais próximo possível do tempo real (GENTILI; MIRCHANDANI, 2011). Sendo assim, a utilização de uma ou diversas fontes de dados em “tempo real” é a base de entrada tanto para as ferramentas históricas como para aquelas baseadas em simuladores de tráfego

Cabe aqui esclarecer que a expressão “tempo real” utilizada em nosso texto indica, na verdade, a atualização dos dados em “quase tempo real” pois pequenas defasagens de alguns segundos e até de poucos minutos podem ser aceitas como “tempo real” em diversas aplicações de previsão de tráfego.

São diversas as fontes de dados que podem ser utilizadas para atualização da base do sistema em tempo real. No geral podemos obter informações de centrais de monitoramento do tráfego, veículos rastreados, de sensores instalados em veículos, de sensores e sistemas ITS, de aplicativos e sensores instalados em celulares, de sistemas de bilhetagem ou contagem de passageiros do transporte público.

A disponibilidade de sensores em diversos pontos da via possibilita a obtenção de dados sobre o fluxo de usuários, a velocidade pontual e de trechos e o tempo de ocupação, dentre outros.

Os equipamentos de Fiscalização da Velocidade (radares), hoje dotados de recursos de reconhecimento/leitura automático de placa (OCR – Optical Character Recognition) oferecem informações detalhadas e em tempo real da velocidade individual e pontual dos veículos e também são capazes de efetuar a classificação do tipo de veículo, seja com base na placa identificada, seja com base na variação dos dados obtidos em seus sensores, como por

exemplo a variação da massa metálica detectada por um laço magnético durante a passagem de um veículo. (BERNARDI, 2015a)

Equipamentos Semafóricos possuem contadores físicos ou virtuais que indicam o volume do fluxo e o tempo de permanência de um veículo na área de contagem, possibilitando inferir a qualidade do tráfego a cada momento. Praças de Pedágio são dotadas de contadores que monitoram a quantidade de veículos e detectam a quantidade de eixos e de modo indireto, como no caso dos radares, classificam os veículos por tipo.

Estes são apenas alguns exemplos dos recursos ITS distribuídos pela rede viária que atualmente disponibilizam dados relevantes. Esses sistemas usualmente estão conectados às redes de comunicação e enviam dados em ao longo do tempo.

No nosso caso de estudo utilizaremos os dados de velocidade, de classificação veicular e de volumetria obtidos com base nos radares instalados nas vias urbanas do Município de São Paulo.

Na mesma direção, dados de sistemas de indicação de rota, de redes sociais e de rastreamento de celulares têm sido estudados no sentido de monitorar o deslocamento dos usuários pelo meio urbano.

Hoje existem sistemas que, com base em sensores embarcados em veículos e celulares, comunicam automaticamente a ocorrências de acidentes (GENERAL MOTORS, [s.d.]; MALLET, 2013) ou ainda a presença de chuva e até de deformações na pista, e também dados de bilhetagem dos sistemas de transportes poderão ser utilizadas num sistema de previsão de tráfego, embora não façam parte de nossa pesquisa.

### **2.9.1 Complemento de Dados e *Outliers***

Os estudos de “*outliers*” já perfazem mais de 50 anos (GUO; HUANG; WILLIAMS, 2015) e diversas abordagens podem ser adotadas. Com relação à previsão de tráfego as ferramentas baseadas no Reconhecimento de Dados também têm se mostrado úteis na detecção de “*outliers*” (ABDULLATIF; ROVETTA; MASULLI, 2016; ARMSTRONG; COLLOPY, 1992; GUO; HUANG; WILLIAMS, 2015; GUPTA et al., 2014; MOAYEDI; MASNADI-SHIRAZI, 2008; RASHEED; ALHAJJ, 2014; SAHA et al., 2016; SERNEELS; VERDONCK, 2008) o que é importante em nosso caso específico, uma vez que “*outliers*” podem ser resultantes tanto de falhas como de situações atípicas e em ambos os casos existe a necessidade de tratamento.

Por outro lado, “*outliers*” resultantes de incidentes, acidentes, eventos, impacto de chuvas e outros motivos que impactem temporariamente o fluxo do tráfego devem ser enviados à ferramenta de previsão, devidamente caracterizados, de modo que sejam considerados, aumentando sobremaneira a confiabilidade dos resultados em casos atípicos de tráfego.

Importante salientar que a análise de um “*outlier*” deve levar em conta não apenas o próprio ponto (local e tempo) atípico do dado, devendo também considerar locais próximos e os períodos exatamente anteriores e posteriores ao mesmo (VAN LINT; HOOGENDOORN; VAN ZUYLEN, 2005). Esta observação, correlacionada com o próprio local e com locais próximos, é que poderá indicar a diferença entre uma falha e uma situação atípica de tráfego.

Falhas devem corrigidas quando possível ou descartadas e eventualmente substituídas por dados estimados. Este tipo de aplicação é especialmente possível com o uso das ferramentas de Reconhecimento de Dados, pois com base em dados históricos e também com base nos últimos dados disponíveis podem estimar o valor a ser adotado, tornando-se peça importante na solução.

Devemos considerar, no entanto, que para falhas de maior duração, acima de algumas horas, a situação do momento anterior perde significado, passando-se a trabalhar com base nos dados históricos médios para o dia típico, de modo que tanto o Reconhecimento de padrões como os modelos de simulação são capazes de efetuar estimativas. Neste caso eventualmente o sensor em falha deva ser desconsiderado passando-se a efetuar previsões para o local com base nas estimativas dos demais sensores.

## 2.10 CONSIDERAÇÕES FINAIS DO CAPÍTULO 2

Ao longo deste capítulo foram abordados os temas relativos à Estimação da situação do tráfego e à Previsão de Tráfego de curto e longo prazo. Foram apresentados aspectos importantes quanto aos estudos de previsão de tráfego, dentre os quais destacaram-se: as ferramentas que podem ser utilizadas, a oferta e demanda de tráfego, a sazonalidade, as relações básicas do tráfego - envolvendo fluxo, velocidade e densidade, o impacto de fatores externos, a análise espaço-temporal e a necessidade de tratamento dos dados em tempo real.

Além das Revisões Científicas (Reviews), indicadas no capítulo anterior e que foram eventualmente retomadas neste capítulo, apresentamos artigos publicados em revistas

científicas, trabalhos apresentados em congressos técnicos, relatórios técnicos e sites de referência que serviram de base para nossos estudos.

Muitos trabalhos de previsão de tráfego focaram nas técnicas de Reconhecimento de Padrão, enquanto o uso dos simuladores aparece com menor ênfase e quantidade, tendo sido localizados alguns poucos artigos com abordagens híbridas para sistemas de previsão.

Da análise dos documentos foi possível verificar que o tema escolhido para a pesquisa tem sido estudado nas últimas décadas, mas se mantém atual e desafiador, com muitos trabalhos sendo publicados e com diversos pontos a serem explorados. Essa pujança está relacionada com a disponibilidade de novas fontes de dados que disponibilizam dados em grande volume e em tempo real, as novas técnicas de análise de dados e de inteligência artificial e também às linguagens e avanços tecnológicos na área da computação, que permitem processamentos de grande número de informações em curtos espaços de tempo.

Assim, neste capítulo apresentamos a base teórica que subsidia a elaboração da proposta apresentada no capítulo 3.





### 3 MODELO PROPOSTO

O modelo aqui proposto é um modelo híbrido de previsão de tráfego de curto prazo e está dividido em duas etapas, estimação e previsão. Nosso escopo será passar pela etapa de estimação, tratando os dados das diversas fontes disponíveis a fim de caracterizar as condições de tráfego, tanto com relação à oferta quanto à demanda, a fim de possibilitar a aplicação dessa caracterização na etapa de previsão, em especial a previsão com uso de simuladores de tráfego.

Nossa proposta tem como objetivo principal fornecer as bases de uma ferramenta de tomada de decisões aos gestores de cidades, para uso em situações atípicas, com capacidade de prever o tráfego para ao menos 60 minutos à frente do momento em que é executada. Neste sentido a proposta de previsão de tráfego aqui apresentada se difere da maioria das propostas verificadas na bibliografia, cujo foco principal está em fornecer dados dos próximos minutos.

Este capítulo apresenta 4 itens principais abordando os seguintes aspectos:

- 3.1 A estrutura básica do modelo;
- 3.2 Os dados disponíveis e como serão tratados e uniformizados;
- 3.3 Um ensaio sobre o uso do simulador na etapa de previsão;
- 3.4 O que já prevemos ser possível incluir no futuro.

#### 3.1 A ESTRUTURA BÁSICA DO MODELO

Como destacado no início deste capítulo, o modelo de previsão de tráfego de curto prazo aqui proposto é híbrido e baseia-se no uso de:

- Reconhecimento de Padrão, na etapa de estimação para a complementação de informações ausentes e na detecção de “*outliers*”;
- Simulador de tráfego, baseado em matrizes de Origem e Destino pré-formatadas e na rede viária existente para a etapa de previsão.

Além disto o modelo proposto tem uma etapa inicial onde a base de dados é construída com o uso dos dados históricos de tráfego e da base geográfica existente, devendo ser atualizada periodicamente. A etapa de Caracterização do Tráfego, é uma etapa intermediária

entre a estimação e a previsão, sendo que nela os dados estimados são organizados em formato que possam ser utilizados nos simuladores de tráfego na etapa seguinte.

A Figura 3.1 ilustra a estrutura do modelo proposto, apresentando resumidamente os passos de preparo e caracterização dos dados que serão descritos ao longo deste capítulo 3. Inicialmente os dados pré-existentes precisam ser tratados e avaliados, com o uso de ferramentas de Reconhecimento de Padrão, de modo a criar a base inicial do Sistema de Previsão proposto. Ajustes periódicos devem ser aplicados sempre que ocorram alterações programadas que impactem a capacidade e configuração da rede ou da demanda de tráfego. O passo de ajustes, em tempo próximo ao real, é parte primordial do modelo, de modo a mantê-lo permanentemente atualizado com base nas últimas informações sobre as condições existentes em campo e sobre as variações ocorridas na demanda; nesta etapa, o uso de ferramentas de Reconhecimento de Padrão visa complementar os dados não recebidos dos sensores e identificar “*outliers*”. Na caracterização do tráfego os dados de oferta são organizados com base em links e nós, e os de demanda em formato de matrizes OD de alocação dinâmica, de modo a possibilitar sua utilização no Simulador de Tráfego que fará a previsão.

Figura 3.1 – Passos de Preparo e Caracterização do Tráfego para uso no sistema de Previsão com Simulador de Tráfego



Fonte: O próprio autor

Conforme descreveremos no item 3.2, os dados das diversas fontes disponíveis serão tratados individualmente, de modo a extrair as informações relevantes ao modelo de previsão. Nessa etapa os dados de velocidades pontuais e de percurso, volumes pontuais, tempos de percurso entre 2 pontos, incidentes e ocorrências serão extraídos de dados fornecidos por sensores (radares), aplicativos (Waze) e sistemas de gestão (CET).

Os dados de tempo relativos ao momento em que a informação foi gerada e/ou extraída do sistema servirão de base para a organização temporal dos fatos. Serão avaliados, inicialmente, os dados relativos a dias úteis, separados em períodos característicos do dia.

Com base nas informações georreferenciadas e organizadas temporalmente será possível efetuar análises espaço-temporais.

### **3.1.1 Estimação com o uso de ferramentas de Reconhecimento de Padrão**

A escolha do uso de ferramentas de Reconhecimento de Padrão para a etapa de estimação se deve à rapidez computacional com que operam e à possibilidade de inferir valores complementares, com base nos dados dos últimos períodos de um ponto específico e de pontos à ele correlacionados, sendo então possível definir valores ausentes, por falhas sistêmicas em geral e também detectar “*outliers*” numa sequência de dados organizados temporalmente. Resumidamente podemos descrever o uso da Ferramenta de Reconhecimento de Padrões do seguinte modo:

- a) Enquanto os dados de campo são coletados para a próxima interação a ferramenta de reconhecimento de padrão estima a faixa de valores que seria aceitável para cada ponto de medição e para cada trecho de via com base nas informações anteriores do ponto/trecho e de seus vizinhos
- b) Os novos dados coletados são comparados com a faixa de valores aceitáveis, sendo separados em aceitos (quando dentro da faixa) e duvidosos (quando fora da faixa).
- c) Os valores aceitos são enviados para a etapa de caracterização.
- d) Os valores duvidosos passam por uma avaliação mais detalhada, incluindo a verificação de valores fora da faixa em outras fontes de dados e a comparação com outros pontos ou trechos. Novamente os dados são classificados em aceitos ou duvidosos:

- Os valores duvidosos, transformados em aceitos são enviados à etapa de caracterização e, caso avaliados como “outliers”, algum tipo de alerta pode ser emitido ao operador do sistema.
  - Os valores duvidosos não aceitos serão novamente avaliados com relação à situação anterior na mesma fonte, pois podem tanto indicar algum tipo de outlier, quando devem ser tratados na forma de aceitos, ou de falha nos dados quando devem ser descartados e substituídos por valores estimados inicialmente.
- e) Os dados da faixa de valores aceitáveis serão usados para estimar o valor quando este não for recebido à tempo de ser processado ou for recebido em branco, vazio. Deve ser avaliado um período máximo para esta ação, a partir do qual o ponto de coleta passa a ser desconsiderado e o modelo deve seguir com a simulação sem a informação pontual.

A escolha da ferramenta se dará ao longo dos estudos da próxima fase, quando será possível avaliar o uso das ferramentas disponíveis, em especial nossos estudos avaliarão a utilização das abordagens por Séries Temporais e por ferramentas de Inteligência Artificial.

As Séries temporais serão avaliadas inicialmente, pois facilitam uma análise visual da variação dos dados ao longo do tempo, facilitando a interpretação dessa variação. As séries temporais, de um ponto, podem também ser comparadas com séries de outros pontos próximos ou correlacionados, o que pode facilitar a complementação dos dados, já que muitas vezes podemos inferir, de modo aproximado, a variação de um local com base na variação dos locais próximos. Da mesma forma, a verificação de um ponto fora da faixa prevista pela série temporal pode indicar a presença de um “outlier” a ser tratado.

As ferramentas de Inteligência Artificial, por sua vez, precisam ser previamente treinadas para a análise dos dados e para efetuar a previsão, o que implica num processo prévio mais detalhado. Embora sejam tidas como ferramentas de “caixa preta”, que dificultam a análise do processo, as redes neurais tem a característica de permitir inferências com base em grande volume de dados históricos, como ocorre em nosso caso.

Eventualmente, durante os estudos outras técnicas de reconhecimento de padrão, dentre as citadas no capítulo 2, poderão ser avaliadas, caso se julgue necessário e produtivo.

### **3.1.2 Previsão com o uso de Simulador de Tráfego**

O principal motivo por se optar pelo uso de um Simulador de Tráfego para a etapa de previsão decorre da sua capacidade de adaptação às situações atípicas, que ocorrem diariamente no tráfego. Essa adaptação pode se dar através da alteração nas características da demanda, decorrente de eventos e dias atípicos ou através de alterações na oferta, conforme já descritas no capítulo anterior.

As alterações da demanda devem ser feitas diretamente nas tabelas de entrada de demanda, com base em matrizes dinâmicas obtidas na fase de caracterização do tráfego. Situações atípicas podem ensejar a imputação de alterações temporárias e pontuais nas matrizes. O impacto da alteração será determinado durante o processo de simulação, quando deve-se verificar a alteração dos volumes decorrentes das alterações de demanda indicadas.

As alterações na oferta implicam em alterar a capacidade de um link ou nó com base nas variações definidas na fase de estimação. Essas alterações devem ser efetuadas apenas nos pontos e trechos afetados, uma vez que a previsão do impacto dessa alteração é feita diretamente pelo Simulador de tráfego.

Para a imputação das alterações decorrentes de situações não previstas, em tempo próximo ao real, é necessária a criação de interface específica na ferramenta de simulação. Uma vez que cada simulador possui características próprias de programação e de interface de integração, nossa pesquisa será direcionada à definição dos itens básicos, mais comuns à maioria dos simuladores, que devem ser alterados quando verificada uma ocorrência imprevista. Essas alterações poderão ser efetuadas através de interface humana ou, eventualmente, através de integração com base nos dados obtidos no processo de estimação.

### **3.1.3 Necessidade de normalização das fontes de dados**

O modelo aqui proposto é baseado no cruzamento de dados de diversas fontes para a atualização em tempo real de sua base. Dessa forma, torna-se necessária a normalização dessas fontes. Como os dados das diversas origens possuem características diferentes sua normalização deve ocorrer com base no tempo e no espaço, ou seja, as informações dos diversos sistemas listados nos itens anteriores deste capítulo deverão ser agrupadas

temporalmente, a intervalos de tempo a serem definidos, em segundos ou minutos, considerando sua distribuição espacial.

Como base para montagem dos dados de entrada no simulador serão priorizadas as características de velocidade e volume que, analisadas em conjunto com as informações de filas do sistema Waze, deverão fornecer as características básicas do tráfego em cada trecho.

Para a normalização espacial serão utilizadas ferramentas de SIG (Sistemas de Informação Geográfica) possibilitando caracterizar os links e nós da rede viária, de modo que seja viável atribuir características específicas para cada um desses elementos. Em outras palavras, a proposta prevê a existência de um mapa da mobilidade onde, para cada trecho de via, são atribuídas características de capacidade e fluxo em tempo próximo ao real.

Nessa direção, as características de capacidade de cada trecho e nó são inseridas no SIG, inicialmente com base nas características físicas e ajustadas de acordo: com a densidade e velocidade do tráfego a cada momento, com base no controle do tráfego, através de semáforos, da regulamentação de estacionamento e também da ocorrência de chuvas, acidentes, alterações operacionais, obras na via, manifestações, etc.

Uma questão importante a ser avaliada é a diferença entre o tempo em que algo acontece e o momento em que este é fornecido ao sistema. Por exemplo, para que um trecho de fila seja indicado no Waze é necessário que os servidores do aplicativo recebam e tratem uma certa quantidade de informações de velocidade de seus usuários; e somente após o tempo necessário ao tratamento dessas informações é que o aplicativo as disponibiliza. Já no caso dos radares, a situação atual é a de que os equipamentos montam blocos de registros e os enviam a cada 4 minutos. Então, concatenar o tempo das informações mostra-se importante, para evitar informações defasadas entre si e eventualmente conflitantes.

Já as características de demanda de cada trecho e nó são ajustadas a partir de um banco de dados de matrizes OD, baseado em dados históricos cuja sazonalidade horária, diária, semanal e mensal é conhecida e então são alteradas com base em eventos planejados e, por fim, são ajustadas em tempo real com base em situações não previstas.

#### **3.1.4 A Rede Viária ajustada para uso do simulador**

Como a proposta está voltada para a malha urbana de São Paulo, existe a necessidade de se caracterizar esta malha e também de entender desde já que os dados serão tratados com

base nos links (trechos de vias) e nós (cruzamentos, entroncamentos, acessos, etc.) da rede viária. A rede utilizada será a do GeoSampa que é disponibilizada pela Prefeitura de São Paulo em seu site<sup>4</sup>.

Para o nosso modelo é necessário que a oferta da rede também seja ajustada de modo contínuo. Para tal, a rede básica obtida através de mapa da cidade, caracterizada de acordo com a classificação da via e a capacidade de cada link e nó, também precisa ser atualizada, de acordo com alterações em sua capacidade decorrentes de:

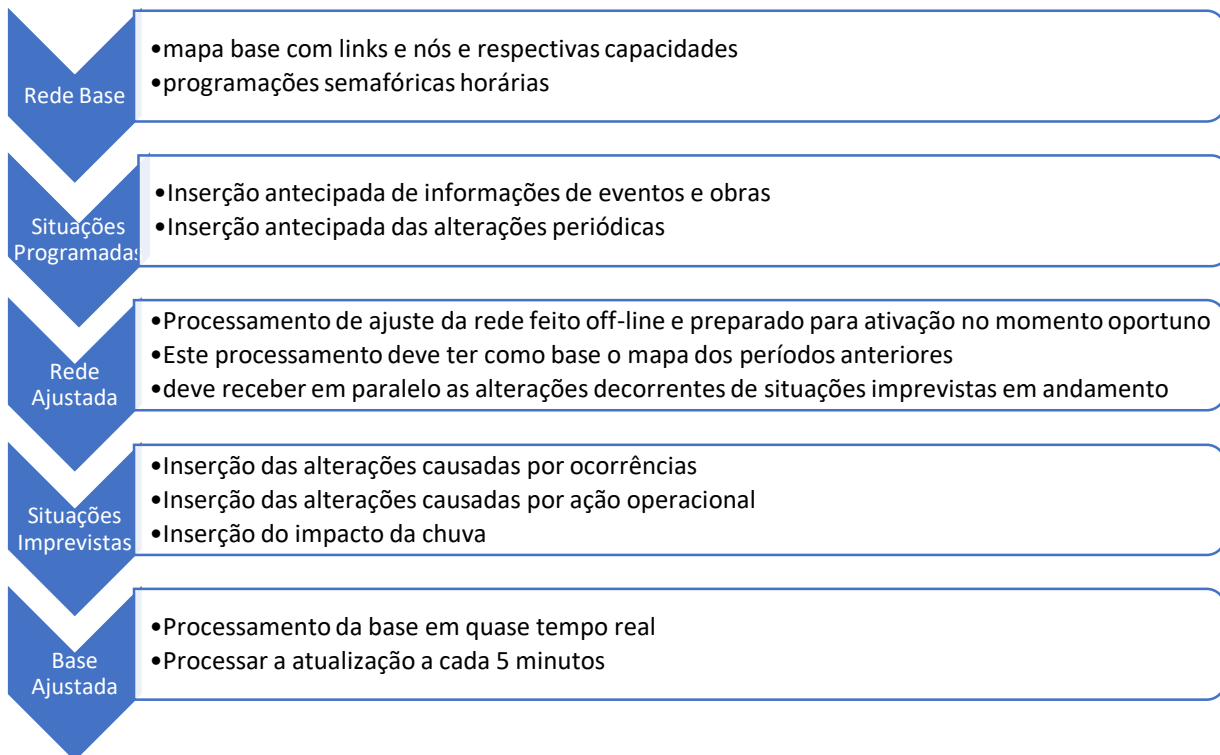
- a) acidentes e outras ocorrências - que reduzem temporariamente a capacidade de uma via;
- b) impacto de chuvas - as quais reduzem a velocidade de percurso e, por consequência, a capacidade de um trecho;
- c) Impacto de alterações operacionais como bloqueios de vias ou acessos - que reduzem a capacidade - ou da montagem de faixas reversíveis - que ampliam a capacidade de um sentido da via, em detrimento da redução da capacidade do outro sentido. Neste mesmo item incluem-se alterações operacionais como a que é feita diariamente no túnel Jânio Quadros o qual opera no sentido centro das 06h00 às 10h00 dos dias úteis e no sentido contrário nos demais dias e horários;
- d) Impacto de obras, programadas ou não, que reduzem a capacidade da via temporariamente;
- e) Impacto de eventos programados que, por vezes causam o bloqueio ou a alteração na circulação de vias;
- f) Impacto das Ciclo-faixas de lazer que são montadas na cidade aos domingos e feriados e que reduzem a capacidade de diversas vias, pois uma das faixas de tráfego é destinada ao tráfego de bicicletas. Neste mesmo item incluem-se os bloqueios de alguns cruzamentos e de movimentos de conversão;
- g) Impacto das mudanças nas programações semaforicas que ocorrem ao longo do dia.
- h) Impacto da regulamentação de estacionamento - quando feita por períodos ao longo do dia, por exemplo quando ocorrem proibições em trechos, apenas nos horários de maior movimento.

---

<sup>4</sup> [http://geosampa.prefeitura.sp.gov.br/PaginasPublicas/\\_SBC.aspx#](http://geosampa.prefeitura.sp.gov.br/PaginasPublicas/_SBC.aspx#)

Para a apropriação desses diversos itens a metodologia será a de alterar a capacidade do link ou nó envolvido, de acordo com a situação e durante o período de impacto do mesmo. A Figura 3.2 ilustra os passos a serem seguidos para a atualização da rede viária.

Figura 3.2 – Fluxo de preparo da base da rede viária para o uso no sistema de previsão de tráfego de curto prazo.



Fonte: O próprio autor

O sistema de simulação receberá como carga inicial uma base da rede, com características físicas que são relativamente fixas. Salienta-se que a rede é “Relativamente Fixa” pois precisa ser atualizada periodicamente em decorrência da criação de novas vias e acessos e da alteração da geometria viária, da inclusão de novos semáforos e alterações na circulação decorrentes da evolução natural da cidade. Ao longo do período em que esteve na coordenação da Central da CET o autor acompanhou este trabalho de atualização que era realizado mensalmente e somente em casos muito especiais ocorria em período menor.

As reduções de capacidades, dos trechos de via, serão imputadas com base na quantidade de faixas ocupadas pela ocorrência, caso a informação esteja disponível, ou, de modo mais aproximado, com base no impacto médio do tipo de ocorrência obtido nos dados históricos.



As alterações decorrentes de chuvas serão indicadas por porcentagem de redução na capacidade decorrente da redução da velocidade.

Por outro lado, as alterações na regulamentação de estacionamento, pela sua grande variação de horários, trechos e características, deixará de ser considerada em nossa pesquisa, podendo ser implementada em situação futura por outros pesquisadores.

Na sequência os nós da rede, que tem semáforos, receberão a informação das programações semaforicas dos principais horários, de modo a indicar a alteração consequente na capacidade. Observa-se que numa situação mais ideal, que poderá ser implementada por outros pesquisadores no futuro, o sistema deveria ser integrado com os sistemas de gestão semaforica (por exemplo o SCOOT<sup>5</sup>), de modo a receber alterações na programação em tempo real.

Do mesmo modo que as Matrizes de OD, poderia ser criada uma tabela de eventos onde fossem registradas as alterações periódicas que ocorrem na rede, como as ciclofaixas de lazer e as faixas reversíveis. Assim, quando do momento de ativação dessas atividades, ocorreria a alteração das capacidades dos links da rede envolvidos. Eventos e obras programadas poderiam ser incluídos em tabela similar, identificando os links e nós afetados para que o sistema fosse atualizado, todavia por não estarem disponíveis dados georreferenciados dos eventos e obras, os mesmos não serão incluídos em nossa pesquisa.

Na mesma direção, um modelo de previsão precisa prever a possibilidade de inserção de informações de ocorrências não previstas como chuvas, incidentes e ações operacionais temporárias. Neste caso, o momento de alteração da rede deve ser a primeira atualização após a recepção da informação, tanto no caso de início como de término da situação imprevista.

Dados dos sensores que indiquem reduções bruscas no fluxo poderão servir de alerta com relação às ocorrências imprevistas, mas não servirão para alteração direta da base de capacidade, pois não identificam a causa e sim suas consequências, as quais podem estar à jusante ou à montante do próprio sensor.

Como os simuladores comerciais, em sua grande maioria, possuem interfaces de integração que permitem a conexão com aplicações desenvolvidas externamente, por exemplo em linguagem Python ou similares, a proposta é que estas interfaces sejam utilizadas

---

<sup>5</sup> Split Cycle and Offset Optimisation Technique - <https://trlsoftware.com/products/traffic-control/scoot/>

para a inserção de alterações indicadas na caracterização do tráfego em cada passo de atualização do sistema.

### 3.1.5 Resultados esperados

Espera-se ser possível a caracterização do tráfego em formato adequado à sua utilização no Sistema de Simulação que fará a previsão de curto prazo.

Com relação à demanda, pretende-se que as Matrizes de Origem e Destino, utilizadas no processo de alocação dinâmica do tráfego, sejam ajustadas, previamente, com base nos dados históricos e, em tempo próximo ao real, com base nos dados de volumetria obtidos nos sensores.

Pretende-se que os dados de oferta sejam gerados em formato que permita indicar ao simulador de tráfego as alterações de capacidade ocorridas nos links, em decorrência de obras, chuvas, incidentes e ações operacionais e nos nós em decorrência de ajustes semafóricos.

Quanto às falhas verificadas nos dados, espera-se que o uso da ferramenta de Reconhecimento de Padrão seja suficiente para efetuar sua complementação e que os “*outliers*”, ao serem detectados, possam gerar um alerta ao gestor de tráfego e que também sirvam de base para alterações nos dados de oferta e demanda.

Por fim, espera-se que a atualização do sistema de simulação com base na caracterização efetuada seja capaz de produzir uma previsão adequada do tráfego futuro num horizonte de acima de 60 minutos.

## 3.2 OS DADOS DISPONÍVEIS E COMO SERÃO TRATADOS E UNIFORMIZADOS

Neste item são apresentados os dados que já estão disponíveis e como será feito seu tratamento e uniformização com vistas a prepará-los para a elaboração da caracterização do tráfego. Na Tabela 3.1 os dados disponíveis são apresentados de modo resumido, indicando-se a fonte, o tipo de dado e considerações básicas sobre sua obtenção.

Tabela 3.1 – Dados Disponíveis

Fonte	Tipo de Dado	Como será obtido
Radar	Volume	Quantidade de veículos que passam pelo equipamento em determinado intervalo de tempo, classificados por tipo: moto, auto, ônibus e caminhão
	Velocidade	Média ou Mediana das velocidades dos veículos que foram detectados pelo radar num determinado intervalo de tempo
	Velocidade de Percurso	Média da velocidade de percurso entre dois radares, com base no pareamento de placas
Waze	Filas	Conforme fornecido pelo aplicativo, com via, extensão, e final do trecho. Informação com geolocalização disponível.
	Velocidade de Percurso	Obtida diretamente do aplicativo para os trechos onde se registram atrasos.
	Alertas	Diretamente do aplicativo, com tipo e geolocalização, conforme indicado pelos usuários
CET	Filas	Diretamente do sistema Pintalent da CET, com extensões e trechos das vias monitoradas, necessário tratar a geolocalização
	Ocorrências	Do sistema de gestão de ocorrências da CET, com geolocalização e ocupação da via
IAG	Precipitação	Total de precipitação num determinado intervalo de tempo, por subprefeitura do Município de São Paulo

Fonte: o próprio autor

### 3.2.1 Dados dos radares

O Município de São Paulo conta com 1005 pontos com radares de fiscalização de velocidade, sendo que alguns deles também fiscalizam infrações relativas à semáforo vermelho, faixas exclusivas de ônibus e conversão proibida. Dependendo da tecnologia/tipo de equipamento utilizado um mesmo ponto pode ter mais de um equipamento. Assim o total de equipamentos instalados é de 1630.

Os equipamentos atualmente instalados são classificados em 4 tipos: Lombada Eletrônica, radar portátil, radar estático e radar fixo.

Todos os equipamentos instalados na área de restrição de circulação também fiscalizam o desrespeito ao rodízio, tanto dos automóveis (pelo último dígito da placa) como dos veículos de grande porte (também identificados pela placa em cruzamento com o cadastro nacional de veículos).

Cada equipamento envia um arquivo texto aos servidores de dados a cada 4 minutos, do qual consta o Registro de cada passagem de veículo pelo local. Os dados disponíveis são:

Código do Local, Data, Hora, faixa de tráfego, entre-faixa de tráfego (no caso de fiscalização de motos), tipo de registro (com ou sem infração), espécie e tipo do veículo, comprimento do veículo, velocidade de passagem e tempo de ocupação do laço detector.

Os dados utilizados em nosso estudo inicial foram obtidos junto à SMT-SP – Secretaria de Mobilidade e Transportes do Município de São Paulo e são relativos ao ano de 2018

Os dados foram fornecidos em formato \*.txt, agrupados por dia e lote (cada um dos 4 prestadores de serviço). Dessa forma foram obtidos 1430 arquivos compactados (4x365) cada qual contendo entre 50 e 150 mil pequenos arquivos de texto com os dados, cada qual com a informação relativa ao período de 4 minutos de um radar. Aqui enfrentamos a primeira dificuldade prática no tratamento dos dados, uma vez que a descompactação de cada um dos 1430 arquivos leva em torno de 10 minutos, mesmo utilizando um computador com processador i7 de 8ª geração, 32 GB de memória RAM e armazenamento em disco sólido (SSD).

Após descompactados, os dados precisavam ser reunidos e organizados em formato que possibilitasse seu tratamento por sistemas de bancos de dados, neste momento, pelo sistema SQL Server. Este trabalho complementar consumia outros 12 minutos no tratamento de cada arquivo. Assim, apenas para o preparo de todos os dados seriam necessárias cerca de 520 horas ininterruptas de processamento para a descompactação, além da necessidade de automatizar o processo.

Em busca de definir uma melhor metodologia de tratamento dos dados entendemos por bem fazer uma análise exploratória dos dados, em menor escala, buscando entender o conteúdo das informações disponíveis e as possibilidades de análises futuras. Dessa forma, nesta etapa inicial, optamos por amostrar apenas alguns dias, descritos a seguir, e utilizar ferramentas de análises de dados como SQL Server, Grethl e PowerBI.

Verificamos assim que no prosseguimento do estudo haverá a necessidade de tratamento dos dados através de linguagens construídas para o tratamento de BigData. Pela análise da literatura, voltada ao tratamento de dados em séries temporais, verificamos a possibilidade de uso das linguagens R e Python, de modo que na próxima etapa, após o Exame de Qualificação, faremos uma avaliação e escolha da linguagem a ser utilizada.

Encontramos em (BERNARDI, 2015b) uma análise da qualidade do funcionamento dos equipamentos em relação à identificação das placas. Diversos tipos de situações operacionais são avaliados sendo constatado que entre 87% e 98% das placas são identificadas

corretamente. Isto implica que podem ocorrer falhas nessa identificação, impactando o uso dessa informação nos sistemas de previsão. Verificou-se também o impacto da velocidade de passagem do veículo pelo sensor, sendo que neste caso a maioria dos testes indicou acertos acima de 90%. Por fim, destacou-se a análise do impacto do horário do dia, na qual o estudo indicou possível correlação com a posição do sol em relação ao equipamento, resultando em menor número de identificações após o meio dia. Como veremos no próximo capítulo os dados que utilizamos nas análises iniciais também mostraram menor qualidade de identificação das placas no amanhecer e anoitecer e durante o período noturno.

Consideramos também que, mesmo que a placa do veículo não seja identificada, como ocorreu com 25% das amostras que analisamos até o momento, a informação de sua passagem e de sua velocidade pontual já são úteis, como informação importante para o sistema. No nosso caso, apenas a análise de tempos de percurso entre dois equipamentos é que fica prejudicada na falta da identificação da placa, todavia a análise preliminar mostrou ser viável a obtenção de velocidades médias de percurso, como apresentaremos mais à frente.

Apesar das falhas indicadas, verifica-se que os sistemas de radares, que incluem o reconhecimento das placas, fornecem informações em grandes volumes e de modo ininterrupto, possibilitando seu uso em sistemas de previsão de tráfego.

Wang et al. (2019) propuseram uma abordagem de análise e ponderação de erros para melhorar a acurácia de um sistema de Estimção da Densidade do Tráfego em Áreas Urbanas. Segundo a proposta, o modelo recebe a informação da probabilidade de dois tipos de falhas de detecção: registro de veículos que na verdade não passaram e ausência de registro de veículos que passaram pelo sensor. Para a aplicação da metodologia seria necessária uma pesquisa específica, com acompanhamento por imagens em vídeo ou in loco, a fim de comparar os dados registrados pelos radares e os veículos que efetivamente passaram. Tal análise não faz parte de nosso escopo neste momento, mas poderá ser complementada por outros estudos, de modo a aumentar a acurácia do modelo proposto.

### **3.2.2 Dados de Filas e velocidade do Waze**

Serão utilizados para complementar as informações dos radares, de modo a propiciar a atualização e calibração da rede como um todo, incluindo vias e trechos não cobertos por radares.

A região Metropolitana de São Paulo, atendida pelo código DDD 011, tem quase 35 milhões de linhas de telefonia celular, o que corresponde a pouco mais de 1,5 linhas por habitante (TELECO, [s.d.]). Assim, certamente dados provenientes do posicionamento desses equipamentos podem prover informações importantes sobre o comportamento da população.

De modo semelhante ao *“Floating Car Data”*, hoje podemos verificar na literatura acadêmica a expressão *“Floating Phone Data”*, que consiste no rastreamento de equipamentos de telefonia celular (FRIEDRICH et al., 2010). Através desse rastreamento é possível inclusive obter matrizes de Origem e Destino para diversas épocas e horários (TOLOUEI; PSARRAS; PRINCE, 2017).

Aplicativos, como o Waze, têm se valido do rastreamento de celulares de seus usuários para efetuar a qualificação do fluxo de tráfego dentro de padrões de fluidez. Consta do site oficial do aplicativo, acessado em 11/2018, que o aplicativo já conta com mais de 90 milhões de usuários ao redor do globo (WAZE, [s.d.]). Algumas reportagens indicam que São Paulo é a cidade com maior número de usuários no mundo, com 4 milhões de usuários ativos (STARTUPI, [s.d.]). Como o aplicativo depende do rastreamento e de dados fornecidos de modo ativo e passivo por seus usuários, essa quantidade grande de usuários tende a aumentar a acurácia dos dados oferecidos a todos.

A SMT-SP tem convênio firmado com o Waze para troca de dados, o que permite o uso dos dados de velocidade média do trecho nos trabalhos de planejamento e monitoramento do tráfego da cidade. Além disto, estão também disponíveis os dados de ocorrências informados pelos usuários.

Os dados de filas serão tratados com base na informação de georreferenciamento, atribuindo a característica de fila e velocidade de percurso aos links afetados. Para uniformizar a informação os dados serão cruzados com as informações de radares de modo a garantir sua consistência. Os de velocidade de percurso obtidos por pareamento de placa dos dados de radares serão utilizados para aferir os valores apresentados pelo aplicativo.

### **3.2.3 Dados de Meteorologia**

Os dados de Meteorologia são atualizados e disponibilizados constantemente pelo IAG – Instituto de Astronomia, Geofísica e Ciências Atmosféricas da USP – e podem ser acessados em página web.

Para nossos estudos obtivemos uma amostra de 22 meses com informação da precipitação a cada 10 minutos, das 31 estações meteorológicas que cobrem o Município de São Paulo. Os dados recebidos estavam organizados com base na quantidade de precipitação em cada uma das 33 SubPrefeituras do Município.

Os dados foram avaliados tendo sido consideradas as variações sazonais mensais que indicam a concentração de chuvas mais intensas durante o verão, como era de se esperar.

Para uso no sistema de previsão de tráfego de curto prazo, toda a área interna de cada Sub-Prefeitura será considerada de modo homogêneo. Assim, todas as vias incluídas na área de abrangência de uma estação serão consideradas com a mesma intensidade de chuva. Esse tipo de análise já mostrou resultados em estudo anterior, onde foi verificado que, na média, os ônibus tiveram sua velocidade de percurso reduzida de 17 para 13 km/h nos momentos de chuva. (GONÇALVES, 2018)

A atualização do sistema se dará a cada 10 minutos, com base na disponibilidade dos dados obtidos. Na prática, essa atualização pode ocorrer em tempo menor, de acordo com a disponibilidade dos dados. Nos estudos iniciais não foi possível definir se é possível agregar essa atualização em espaços de tempo menores.

Outro aspecto a ser avaliado é a quantidade de chuva acumulada no período, já que intuitivamente esperava-se que chuvas leves apresentassem impacto menor do que chuvas mais fortes. Assim, poderão ser feitas análises do impacto da existência de chuva em relação à sua ausência e do impacto da chuva acumulada nas últimas 2 horas.

O impacto resultante da chuva será inserido no sistema de previsão de tráfego de curto prazo através da alteração da capacidade nas vias, incluídas na área de abrangência de cada radar. Inicialmente, a fim de não sacrificar o tempo disponível aos estudos e elaboração do método, serão consideradas as variações indicadas em outros estudos específicos (GONÇALVES, 2018; HOU et al., 2013). Opcionalmente, no futuro, os próprios dados do sistema de previsão de tráfego de curto prazo, aqui proposto, poderão servir de base para estudos que detalhem melhor o impacto das chuvas, aprimorando o próprio modelo.

### 3.2.4 Dados de Ocorrências

Serão obtidos diretamente do sistema de ocorrências da CET. Para nosso estudo foi obtida uma cópia das ocorrências registradas no sistema relativa aos anos de 2014 a 2018.

As ocorrências são informadas em detalhes pelas equipes de campo quando da chegada ao local, indicando o local exato, que inclui o endereço e o sentido da via e também a ocupação (calçada, número e posição das faixas de rolamento afetadas, etc.) e ainda alterações na ocupação da via decorrentes tanto do trabalho dos veículos de socorro como da liberação parcial e total da via ao tráfego.

Essas informações são repassadas ao sistema de gestão da Central de Operações de três formas:

- a) Por voz via celular ou rádio – neste caso a Central recebe a informação e registra no sistema de gestão e envia ao celular do agente para complementos e atualizações;
- b) Por mensagem (sistema ZapCET, semelhante ao Whatsapp) – também neste caso a Central registra a ocorrência no sistema de gestão e envia ao celular do agente;
- c) Por dados – o agente preenche a ocorrência em aplicativo específico, disponível no celular de trabalho, e transmite a informação via 4G à Central de Operações.

As ocorrências são georreferenciadas com base nos endereços informados pelo agente de campo e armazenadas de modo organizado em bancos de dados relacionais, o que torna possível que as mesmas sejam inseridas no Simulador em quase tempo real, através de integração com os bancos de dados do sistema de previsão de tráfego de curto prazo aqui proposto, com defasagem relativa ao tempo de preenchimento pelo agente de campo, transmissão à Central e processamento no sistema de gestão.

Como as equipes da CET informam a quantidade de faixas afetadas por uma ocorrência, o impacto das ocorrências será inserido no sistema através da redução da capacidade da via, com base na redução de espaço disponível para circulação, decorrente da ocupação da mesma na via. Será necessário definir a forma de inserção da alteração, para os casos em que não haja a informação da ocupação.

No período de 01/07 a 31/12/18 foram registradas no sistema de dados da CET 531.603 ocorrências, de 89 códigos diferentes (vide listagem no Anexo A - 1). Numa análise inicial desses dados pudemos verificar que:



- Havia uma grande concentração de registros em itens relativos à atividades de fiscalização (58%). Estes dados não serão considerados pois, de modo geral, seu impacto na capacidade da via é reduzido.
- Do grupo relacionado com problemas na sinalização semafórica, que correspondia a 12% do total de falhas, serão desconsideradas as falhas não críticas, assim definidas aquelas falhas que não impedem a continuidade do funcionamento do sistema semafórico no cruzamento, como o caso de lâmpadas queimadas, caixa aberta, etc. Aquelas com maior potencial de impacto na capacidade da rede, como semáforos apagados ou operando contingencialmente no “amarelo piscante” que correspondiam respectivamente a 30% e 28% das falhas semafóricas, e que serão mantidas.
- O grupo de ocorrências não emergenciais correspondia a 26% do total. Como no caso das falhas semafóricas, deste grupo também serão selecionados os itens com maior potencial de impacto no fluxo ou na capacidade da rede viária. Assim, preservamos as ocorrências como veículos quebrados/parados na via (34%) e serviços/obras na via (13%) e desconsideramos as informações relativas à buracos e outros tipos de interferências de menor potencial de impacto.
- Por fim, temos as ocorrências classificadas como emergenciais que somam pouco menos de 5% do total. Estão incluídos nesta classe os acidentes com e sem vítimas, manifestações, quedas de árvore e alagamentos, dentre outros. Neste caso, julgou-se útil que todas as ocorrências sejam preservadas no estudo, tendo em vista que no geral implicam na ocupação parcial ou total da via e que além disto podem despertar curiosidade dos usuários, alterando seu comportamento e também podem implicar em alterações operacionais com impacto na oferta da rede viária disponível.

A listagem do Anexo A - 2 indica objetivamente as ocorrências que foram consideradas e descartadas nesta etapa, com as quantidades de registros correspondentes.

Também avaliando os dados verificamos que 14580 registros de ocorrências apareciam mais de uma vez na listagem, totalizando 6526 ocorrências distintas. Isto se deve à atuação de diversas equipes da CET num mesmo evento, seja por sua complexidade - ao requerer mais de um recurso simultâneo (ex.: manifestações de maior porte), seja por sua duração – ao implicar na troca de equipe ao final de cada jornada de trabalho.

Ainda com relação às ocorrências, verificamos que o aplicativo Waze disponibiliza a informações de alertas gerados por seus usuários, sendo que estão incluídos alertas relativos a acidentes e veículos parados na via. Não há informação de faixa de ocupação, de modo que será necessário definir uma estratégia de escolha desse fator.

Os alertas fornecidos pelo Waze são georreferenciados com menor qualidade do que as informações fornecidas pela CET, todavia a grande quantidade de usuários no Município de São Paulo favorece que os usuários indiquem uma ocorrência antes da mesma ser detectada pela CET, possibilitando assim uma atualização mais ágil de nosso modelo de previsão.

### **3.2.5 Matriz OD para Alocação Dinâmica**

Tendo em vista o tempo dispendido na análise dos demais dados nesta etapa, não foi possível efetuar uma análise detalhada com relação à Matriz OD a ser empregada.

Para o nosso estudo final pretendemos tomar como base a Matriz OD do Metrô (METRÔ, 2018; SETM; METRÔ, 2018) que foi refeita entre 2017 e 2018 e está sendo disponibilizada em lotes.

Esse tipo de matriz OD é importante para estabelecer a demanda de viagens em dias típicos, ou seja, deve ser considerada como uma matriz média inicial, onde se estabelece a demanda média de um dia útil. Já para os finais de semana a prática tem sido utilizar a mesma matriz com alguma redução percentual ou com a exclusão de demandas relacionadas a determinado objetivo, o que não é adequado ao nosso tipo de aplicação.

Nossos estudos estarão concentrados nos dias úteis por serem os dias de maior interesse aos gestores de cidades e nos finais de semana. Todavia a metodologia será apresentada de modo que seja possível sua expansão aos demais dias, como feriados e vésperas de feriados.

Pretende-se que a definição das matrizes seja feita com base em análise dos dados dos radares que detectam as alterações de fluxo ocorridas ao longo do tempo. Alguns dos macromodelos de simulação de tráfego utilizados em estudos de planejamento possuem interface que permite ajustar e inferir alterações na matriz OD com base no fluxo indicado em diversos links da rede.

Outra técnica parcialmente possível para a montagem de matrizes OD distintas para cada situação seria a análise das passagens de veículos identificados nos radares.

Também tendo em conta que o modelo proposto indica a necessidade de atualização em tempo próximo ao real, nossa preocupação deve ser em possibilitar a alocação dinâmica da demanda. Para tal é importante considerar não apenas a mudança do fluxo geral, que ocorre ao longo do dia, mas também que a direção da demanda se altera conforme o horário, sendo que a alteração mais notória é a que ocorre entre os picos da manhã quando o principal movimento é de saída da residência ao trabalho e à tarde no retorno às residências respectivamente. Com o mesmo enfoque, podemos também considerar variações menores como as que ocorrem durante o horário de almoço e à noite com as demandas relativas às universidades que possuem cursos noturnos.

Assim, para considerar a variação intra-dia da demanda, será avaliada a construção de matrizes para períodos relativamente homogêneos do dia.

### 3.3 UM ENSAIO SOBRE O USO DO SIMULADOR DE TRÁFEGO NA ETAPA DE PREVISÃO

O ensaio do uso dos simuladores terá por objetivo efetuar testes da viabilidade de uso dos dados preparados nas etapas de estimação e caracterização.

Conforme já discutido no capítulo 2, o simulador de tráfego a ser utilizado em nosso modelo deve ser um mesossimulador que atue considerando o efeito do tráfego ao longo do tempo, de modo que, quando é feita a carga do tráfego, este vai aos poucos ocupando as vias e através de modelos de capacidade e demanda se prevê a densidade do fluxo, sendo possível verificar, ao longo do tempo, as vias que se tornam congestionadas e apropriar o impacto disto na escolha de rota dos usuários que adentram ao sistema ou que estão percorrendo trajetos afetados.

O mesossimulador a ser utilizado deverá ser capaz de receber informações da alocação dinâmica do tráfego e alterações de capacidade na sua rede viária nos momentos de reinício do ciclo. Para que seja útil aos gestores de tráfego, a meta é que cada ciclo de simulação efetue a previsão de ao menos 60 minutos à frente (desejável acima de 120 minutos), sendo inicialmente previsto, com base na análise da literatura indicada no capítulo 2, que cada ciclo de previsão dure até 5 minutos.

Dentre os mesossimuladores, que tomamos conhecimento através da literatura pesquisada, destacamos 3 deles pela possibilidade de acesso e uso dos mesmos na fase final. O primeiro deles está em desenvolvimento na própria Universidade de São Paulo, o segundo

é um produto acabado e em fase de comercialização e o terceiro foi desenvolvido no MIT (Massachusetts Institute of Technology) para soluções de gestão da rede de tráfego e respostas a emergências.

Ao longo da segunda fase de estudos poderemos efetuar uma melhor avaliação destes e eventualmente de outros simuladores disponíveis e justificar, de modo mais objetivo, a escolha por um deles. Salientamos ainda que a proposta aqui apresentada pretende ser adequada ao uso de quaisquer dos mesossimuladores de mercado, desde que possam receber dados em tempo real e possuam desempenho computacional adequado à aplicação.

### **3.3.1 InterSCSimulator**

O InterSCSimulator é um Mesossimulador de Cidades Inteligentes, de código aberto e que possibilita a simulação de tráfego de metrópoles, característica para a qual foi especialmente desenvolvido por Eduardo Zambom Santana em sua tese de doutorado no Instituto de Matemática e Estatística da USP (IME) (SANTANA, 2019).

Uma das grandes vantagens do IntesSCSimulator é que ele foi construído para simular milhões de atores simultaneamente e distribuídos na malha urbana de uma metrópole, ao longo do dia e conforme seu horário previsto de saída.

O sistema ainda está em desenvolvimento e em processo de otimização. Parte das interfaces iniciais deste simulador foram adaptadas do Matsim<sup>6</sup>, que é um mesossimulador de código aberto.

A velocidade de processamento do modelo depende tanto da infraestrutura de hardware como do tamanho da rede viária e também da quantidade de viagens a serem processadas. Assim, considerando as simulações de teste desenvolvidas na área do município de São Paulo, com 22 milhões de viagens, foram verificados processamentos até 100 vezes mais rápidos do que o tempo real para o período da madrugada, 25 vezes mais rápidos no entre picos, mas nos horários de pico o tempo de processamento ainda ficou próximo ao tempo real, chegando em dois casos ser mais lenta que o próprio tempo real. Embora o aumento do tempo de processamento seja pontual, para possibilitar seu uso num sistema de previsão de tráfego de curto prazo, em tempo quase real, será necessário garantir que o processamento seja, pelo

---

<sup>6</sup> <https://matsim.org/>

menos, 12 vezes mais rápido do que o tempo real, possibilitando processar 1 hora à frente em 5 minutos no máximo.

Segundo Santana (2019) as etapas de paralelização do processamento ainda estão em desenvolvimento, e que o sistema poderia ser processado em servidores com maior quantidade de núcleos e memória, de modo que no futuro a velocidade de processamento necessária poderá ser atingida. Na direção da melhoria do desempenho com paralelização do processamento, (ATTANASI et al., 2015) afirma que a estratégia é plenamente aplicável e tem resultados relevantes na redução do tempo de processamento.

Portanto, verificamos que o simulador escolhido tem a escalabilidade necessária para o enfrentamento da simulação em tempo real de uma megacidade como São Paulo.

Outra característica importante é que o mesmo já está configurado para o uso de Alocação Dinâmica de Tráfego, necessária à implementação em tempo real.

O simulador requer a entrada obrigatória de 3 arquivos XML (SANTANA, 2019):

- Como em todos os simuladores de tráfego é necessária a utilização do mapa a ser utilizado. Neste caso o mapa é definido com base na posição dos nós, sendo os links definidos como ligações entre os nós. Os links são caracterizados com base no seu comprimento e velocidade de fluxo livre. Na versão inicial, a capacidade dos links foi obtida com base em ferramenta do MatSim e informações do Open Street Maps, todavia é possível a alteração dessa capacidade através de apropriação de valores mais adequados no momento da entrada do arquivo inicial.
- As viagens que serão simuladas têm como definição: nó de origem, nó de destino, hora de início e modo de viagem (à pé, veículo, ônibus, etc), e é possível simular viagens multimodais através das indicações de sub-viagens. Para isto é necessário estabelecer as matrizes OD.
- Arquivo de configuração do modelo, que serve para iniciar o modelo e possui informações dos diversos arquivos de entrada e dos horários de início e término da simulação.


O modelo relativo aos veículos leva em conta que o trajeto por onde eles passarão é uma sequência de links e nós. O modelo calcula a velocidade de cada veículo em cada link, o que por sua vez é dependente da densidade de tráfego existente a cada momento.

O modelo adota a função de relação densidade / velocidade proposta no HCM 2000 (NATIONAL RESEARCH COUNCIL (U.S.). TRANSPORTATION RESEARCH BOARD., 2000). Esta relação é simples e poderia ser melhorada para situações onde se pretende maior detalhamento da situação (vide item 2.4). Por outro lado, considerando a meta de desempenho proposta no início deste item 3.3 (prever mais de 60 minutos de tráfego em alguns minutos), esta aparente deficiência pode resultar em qualidade já que uma das formas de acelerar o processamento de sistemas é buscar a simplificação de seus algoritmos

Segundo seu criador, o modelo possui ainda outros componentes de integração voltados à aplicação em Cidades Inteligentes, como o controle de vagas de estacionamento, sensores de diversos tipos, dentre os quais os contadores de tráfego, locais de interesse ao fluxo (locais de eventos) e eventos programados de fechamento de vias.

O Simulador possui duas interfaces de saída, sendo a primeira visual em formato de mapas e gráficos, conforme Figura 3.3 (reproduzida do texto original), e outra de dados, desenhada de modo a facilitar a integração e tratamento dos dados com o uso de diversas linguagens como R e Python.

Figura 3.3 – interface visual de saída do InterSCSimulator



Fonte: Santana (2019)

Durante a apresentação e os debates da defesa da tese de Eduardo Felipe Zambom Santana ocorrida em 18/03/19<sup>7</sup>, verificamos que na versão inicial:

- O sistema não faz o re-roteamento das viagens em decorrência de interferências na rede, o que é um problema para a nossa proposta. Todavia, já existem trabalhos sendo desenvolvidos no IME/USP para incorporação dessa característica.
- O parâmetro básico de distribuição das viagens é o tempo, sendo desconsiderado os demais componentes de custo que podem afetar a escolha do usuário.
- A alocação do modo de viagem é pré-definida, e o modelo ainda não é capaz de identificar a escolha do modo de transporte com base no custo e em modelos de escolha do usuário.
- Não inclui as características dos nós, utilizando apenas a indicação de distribuição que ali ocorre, o que inviabiliza a apropriação de características de sistemas de controle semafórico e de preferência de passagem.

Consideramos nesta etapa que o InterSCSimulator é uma ferramenta em desenvolvimento e que estudos complementares estão em desenvolvimento no grupo do projeto InterSCity (KON, 2017; MACÊDO BATISTA et al., 2016), podendo gerar novas interfaces e características nos próximos anos, de modo que viabilizem seu uso no nosso estudo.

### **3.3.2 Optima**

Este simulador é comercializado pela PTV-Group e tem como característica ser um simulador comercial já preparado para as ações de previsão de tráfego de curto prazo.

Esta ferramenta está baseada no macrossimulador Vissum, também produzido pela PTV-Group (PTV GROUP, 2017) e está preparado para ser integrado com outros sistemas de ITS. O sistema é montado em três etapas:

- a) na primeira é utilizado o macrossimulador Vissum para a montagem da rede, incluindo as capacidades características dos trechos e os tempos de percurso

---

<sup>7</sup> Informações verbais obtidas durante a apresentação e os debates da Defesa de Tese de Eduardo Felipe Zambom Santana em 18/03/10 no Instituto de Matemática e Estatística da Universidade de São Paulo

“usuais” com base nas matrizes OD típicas para dias úteis e para finais de semana. Esses dados são transferidos para o sistema Optima como base inicial de cálculo.

- b) Na segunda etapa o Optima recebe em “tempo real” os dados de fluxo, da velocidade e de alterações na capacidade e os processa para obter a situação atual do tráfego nos trechos monitorados e também nos trechos não monitorados (com base na simulação recebida do Vissum). Os dados das diversas fontes são harmonizados de modo a obter o fluxo e a velocidade nos links da rede.

O sistema possui interfaces para receber dados de “Floating Car Data” (como Waze), AVL/GPS, de sensores com reconhecimento de placa (como os radares), de contadores veiculares, de sistemas de transporte público e ainda informações relativas a incidentes e trechos em obras.

Como o sistema coleta e processa permanentemente os dados da rede ele está sempre atualizado com a última informação disponível.

- c) Na última etapa o Optima efetua a previsão do tráfego para a próxima hora. A interface ainda permite que o usuário insira cenários para compará-los, o que é útil quando se deseja comparar alternativas de gestão para um problema em andamento.

Este sistema possui interfaces para exportar os resultados para painéis de controle e gestão e para sistemas de controle semafórico e de painéis de mensagens variáveis.

### **3.3.3 DynaMIT**

O Sistema DynaMIT foi desenvolvido pelo laboratório de Sistemas Inteligentes de Transportes do MIT (Massachusetts Institute of Technology) com o objetivo de tratar em tempo real a gestão de redes de tráfego e apoiar respostas a situações emergenciais.

O sistema trabalha com base na alocação dinâmica do tráfego em rede viária pré-definida. O sistema recebe atualizações de dados de sistemas ITS e de rastreamento de veículos em tempo real e efetua a Estimção do Estado do Rede (Oferta) e da Demanda por viagens. Então efetua uma recalibração dinâmica do modelo, tornando-se hábil a efetuar a previsão do fluxo futuro.

O sistema efetua sua previsão com base nos dados atualizados e em estratégias de controle (semáforos, Painéis, etc).



Como no caso do Optma da PTV Group, o Dynamit tem interface para análise de cenários e fornece informações a outros sistemas através de integração, possuindo interface que trabalha em tempo real.

### 3.4 ITENS A INCORPORAR AO MODELO DE ESTIMAÇÃO E PREVISÃO NO FUTURO

Tendo em vista a disponibilidade de tempo e a necessidade de limitar nosso escopo dentro do possível para esta e a próxima etapa, optamos por não incluir neste momento alguns itens que poderão ser incorporados de modo incremental ao modelo proposto (Tabela 3.2). A listagem apresentada não esgota os itens possíveis de expansão, mas sim destaca aqueles já avaliados até a presente data.

Nosso modelo está sendo construído de modo a possibilitar a inclusão dos itens aqui citados e de outros que se façam disponíveis no futuro, sendo nosso entendimento que cada um desses itens pode contribuir para a melhora da qualidade do processo de estimação e previsão.

Tabela 3.2 – Itens fora do escopo da pesquisa mas que poderão ser incorporados através de estudos futuros

Tipo de dado	O quê	Tipo de informação
GTFS	Padrão de dados de transporte público internacional	Dados de programação horária de frota e dados em tempo real de velocidade e de posição georreferenciada dos ônibus urbanos
Datas especiais	Datas com variações específicas na demanda de viagens como vésperas de feriado e quarta-feira de cinzas	Apropriar matriz OD para datas especiais contemplando sua característica específica
Eventos e Obras Programadas	Eventos na via pública ou não, mas que causam interrupção ou impacto significativo no tráfego	Indicar no sistema as vias e horários de bloqueios decorrentes do evento alterando assim a oferta da rede viária.
Sistema Semafórico Centralizado	Programação semafórica e semáforos que operam sob demanda, e em tempo real e também aquelas efetuadas pelas equipes operacionais	Manter atualizada a divisão de tempos dos estágios para qualificar a capacidade do nó/cruzamento.

Tabela 3.2 – Itens fora do escopo da pesquisa mas que poderão ser incorporados através de estudos futuros (continuação)

Tipo de dado	O quê	Tipo de informação
Regulamentação de Estacionamento com horário	Sinalização vertical de regulamentação de estacionamento com horários específicos	Ocupação e liberação de faixas por veículos estacionados que alteram a capacidade da via em determinados horários conforme horários previstos na regulamentação
Sistemas ITS em geral	Sistemas que forneçam dados de seus sensores ou que utilizem os dados de previsão para otimizar seu funcionamento, além do sistema de radares que foram aqui considerados. Entre outros incluem-se os contadores veiculares, PMVs (Painéis de Mensagem Variável) e câmeras de vídeo	Dados diversos como volume, velocidade, ocupação, incidentes, poluição, etc. Integração entre o sistema de previsão e os demais sistemas de ITS para otimizar o funcionamento de ambos
Veículos Inteligentes	Veículos funcionando como sensores da qualidade do tráfego e de si próprios	Medição de velocidade e de trajetos efetuados, análise de matriz OD Integração entre o sistema de previsão e os veículos para aprimorar os sistemas de roteamento e direção autônoma
Dados de celulares	Posicionamento e deslocamento de celulares com base no posicionamento GPS do aparelho e triangulação de antenas	Obter maior detalhamento na matriz OD dinâmica.

Fonte: o próprio autor

### 3.4.1 Eventos e Obras Programadas

Os dados relativos aos eventos e obras programadas são mantidos pela CET em sistemas distintos, sendo um de autorização de eventos e outro de autorização e fiscalização de obras.

Estes sistemas já detêm informações relativas à data e local do evento/obra e dados operacionais, como vias bloqueadas e desvios, horários de início e término dos bloqueios. Todavia, parte dessa informação hoje é registrada em formato texto, dificultando seu uso de modo integrado.

Novas versões desses sistemas estão em desenvolvimento, sendo prevista a inclusão de uma interface de mapa onde o planejador possa mais facilmente indicar as informações, de

modo georreferenciado e com indicações de horários previstos. Uma vez que não temos como garantir as informações georreferenciadas para nosso estudo este item deixará de ser considerado.

### **3.4.2 Sazonalidade e Datas Especiais**

Devido à nossa limitação de escopo, já exposta no início deste capítulo, optamos por avaliar inicialmente os dias úteis, que são aqueles com maior importância aos gestores de cidades. Caso haja disponibilidade de prazo, serão desenvolvidas as matrizes OD também para os finais de semana. Para estudos futuros sugerimos a análise e elaboração de matrizes OD específicas para as seguintes situações:

- a) Dia da semana – segunda, terça, quarta, quinta, sexta, sábado e domingo;
- b) Feriados oficiais;
- c) Vésperas de feriados, emendas e dias após o feriado – neste caso apenas os dias úteis foram considerados, pois ocorre uma mudança na demanda do tráfego nessas datas em decorrência da saída e retorno de pessoas que viajam durante os feriados. Os volumes verificados nos radares próximos às rodovias podem apresentar alterações significativas nessas datas, caracterizando o aumento da demanda nesses locais e portanto uma alteração pontual na matriz de Origem e Destino;
- d) Quarta-feira de Cinzas – este dia possui uma característica única, pois por tradição o expediente comercial inicia-se apenas após às 12h, o que implica num deslocamento de pico ao meio dia;
- e) Dias de jogos do Brasil na Copa – também por tradição, nos dias de jogos da seleção brasileira nas Copas do Mundo as empresas, de modo geral, liberam seus funcionários no horário dos jogos. Assim, caso o jogo seja pela manhã o expediente ocorre apenas à tarde e vice versa.

## **3.5 CONSIDERAÇÕES FINAIS DO CAPÍTULO 3**

Neste capítulo tratamos de apresentar nossa proposta de trabalho, apresentando o modelo de solução proposto (com sua estrutura, etapas e organização), as fontes de dados

disponíveis e a forma como estas serão tratadas. Por fim, indicamos as evoluções que o modelo proposto pode receber em pesquisas futuras.

O modelo de Previsão de Tráfego de Curto Prazo proposto está apoiado na base teórica apresentada no capítulo 2, e inova ao propor o uso de uma solução híbrida baseada em Reconhecimento de Padrões e Simulação de Tráfego.

A proposta também se difere ao focar as necessidades e preocupações dos gestores de tráfego, transportes e de cidades quanto ao impacto de situações imprevistas em períodos acima de 60 minutos.

Todos os dados necessários à implementação do modelo, como proposto, foram discutidos quanto ao seu conteúdo e proposta de tratamento e estão disponíveis para uso, sendo que sua análise inicial será apresentada no próximo capítulo.

## **4 ANÁLISE PRELIMINAR DOS DADOS DISPONÍVEIS**

Os dados para o desenvolvimento da pesquisa foram obtidos somente entre novembro e dezembro de 2018. Conforme já destacado ao longo dos capítulos anteriores, pelo formato que os dados dos radares foram fornecidos (pastas diárias compactadas, cada qual com mais de 50 mil arquivos) ocorreram dificuldades no tratamento inicial de descompactação e unificação dos mesmos. Por consequência, a análise desses dados de radares foi efetivamente iniciada no início de março de 2019.

Dessa forma, considerando o prazo disponível para a etapa de qualificação, optamos por fazer uma breve incursão pelos dados disponíveis, em busca de entendê-los quanto à forma e conteúdo, avaliando-os quanto à sua integridade. Nosso objetivo foi o de iniciar a caminhada, de modo que fosse possível a tomada de decisão quanto às abordagens – metodologias, linguagens e sistemas - a serem utilizados no prosseguimento dos estudos, após o exame de qualificação.

Neste capítulo pretendemos apresentar os dados disponíveis e diversos indicativos de que é possível extrair dos mesmos as informações necessárias ao modelo de previsão de tráfego proposto.

Este capítulo inicia-se descrevendo a escolha das datas e local dos estudos preliminares efetuados, prossegue com a apresentação e análise preliminar dos dados, destacando-se a análise dos dados dos radares, seguida de análises menos detalhadas dos dados do Waze, das ocorrências da CET e da interrelação entre essas 3 fontes.

Na sequência, apresentamos uma análise inicial relativa à sazonalidade com base nos dados da CET e dos radares.

### **4.1 DAS ESCOLHAS INICIAIS E AJUSTES NECESSÁRIOS**

#### **4.1.1 Datas utilizadas na análise preliminar**

De início escolhemos o dia 09/05/18 por ser um dia útil (quinta-feira) anterior à greve dos caminhoneiros ocorrida no Brasil, e por estar esta data num mês típico, distante das férias escolares. Os estudos foram iniciados com os dados de radares, Waze, ocorrências da CET e chuva.

No desenrolar de nosso estudo exploratório preliminar, escolhemos inicialmente comparar o dia 09/05 com alguns dias do mês de novembro de 2018, tendo em vista que esse mês possui 2 feriados, possibilitando a análise de dias atípicos e, além disto, a ocorrência de queda parcial de um viaduto na Marginal Pinheiros, o que nos permitiria efetuar avaliações relativas ao seu impacto.

Todavia, após o preparo inicial dos dados dos radares, verificamos que não seria possível a análise conjunta com as informações de velocidade de trecho e de ocorrências do sistema Waze, no período escolhido, devido a uma falha técnica no servidor da CET que deixou de armazenar as informações do sistema Waze por vários dias nos meses de outubro e novembro de 2018.

Por decorrência, foi necessário escolher outro período para comparação e optamos por comparar os dados do dia 09/05/18 com os dias 06, 13, 14, 20 e 21 de setembro de 2018. Como vemos na Tabela 4.1, as datas escolhidas possibilitaram comparar 4 quintas-feiras, sendo que destas uma teve ocorrência de chuvas e outra foi uma véspera de feriado. Também foram escolhidas 2 sextas-feiras, uma com e outra sem chuva para verificar as semelhanças entre a véspera de feriado e as sextas-feiras.

Tabela 4.1 – Datas utilizadas no estudo preliminar

Data	09/05/2018	06/09/2018	13/09/2018	14/09/2018	20/09/2018	21/09/2018
Dia Semana	Quinta	Quinta (Véspera de Feriado)	Quinta	Sexta	Quinta	Sexta
Chuva	Não	Não	Não	Sim	Sim	Não

Fonte: O próprio autor

Os dados de radares para as novas datas foram organizados em formato adequado ao seu tratamento. Todavia, após o início das análises verificamos a necessidade de remontar ainda mais uma vez as tabelas de dados, devido às duplicidades de dados detectadas nesse momento.

Optamos por utilizar apenas o dia 09/05 nas análises exploratórias que compararam as informações extraídas dos radares com as dos demais sistemas.

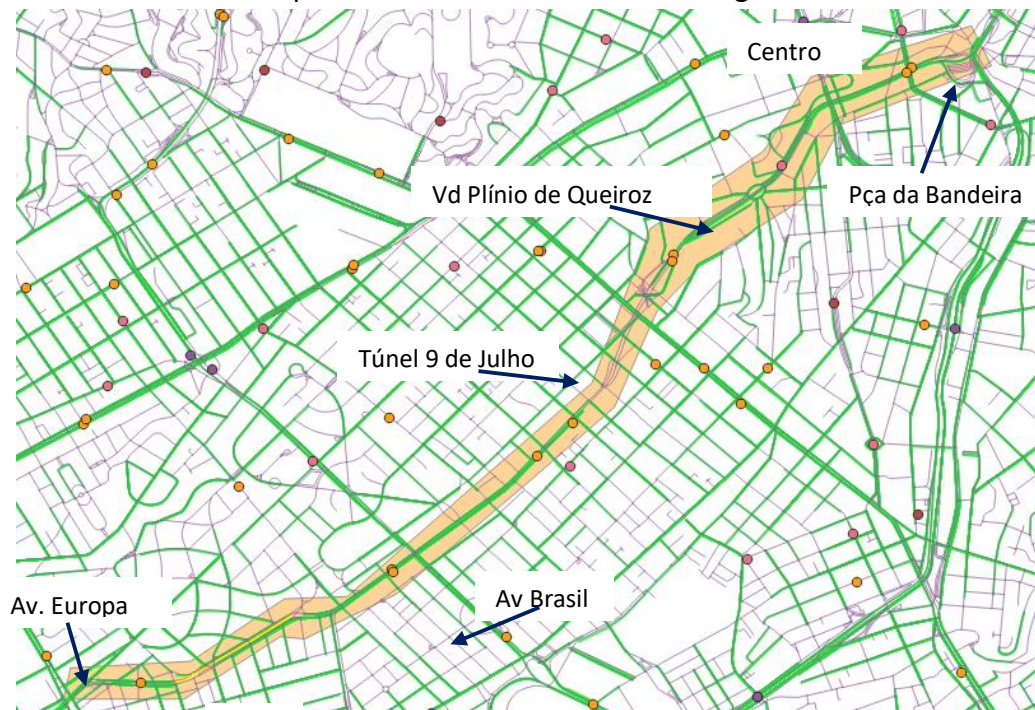
#### 4.1.2 Local escolhido para a análise preliminar comparativa

Para análises mais gerais utilizamos os dados de toda a cidade. Para a análise comparativa dos dados das diversas fontes e para alguns detalhamentos pontuais, escolhemos o corredor da Avenida 9 de Julho. A escolha desse corredor teve duas motivações iniciais:

- Por ser uma via dotada de radares ativos, com registros de lentidões e ocorrências, tanto no sistema Waze como no sistema de dados da CET;
- Por ser uma via com corredor de ônibus, o que permite verificar a diferença entre a velocidade dos coletivos e dos demais veículos nessa situação. Conforme já destacado no capítulo 3, os dados classificados dos radares nos permitiram avaliar esta característica.

A Av. 9 de Julho, tem cerca de 6 km de extensão e foi construída sobre um córrego canalizado. A via possui sentido duplo de circulação e canteiro central em toda sua extensão e está dividida em 4 trechos característicos:

Figura 4.1 – Av. 9 de Julho e posicionamento dos radares da região



Obs. Os pontos coloridos representam os locais dos radares e os trechos em verde são trechos onde ocorreu alguma lentidão registrada pelo aplicativo Waze no período.

Fonte: O próprio autor

- a) O trecho entre a Pça da Bandeira e o Túnel 9 de Julho tem 2 km de extensão e não tem cruzamentos, apenas semáforos de travessia de pedestres. Nesse trecho está o viaduto Plínio de Queiroz que passa sobre a Pça 14 Bis, único ponto onde haveria um cruzamento. Das 3 faixas de rolamento a da esquerda é um corredor de ônibus e as outras duas são destinadas aos veículos. O viaduto Plínio de Queiroz possui duas faixas por sentido e ponto de ônibus sobre ele, ver Figura 4.1;
- b) O túnel 9 de julho é composto por duas estruturas, uma por sentido, tem 0,8 km de extensão e duas faixas por sentido;
- c) No trecho de 1,9 km, entre o Túnel e a Av. São Gabriel, a via volta a ter 3 faixas por sentido, com o corredor de ônibus à esquerda. Este trecho tem diversos cruzamentos semaforizados, sendo o principal com a Av. Brasil;
- d) Quase todo o último trecho, localizado entre a Av. São Gabriel e a Av. Europa, tem 1,3 km e duas pistas por sentido, sendo duas faixas de rolamento em cada pista. A faixa da esquerda da pista central é destinada aos ônibus.

## 4.2 DADOS DOS RADARES

Os dados dos radares foram obtidos junto à Secretaria Municipal de Mobilidade e Transportes do Município de São Paulo, totalizando os 12 meses de 2018. Os dados de apenas um dia ultrapassam a casa de 24 milhões de registros.

Conforme apresentado no capítulo 3 os dados foram fornecidos em diversas pastas, cada qual com milhares de arquivos texto compactados, o que impôs uma etapa inicial de trabalho que envolvia a descompactação de arquivos e o preparo deles para o tratamento em formato de tabelas e bancos de dados.

Em nossa prospecção inicial, com dados de apenas alguns dias, já foi possível constatar que para as próximas etapas será necessária a utilização de ferramentas e linguagens construídas para o tratamento de BigData, conforme já citado no capítulo 3.

A Tabela 4.2 indica alguns dos quantitativos dos dados verificados na análise exploratória inicial. As duplicidades indicadas na tabela foram detectadas, quando passamos a avaliar a flutuação do fluxo ao longo do dia. Não estamos tratando aqui de uma duplicação total dos dados. Enquanto alguns registros não estavam duplicados, outros se repetiam até cerca de 10



vezes. Não foi possível definir a origem desse problema, todavia, conforme já citado no item 4.1, foi necessário refazer todas as tabelas que estávamos utilizando para as análises.

Os dados obtidos dos radares serviram de base para vários itens de nossos estudos conforme se constata ao longo deste documento.

Considerando que a quantidade de registros (fluxo de veículos), a velocidade pontual e o tempo de percurso entre dois pontos eram suficientes para a caracterização inicial do trecho, nesta etapa preliminar de nossos estudos optamos por não avaliar os dados de tempo de ocupação e do comprimento do veículo, sendo que estes últimos permanecem armazenados e disponíveis em nossos bancos de dados.

Tabela 4.2 – Resumo da quantidade média diária obtida na amostra de dados tratados

	Quantidade Média	Porcentagem
Quantidade de registros no bando de dados	50.649.453	205,46%
Registros com erro - ilegíveis	806	0,002%
Duplicidades detectadas	25.996.702	105,46%
Registros de passagem de Veículos	<b>24.651.945</b>	<b>100,00%</b>
Registros com Placa Identificada	18.354.894	74,75%
Registros sem Placa Identificada	6.225.597	25,25%
Velocidade Pontual Nula ou em branco	629.294	2,55%
Velocidade Pontual Excessiva (>150 km/h)	3.383	0,01%

Fonte: O próprio autor

#### 4.2.1 Quantidade de Placas Identificadas

Como apresentado na Tabela 4.3, considerando apenas os 7 dias avaliados até o momento, pouco menos de 75% dos veículos detectados tiveram suas placas identificadas pelo sistema OCR (*Optical Character Recognition*).

Dentre os veículos com placas identificadas fizemos uma análise da quantidade de vezes em que foram detectados durante um dia. Como 25% dos veículos detectados não foram identificados, é possível que parte desses veículos tenham sido identificados em outro ponto, todavia não foi possível aferir este fato, de modo que os dados apresentados na Tabela 4.3 referem-se apenas aos veículos identificados.

Conforme se verifica na Tabela 4.3 a grande maioria dos veículos, 44,7% foi detectada apenas uma vez ao longo do dia, outros 53% foram detectados entre 2 e 20 vezes e apenas 2% tiveram sua placa identificada entre 20 e 60 vezes.

Com relação aos que passaram mais de 60 vezes temos um grupo de 1.055 veículos que passou entre 61 e 120 vezes. Não evoluímos na análise desses casos neste momento, todavia podem ser ônibus que passam por vias com diversos radares instalados e, como repetem o percurso diversas vezes durante o dia podem atingir esse valor.

Por fim, os 90 veículos identificados mais de 120 vezes podem ou não representar algum tipo erro na coleta. Ainda assim, como nos interessava mais as análises da velocidade e quantidade por trecho, optamos por mantê-los nesta etapa e posteriormente efetuar uma análise mais detalhada para definir sobre a manutenção ou exclusão desses dados.

Tabela 4.3 – Quantidade de vezes em que uma placa é identificada durante um dia

	09/05	06/09	13/09	14/09	20/09	21/09	Média
Dia Semana	Quinta	Quinta*	Quinta	Sexta	Quinta	Sexta	
Chuva	Não	Não	Não	Sim	Sim	Não	
1 vez	2.194.285	2.053.718	1.849.801	1.876.947	1.715.157	1.876.026	1.927.656
2 vezes	526.656	531.139	494.505	507.651	485.005	513.856	509.802
3 vezes	327.477	344.089	318.377	329.454	316.221	335.598	328.536
4 vezes	253.149	271.210	250.745	258.360	251.570	264.889	258.321
5 a 10	798.378	874.779	834.038	827.431	827.358	879.317	840.217
11 a 20	322.795	345.201	371.145	328.126	371.123	384.808	353.866
21 a 30	58.492	62.987	71.581	59.054	73.385	74.446	66.658
31 a 60	24.530	27.255	34.078	23.947	34.271	35.212	29.882
61 a 120	682	820	1.377	748	1.238	1.462	1.055
121 a 180	47	47	49	47	41	46	46
181 a 240	22	10	11	14	20	12	15
240 ou mais	37	30	29	25	25	28	29
Total	4.506.550	4.511.285	4.225.736	4.211.804	4.075.414	4.365.700	4.316.082


\*véspera de feriado

Fonte: O próprio autor

Avaliando-se outro aspecto relativo à identificação das placas dos veículos, com base nos dados do dia 09/05 verificamos que a ocorrência de placas “não identificadas” pelos

equipamentos é maior entre o anoitecer e o amanhecer. A Figura 4.2 apresenta um gráfico de 140 radares (linhas) distribuídos em blocos de 10 em 10 minutos ao longo das 24 horas. Nessa representação, a cor vermelha indica pouca porcentagem de identificação, o verde indica o oposto e os trechos em branco indicam a ausência de dados. A Figura 4.3 é uma ampliação parcial da Figura 4.2 sendo possível verificar valores de não identificação de placas entre 0,04 (4%) e 0,98 (98%).

Figura 4.2 – Representação reduzida da porcentagem de placas não identificadas



Fonte: O próprio autor

Figura 4.3 – Ampliação da Figura 4.2, com indicação das taxas de placas não identificadas


	16:30	16:40	16:50	17:00	17:10	17:20	17:30	17:40	17:50	18:00	18:10	18:20	18:30
03	0,04	0,04	0,07	0,08	0,13	0,17	0,24	0,24	0,2	0,28	0,18	0,25	
06	0,05	0,06	0,11	0,11	0,22	0,15	0,25	0,04	0,07	0,08	0,1	0,05	
28	0,25	0,32	0,35	0,35	0,35	0,36	0,39	0,38	0,44	0,46	0,42	0,45	
15	0,19	0,18	0,2	0,26	0,46	0,43	0,3	0,35	0,28	0,28	0,27	0,27	
45	0,47	0,42	0,46	0,48	0,57	0,62	0,47	0,48	0,46	0,49	0,45	0,48	
07	0,09	0,09	0,1	0,12	0,14	0,14	0,16	0,26	0,25	0,27	0,27	0,3	
27	0,27	0,29	0,41	0,56	0,72	0,61	0,61	0,66	0,63	0,6	0,62	0,66	
17	0,18	0,15	0,12	0,28	0,43	0,68	0,65	0,65	0,61	0,61	0,62	0,59	
27	0,32	0,3	0,3	0,41	0,27	0,24	0,23	0,28	0,26	0,23	0,21	0,28	
08	0,08	0,09	0,07	0,17	0,43	0,65	0,66	0,67	0,7	0,65	0,71	0,71	
11	0,1	0,1	0,13	0,22	0,35	0,65	0,67	0,72	0,67	0,67	0,66	0,71	
06	0,06	0,04	0,09	0,08	0,09	0,28	0,2	0,26	0,28	0,32	0,24	0,28	
26	0,3	0,23	0,27	0,42	0,68	0,93	0,85	0,66	0,69	0,65	0,63	0,65	
16	0,17	0,16	0,17	0,24	0,41	0,71	0,7	0,74	0,73	0,74	0,74	0,7	
09	0,09	0,09	0,1	0,13	0,45	0,74	0,77	0,79	0,8	0,78	0,8	0,81	
15	0,06	0,13	0,14	0,11	0,1	0,12	0,2	0,24	0,22	0,22	0,22	0,21	
12	0,11	0,09	0,09	0,12	0,19	0,31	0,28	0,19	0,19	0,22	0,23	0,2	
21	0,23	0,21	0,28	0,42	0,6	0,87	0,89	0,91	0,91	0,89	0,88	0,89	
65	0,72	0,68	0,72	0,82	0,79	0,59	0,57	0,58	0,56	0,53	0,54	0,58	
06	0,04	0,04	0,06	0,1	0,13	0,11	0,14	0,17	0,16	0,17	0,17	0,16	
05	0,04	0,05	0,04	0,09	0,09	0,1	0,13	0,16	0,16	0,19	0,13	0,14	
37	0,17	0,31	0,23	0,16	0,25	0,14	0,08	0,11	0,16	0,15	0,11	0,11	
39	0,44	0,51	0,43	0,47	0,47	0,8	0,97	0,98	0,97	0,97	0,97	0,97	
16	0,17	0,13	0,11	0,21	0,46	0,47	0,42	0,62	0,65	0,63	0,71	0,66	

Fonte: O próprio autor

Verifica-se na Figura 4.4 que no dia 09/05/18, nos períodos sem sol a quantidade de placas não identificada é maior. Verificamos que os picos de não identificação de placas ocorrem nos horários de transição da luminosidade, pela manhã, no nascer do sol e à tarde quando do poente.

Essa variação na identificação das placas dos veículos implica na qualidade da determinação dos tempos de percurso entre dois pontos, já que reduzem a possibilidade de verificar a mesma placa em mais de um ponto de controle.

Figura 4.4 – Quantidade de veículos detectados x de placas não identificadas



Fonte: O próprio autor

#### 4.2.2 Dados excluídos da amostra inicial

Cerca de 2,5% dos dados foram desprezados por dois motivos diferentes:

- Registros sem informação de velocidade ou com velocidade nula;
- Registros que indicavam velocidades acima de 150 km/h.

O agrupamento dos dados em períodos de 10 em 10 minutos gerou uma matriz com 144 colunas e mais de 850 linhas, ou seja, mais de 120 mil células. Dos dados apresentados na Tabela 4.4 verificamos entre 1,0 e 1,8% de células em branco, fato que ocorre por dois motivos:

- a) Não havia nenhum registro com velocidade indicada naquele radar no período correspondente. Este tipo de informação consta do sistema apenas para controle contratual, sendo fornecida quando não foi verificada a passagem de nenhum veículo durante o período de 4 minutos. Portanto é uma informação que claramente deve ser excluída das análises de volumetria e velocidade;
- b) indicavam velocidade nula o que representaria que um veículo ficou sem se movimentar por mais de 4 minutos. Como essa situação é muito improvável, como a quantidade de dados nessa situação era pequena, e como não era possível identificar se tratava-se de falha ou não nos dados, fizemos a opção de excluí-los da base de estudos na etapa preliminar.

Tabela 4.4 – Quantidade de dados esperada e quantidade de dados ausentes/em branco

	09/05	06/09	13/09	14/09	20/09	21/09	Média
Chuva	Não	Não	Não	Sim	Sim	Não	
Radares ativos	851	866	866	865	867	869	864
Quantidade esperada de veículos	122.544	124.704	124.704	124.560	124.848	125.136	124.416
Quantidade com dados ausentes/ em branco	1.562	2.281	1.194	1.283	1.948	1.446	1.619
Porcentagem de dados excluídos	1,3%	1,8%	1,0%	1,0%	1,6%	1,2%	1,3%

Fonte: O próprio autor

Os dados ausentes, ou em branco, ocorrem mais às madrugadas e concentrados em alguns radares, em especial os radares portáteis, utilizados em fiscalizações específicas, e que, portanto, não representam um monitoramento continuado do fluxo. Excluídas essas situações, verificamos que menos de 0,5% das células de dados estavam em branco.

Os registros com velocidade excessiva, acima de 150km/h correspondiam a apenas 0,01%, todavia distorciam os dados de médias nos períodos em que ocorriam. Na amostra avaliada foram verificados registros com velocidades acima de 300 km/h, o que parece indicar algum tipo de erro do registro.

### 4.2.3 Agrupamentos por 2, 5 e 10 min


No tratamento dos dados iniciamos as análises com períodos de 10 minutos. A fim de aumentar a percepção sobre os dados efetuamos o agrupamento dos dados para períodos de 5 e de 2 minutos. Figura 4.6 a), b) e c).

Para os agrupamentos nos três padrões de períodos, 2, 5 e 10 minutos, foram preparadas tabelas com a quantidade de veículos detectados, a quantidade de placas identificadas, a velocidade média e seu desvio padrão e a mediana da velocidade.

Embora a agregação em períodos menores nos permita um melhor entendimento da variação temporal de um local, devemos considerar que estes fornecem menor quantidade de dados por grupo, podendo gerar mais grupos sem informações e que precisarão ser complementados.

Outra questão a ser considerada nos agrupamentos menores é que a maioria dos corredores urbanos possui semáforos, sendo que em corredores principais o tempo de ciclo semaforico frequentemente atinge 120 segundos ou até mais, de modo que é possível que numa amostra se tenha significativamente mais tempo de verde para o corredor avaliado do que outra o que implicaria em variações no volume entre amostras.

Figura 4.6 - Gráficos da distribuição do volume ao longo do dia de acordo agrupamento



Fonte: O próprio autor


#### 4.2.4 Velocidade Pontual Média x Mediana

Durante as análises dos dados verificamos que a mediana das velocidades na maioria das vezes indica valores acima da velocidade média (Figura 4.7), isto mostra que a distribuição das velocidades não é uniforme nos pontos de fiscalização. A maior parte dos veículos trafega em velocidades mais próximas ao limite fiscalizado.

Segundo Sarno et al. (2012), em estudo feito na Av. 23 de Maio em São Paulo, enquanto apenas 252 motoristas excederam a velocidade nos pontos onde estavam localizados os radares, 2348 excederam a velocidade média de percurso e somente 65 excederam tanto a velocidade pontual quanto a de percurso. Com isto, constaram que se tratava de um tipo de comportamento do motorista paulistano, de reduzir a velocidade apenas no ponto de fiscalização e trafegar acima da velocidade regulamentada quando no trecho entre os pontos de fiscalização. Isto explicaria termos verificado que a mediana é maior que a média.

Desta constatação, resta ainda uma avaliação a ser feita na próxima fase com relação à utilização da média ou da mediana nas etapas de estimação e de previsão.

Figura 4.7 – Relação entre a Mediana da Velocidade e a Velocidade Média



Fonte: O próprio autor

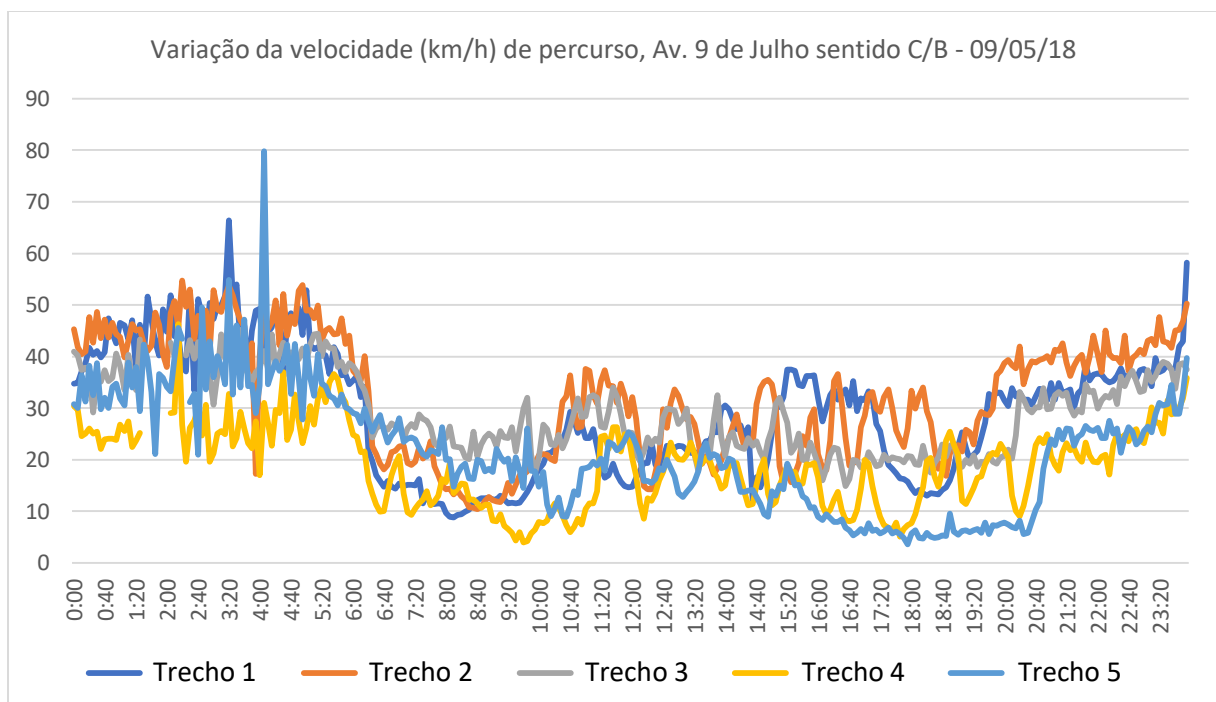


#### 4.2.5 Velocidade Média de Trecho

Iniciamos a análise relativa à obtenção da velocidade média de percurso num trecho, avaliando os dados da Av. 9 de Julho. O método utilizado foi o de pareamento de placas, considerando o tempo decorrido entre a passagem de um veículo num radar a montante e outro a jusante. Conhecido o tempo de percurso e com base nas distâncias obtidas em mapa foi efetuado o cálculo da velocidade de percurso.

Levando-se em conta que para o pareamento ser feito é necessário identificar um mesmo veículo em dois pontos de monitoramento (radares), e que essa dupla identificação não ocorre quando o veículo muda de via antes de atingir o segundo ponto ou, quando a placa do mesmo não é identificada em um dos pontos. Por consequência o volume de informações disponível para o cálculo do tempo de percurso é bastante reduzido, quando comparado com os dados totais disponíveis.

Figura 4.8 – Comparação da velocidade de percurso para diversos trechos da Av. 9 de Julho



Os trechos indicados são contíguos e são iniciados e encerrados em locais onde existem radares

Fonte: O próprio autor

Os testes iniciais de tempo de percurso foram feitos com a base agregada para cada 5 minutos. Foram verificadas as placas dos veículos que passaram por 6 radares localizados na

Av. 9 de Julho no sentido bairro. A Figura 4.8 apresenta a variação da velocidade de cada um dos 5 trechos analisados. Após a análise desses dados constatamos a necessidade de prosseguir com as avaliações na próxima fase, envolvendo períodos maiores para a agregação como, por exemplo, 10 minutos.

#### 4.2.6 Detalhamento por tipo de veículo

Os registros efetuados pelo sistema de radares nos fornecem uma classificação básica por tipo de veículo em 4 categorias: moto, automóvel, ônibus e caminhão. A Tabela 4.5 apresenta os dados resumidos e classificados por tipo de veículo com relação ao dia 09/05/2018.

Tabela 4.5 Resumo de dados por tipo de veículo no dia 09/05/18

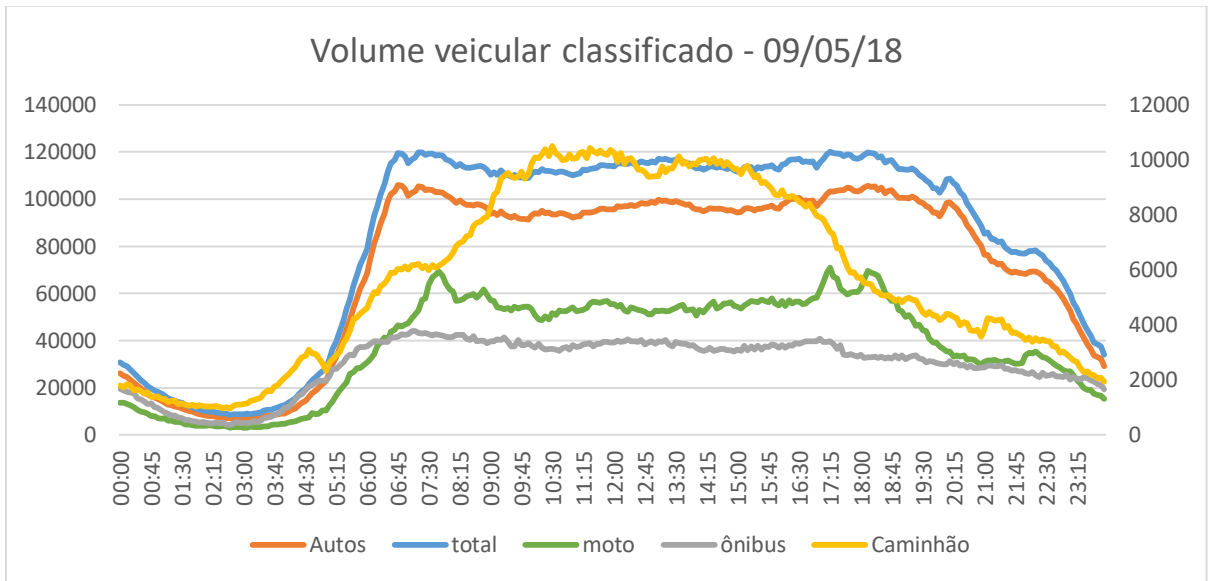
<b>Tipo</b>	<b>Média das Velocidades Médias</b>	<b>Desvio Padrão da Velocidade</b>	<b>Média das Medianas das Velocidades</b>	<b>Quantidade</b>	<b>Placa Não Identificada</b>	<b>% NÃO identificada</b>
Moto	35,05	7,92	35,68	959.414	656.885	68,5%
Auto	32,80	6,57	34,24	20.886.985	5.776.253	27,7%
Ônibus	31,57	5,95	32,74	741.746	186.799	25,2%
caminhão	32,71	5,89	33,70	1.651.443	203.818	12,3%

Fonte: O próprio autor

Na Figura 4.9, temos uma distribuição do volume por tipo de veículo ao longo do dia 09/05/18. Verifica-se que, diferentemente dos demais tipos, os caminhões tem uma característica mais concentrada no meio do dia. Isto pode estar relacionado às restrições de circulação direcionadas à esse tipo de veículo no Município de São Paulo, que os proíbe de trafegar nas principais vias nos horários de pico.

O volume de automóveis é muito superior aos demais e permanece quase constante ao longo do dia, reduzindo-se apenas no período da madrugada. Enquanto, durante o dia, são registrados em torno de 100.000 veículos a cada 5 minutos, os caminhões tem pico próximo a 10.000 e motos em torno de 5.000. no mesmo período

Figura 4.9 – Característica da distribuição do fluxo por tipo de veículo ao longo do dia




Obs. Motos, caminhões e ônibus estão plotados com base na escala do lado direito, Autos e total na escala do lado esquerdo.

Fonte: O próprio autor

As motos aparecem com dois pequenos picos, um pela manhã por volta das 07h30 e outro entre 17h20 e 18h30.

Na Figura 4.10 organizamos os dados de velocidade por tipo de veículo, sendo possível verificar que, no geral, as motos desenvolvem velocidades maiores que os demais veículos, o que pode estar relacionado com a prática de utilizar os corredores formados entre os carros. Já os ônibus operam em velocidade ligeiramente inferior.

Figura 4.10 – Comparação da velocidade média dos diversos tipos de veículos



Fonte: O próprio autor

### 4.3 DADOS DO WAZE

Os dados utilizados foram fornecidos pela CET, com base em contrato de cooperação existente entre a Secretaria Municipal de Mobilidade e Transportes e a Google, do qual a CET e o Waze são os atores na troca de informações.

Os dados são salvos e arquivados em formato de banco de dados a cada 30 minutos, com base na situação do momento. Por consequência, as situações iniciadas e encerradas durante um intervalo das gravações são perdidas, uma vez que são inseridas e retiradas do sistema durante esse período. As situações, trechos de lentidão e alertas, são armazenadas com o horário em que é feita a coleta, não sendo possível determinar com maior precisão o momento em que o alerta foi emitido.

#### 4.3.1 Dados de Lentidão do Waze


Os dados de lentidão e velocidade do Waze são apresentados apenas para os trechos onde se detecta algum tipo de atraso (delay). O atraso é sempre medido com base na diferença do tempo de percurso do mesmo trecho em relação a um momento de trânsito livre, normalmente obtido com as velocidades da madrugada.

Dessa forma, os trechos medidos variam de acordo com o momento, sendo necessário colocá-los numa base geográfica para identificar a reincidência de lentidões num mesmo local.

Em nosso estudo utilizamos o software QGIS para a tarefa de organizar os dados e estudá-los. No caso do estudo da Av. 9 de Julho, foi possível verificar as extensões e a frequência verificando-se a quantidade de feições de lentidão existentes num mesmo trecho de via e também analisar as características dessas lentidões, como: extensão e ponto de término. Para a próxima etapa de trabalho será necessário automatizar essa análise, para possibilitar seu uso num sistema de previsão.

A Figura 4.11 apresenta simultaneamente a soma das extensões de lentidão e o tempo médio de atraso do dia 09/05/18, indicadas pelo aplicativo. As lentidões atingiram, nesse dia, um pico de 1.414 km às 18h30. A média dos atrasos nos trechos com algum tipo de lentidão, variou em torno de 150 segundos durante o dia e próximo a 50 segundos na madrugada.

Figura 4.11 – Extensão dos trechos e tempo médio de atraso – Dados do Waze – 09/05/18



Obs. Dados do Eixo Y à esquerda em metros e à direita em segundos

Fonte: O próprio autor

#### 4.3.2 Dados de Alertas do Waze

Os alertas são gerados pelos usuários do aplicativo, sendo que a localização pode não ser precisa, pois depende da posição em que o usuário está quando indica o alerta. Apesar disto, é possível utilizar a informação no processo de análises cruzadas conforme é discutido no item 4.5.

Não tivemos acesso à informação de como é dado baixa em cada alerta, ou seja, como é feita a definição de manter ou não um alerta ativo no aplicativo.

Para cada alerta são disponibilizadas informações de horário de indicação do alerta por parte do usuário, nome da via, localização geográfica (latitude e longitude), direção (azimute) em que seguia o usuário que informou o alerta (com essa informação é possível inferir o sentido da via em que o usuário trafegava), tipo e subtipo do alerta e a confiabilidade da informação, sendo esta última indicada com base em estatísticas do próprio aplicativo, porém as quais não tivemos acesso.

#### 4.4 DADOS DA CET

A CET nos forneceu dados de extensão de lentidão registrados no sistema PintaLent (sistema desenvolvido pela própria CET para o registro de lentidões) e de ocorrências registradas no seu sistema de gestão de ocorrências.

Os dados iniciais perfazem 5 anos de informações para os dois tipos de informação, todavia apenas os dados de ocorrências estão georreferenciados.

#### **4.4.1 Dados de Lentidão fornecidos pela CET**

Os dados de lentidão fornecidos pela CET estavam organizados por via e horário de registro. Estavam disponíveis a extensão, o sentido e a pista do trecho lento. Havia ainda a indicação do trecho em forma de texto. Não existiam informações geográficas que possibilitassem a inserção direta dessas informações em mapas georreferenciados.

Os dados foram utilizados no processo de análise cruzada e nas análises de sazonalidade, conforme indicados nos respectivos itens.

#### **4.4.2 Dados de Ocorrências Atendidas Pelas Equipes da CET**

Com base nos códigos selecionados no Anexo A, para o dia 09/05 selecionamos 900 das 3773 ocorrências registradas. Na Tabela 4.6 vemos a quantidade de registros por tipo de ocorrência, separando-se as que foram selecionadas das que foram descartadas.

Os dados selecionados foram utilizados conforme indicado no próximo item que trata das análises cruzadas de dados.

Tabela 4.6 Detalhamento da quantidade de ocorrências informadas pela CET no dia 09/05/18

SELECIONADAS		DESCARTADAS			
Código	Quantidade	Código	Quantidade	Código	Quantidade
201	2	209	80	503	12
202	6	210	1	505	4
204	37	211	8	510	1
205	186	215	15	562	5
206	57	216	1	564	4
207	61	219	20	568	3
208	8	220	131	569	8
217	99	222	43	570	3
218	49	223	6	571	6
224	10	225	21	572	7
228	45	226	4	576	13
229	6	227	5	577	36
230	12	233	3	578	22
237	7	234	2	585	29
302	31	235	1	593	1
303	65	251	18	603	9
304	8	255	11	604	130
305	6	335	9	605	7
310	3	348	8	608	12
316	2			610	1358
321	6			611	488
331	1			618	326
334	6				
337	9				
561	83				
563	26				
565	69				
	900		387		2484


Fonte: O próprio autor

#### 4.5 ANÁLISE CRUZADA DOS DADOS

Buscamos aqui verificar a possibilidade de cruzamento dos dados das diversas fontes visando os estudos da próxima fase. A seguir ilustramos esta análise com um pequeno exemplo.

A Figura 4.12 apresenta o volume de veículos medido a cada 5 minutos no radar posicionado no sentido do Centro para o Bairro da Av. 9 de Julho, na altura do número 398. O gráfico apresenta dois pontos claros de redução de volume, um às 06h25 e outro às 14h40.


Figura 4.12 – Volume de veículos a cada 5 minutos na Av. 9 de Julho 398



Fonte: O próprio autor

Poderíamos supor que a queda no volume nesse local fosse verificada em período de tempo próximo, nos pontos de contagem seguinte ou anterior, no mesmo sentido, todavia o fato não ocorreu. Isto provavelmente se deve à curta duração da redução do volume. Como vemos na Figura 4.13 o ponto anterior localizado na Av. Santos Dumont, apresentou redução às 08h00; 16h10, 18h05 e 21h55. Já o posterior não apresentou variações significativas.

Figura 4.13 – Volumes detectados na Av. 9 de Julho 398 e nos radares a montante e jusante desse ponto.



Fonte: O próprio autor




Analisando de modo mais detalhado a Figura 4.13, verificamos que entre 08h10 e 08h20 ocorreu uma redução no volume do ponto analisado. Esta redução é menor que as outras duas avaliadas anteriormente, todavia ela ocorre 10 minutos após a queda brusca na Av. Santos Dumont, que é o ponto anterior.

Após a análise inicial relativa aos volumes, passamos a avaliar as variações das velocidades nos mesmos 3 pontos que utilizamos para verificar os volumes. Como vemos na Figura 4.14 no ponto da Av. 9 de Julho 398 tivemos um período com clara redução nas velocidades entre 7h50 e 9h30 e outra pequena redução às 15h15. Comparando-se inicialmente com os dados de volume do mesmo ponto (Figura 4.12) podemos constatar que são posteriores aos 2 principais picos de redução de volume. No entanto, a redução ocorrida no período da manhã coincide com a redução de volume ocorrida às 08h10.


Também é notável, na Figura 4.14, que o ponto de controle anterior, localizado na Av. Santos Dumont, apresenta redução nas velocidades no mesmo período. Já o ponto de controle posterior, na Av. 9 de Julho 2054, cuja curva de velocidades está apresentada na Figura 4.15, não apresentou variação significativa nesse lapso de tempo.

Figura 4.14 - Comparação da velocidade da Av. 9 de Julho e o ponto a montante



Fonte: O próprio autor

Figura 4.15 – Comparação das velocidades da Av. 9 de Julho 398 e ponto a jusante



Fonte: O próprio autor

Em continuidade à análise cruzada dos dados buscamos verificar os dados de ocorrências em busca de fatos que pudessem explicar tais alterações. Nos dados registrados pelas equipes da CET não verificamos qualquer informação que justificasse as variações de volume e velocidade detectadas nas figuras anteriores. Mas, voltamo-nos então à análise dos dados de ocorrências do Waze verificamos o registro de 3 acidentes nesse mesmo dia no sentido e com influência nos trechos avaliados:

- O primeiro informado em algum momento entre 06h28 e 06h58 ocorreu na Av. Prestes Maia. Esta via está localizada entre a Av. Santos Dumont e a Av. 9 de Julho. Neste caso verificamos apenas o impacto no volume do ponto da Av. 9 de Julho 389 e sem impacto no volume ou velocidade do ponto anterior (Av. Santos Dumont).
- O segundo foi informado entre 07h28 e 7h58 e estava localizado junto à Praça 14 Bis, sob o Viaduto Plínio de Queiroz. A possível lentidão causada por esse acidente pode ser a explicação da redução na velocidade sentida nos dois pontos. Verifica-se que, a velocidade no radar posterior, localizado na Av. 9 de Julho 2054, após a Pça 14 Bis onde ocorreu o acidente, não sofreu variação, ou seja, não foi impactada pelo acidente.
- O terceiro acidente ocorreu também na Pça 14 Bis e foi informado entre 17h58 e 18h28. Nesse período verifica-se apenas um pequena redução nas velocidades verificadas no radar da Av. 9 de Julho 398 às 18h40.

Desta análise cruzada dos alertas do Waze com os dados de velocidade e volume dos radares pudemos avaliar a possibilidade de se prosseguir com estudos no sentido de utilizar os dados dos radares para inferir uma possível ocorrência na via.


Por fim, verificamos os trechos e extensões de lentidões registradas pelo Waze e constatamos o registro de 900 m de trecho lento no sentido do Centro para o Bairro, entre a Pça 14 Bis e proximidades do número 400 da Av. 9 de Julho, de modo que esta informação não confirma claramente o impacto verificado na velocidade média no radar da Av. Santos Dumont.

Segundo os dados da CET até a medição das 08h30 não havia lentidão no trecho e entre 09h00 e 11h00 a lentidão chegou até a R Avanhadava, ou seja, a cerca de 450 m da Pça 14 Bis.

Dessa forma, vemos que tanto Waze como CET indicaram lentidões semelhantes com defasagem de meia hora entre si (08h30 e 09h00). Todavia, a semelhança na variação da velocidade da Av. 9 de Julho 398 e da Av. Santos Dumont no mesmo período, nos levam a ponderar sobre a possibilidade da lentidão causada pelo acidente ter efetivamente atingido a Av. Santos Dumont, tendo permanecido por período menor que 30 minutos, motivo pelo qual deixou de constar nos registros da CET e do Waze que são armazenados com esse intervalo de tempo.

Para aprimoramento de nossas análises na próxima fase de estudos, verifica-se a necessidade de que os dados dessas duas fontes sejam obtidos com frequência menor de tempo, se possível com no máximo 5 minutos.

Figura 4.16 – Velocidade Média por tipo de Veículo na Av. 9 de Julho nº 398




Fonte: O próprio autor

Ainda avaliando o mesmo caso de redução de velocidade, elaboramos a Figura 4.16, que representa a variação da velocidade pontual no radar da Av. 9 de Julho 398, à montante do acidente. É possível verificar que a redução na velocidade foi menos sentida pelos ônibus. Isto certamente está relacionado ao fato da Av. 9 de Julho ser sinalizada com corredor exclusivo de ônibus à esquerda e pelo fato de que quase todos os ônibus que trafegam por ela utilizam o viaduto Plínio de Queiroz localizado sobre a Praça 14 Bis onde ocorreu o acidente.

#### 4.6 SAZONALIDADE

Iniciamos as análises deste tópico com base nos dados de Lentidão da CET. Foram efetuadas comparações com os dados dos anos de 2014 a 2018, permitindo já entender e confirmar nossas expectativas com relação a diversas características. O ano de 2015 apresenta os dados mais próximos à média dos anos avaliados (Figura 4.17). Destaca-se a redução das lentidões nos meses de férias escolares, com ênfase para janeiro e julho.

Figura 4.17 – Comparação das Lentidões Mensais dos anos de 2014 a 2018




Obs. Eixo Y corresponde ao total de quilômetros ocorrido no mês

Fonte: O próprio autor com base nos dados fornecidos pela CET

Detalhando melhor o mês de dezembro, verificamos a existência de característica específica, com forte redução no fluxo no período entre o natal e o final do ano, conforme podemos verificar na Figura 4.18.


Figura 4.18 – Extensão das Lentidões medidas pela CET nos meses de dezembro



Fonte: O próprio autor com base nos dados fornecidos pela CET

O gráfico da Figura 4.19 mostra a variação diária do fluxo no ano de 2015. Verifica-se claramente a presença de feriados em fevereiro (carnaval), abril (Tiradentes) e julho (9 de julho). Também é possível verificar que a última semana de dezembro tem o fluxo muito menor do que todas as outras semanas do ano em janeiro as lentidões vão aumentando a cada semana. Percebe-se ainda a variação semanal com clara identificação dos finais de semana com menor fluxo.


Figura 4.19 – Lentidão Diária medida pela CET no ano de 2015



Fonte: O próprio autor com base nos dados fornecidos pela CET

Já com relação à variação horária, devemos considerar a variação do movimento residência para o trabalho pela manhã e o retorno à residência no final da tarde. Essa variação, característica dos meios urbanos, causa variações significativas de volume num mesmo ponto. A fim de ilustrar tal fato, elaboramos o gráfico da Figura 4.20 que indica a porcentagem horária de tráfego. Dos 852 radares disponíveis no dia 09/05 fizemos a média dos 150 locais com maior concentração de fluxo no pico da manhã, dos 150 cujo fluxo é concentrado no entre-picos e também daqueles 150 com maior concentração no pico da tarde.


Figura 4.20 – Distribuição dos volumes em locais com característica de fluxo horário diferentes.



Fonte: O próprio autor

A semana do Carnaval é uma semana atípica. O carnaval ocorre sempre às terças-feiras e, embora não seja um feriado oficial, por tradição, entre segunda e terça-feira não ocorre expediente comercial e na quarta-feira de cinzas o expediente inicia-se apenas às 12h00. Por ser uma semana com menos dias úteis o fluxo após meio dia de quarta e também na quinta e sexta são menores do que a média do mês. Os gráficos da Figura 4.21, obtidos dos dados de lentidão medidos pela CET em 2015, demonstram essas características.

Figura 4.21 – Gráficos das medições de lentidão da CET relativos ao Carnaval de 2015



Fonte: O próprio autor com base nos dados fornecidos pela CET

Para maior detalhamento deste tópico, com relação à influência dos dias atípicos (carnaval, dias de jogos do Brasil, vésperas de feriado, etc) na distribuição e variação do fluxo pela cidade seria necessária a análise comparativa dos dados de lentidão da CET com os dados do Waze e de volumetria dos radares.

A análise específica e comparativa deste item implicaria na necessidade do uso de ferramentas de informática mais adequadas ao volume e característica desses dados, como o uso de linguagem Python ou R e utilização de hardware com a capacidade de armazenamento e processamento correspondente. Ressalta-se que tanto softwares como hardware já estão disponíveis no laboratório LMAG da USP, restando a necessidade de aprofundamento no uso das ferramentas para o tratamento dos dados, o que deverá ocorrer na próxima etapa. Na mesma direção devemos considerar que para o uso dessa variação pontual nos trabalhos de previsão de tráfego com uso de simuladores seria necessária a elaboração de matrizes de origem e destino específicas para cada situação, o que, embora possível, demandaria um grande esforço e tempo de trabalho, incompatíveis com a pesquisa aqui desenvolvida, motivo pelo qual optamos por elaborar na próxima fase apenas as matrizes dos dias típicos, de modo que em tempo de implantação do projeto de previsão do tráfego as outras matrizes poderão ser elaboradas e incorporadas ao modelo proposto.

## 4.7 DADOS AINDA NÃO ANALISADOS

Até o momento em que concluímos a redação deste texto não havia sido possível tratar os dados relativos à Matriz OD e Chuvas

### 4.7.1 Matriz OD para Alocação Dinâmica

Embora os dados da Matriz OD 2007, atualizada para 2012, já estivessem disponíveis, optamos por aguardar a liberação dos dados detalhados da Matriz 2017. Além disto, para as análises com Alocação Dinâmica é necessário estabelecer claramente a variação das viagens ao longo do tempo, o que será feito durante o tratamento dos dados dos radares previsto para a etapa seguinte de nossos estudos.

Após a conclusão dos estudos citados, serão elaboradas as matrizes OD para os períodos mais característicos do dia útil e para os finais de semana. Caso haja disponibilidade de prazo, serão também elaboradas as matrizes de alguns dos dias atípicos citados no item de sazonalidade do capítulo 3.

### 4.7.2 Dados de Chuvas

Embora ainda não tenhamos desenvolvido estudos com relação aos dados de chuvas fornecidos pelo IAG, conforme apresentamos no capítulo 3, estudos existentes indicam que a ocorrência de chuva induz à redução da velocidade (GONÇALVES, 2018). Embora o índice de redução obtido nesse estudo seja relativo ao transporte coletivo, é possível expandir a análise aos demais veículos.

Consideraremos o volume de precipitação distribuído uniformemente nas áreas de medição, uma vez que os dados são fornecidos com essa granularidade, de modo que a redução de velocidade, causada pela precipitação, será homogênea na área.



## 4.8 CONSIDERAÇÕES FINAIS DO CAPÍTULO 4

### 4.8.1 Os dados disponíveis

Da análise cruzada podemos concluir que existe a possibilidade de uso conjunto dos dados no trabalho de previsão, uma vez que as informações de um sistema podem complementar as informações de outros. A abordagem efetuada buscou destacar a relação espacial e temporal dos fatos e a necessidade de se considerar diversas fontes e informações possíveis de serem extraídas destas.

Com relação à análise que considera pontos próximos, como a que efetuamos na Av. 9 de Julho, é uma das abordagens possíveis na análise e diferenciação entre os outliers causados por intercorrências na via, por variações naturais do tráfego e por falhas sistêmicas. Este estudo deverá ser aprofundado, buscando-se tratar vários casos e incluir na ferramenta de estimação essa característica espacial. Para tal, será necessário o uso de ferramentas já utilizadas na análise preliminar, como o QGIS.

No caso do estudo da Av. 9 de Julho foi possível verificar as extensões e a frequência, verificando-se a quantidade de feições de lentidão existentes num mesmo trecho de via e também analisar as características dessas lentidões, como: extensão e ponto de término.

### 4.8.2 O prosseguimento dos estudos

Da análise preliminar dos dados já foi possível verificar a necessidade de efetuar uma avaliação relativa à utilização da média ou da mediana nas etapas de estimação e de previsão.

O volume de dados envolvido na pesquisa implica no uso de ferramentas de BigData, como as linguagens Python e R, e a utilização de hardware com a capacidade de armazenamento e processamento correspondente. Ressalta-se que tanto os softwares como o hardware foram recentemente disponibilizados no laboratório LMAG da USP.

As análises devem ser direcionadas à viabilização do uso dos dados de modo automatizado, uma vez que se pretende que os dados, após serem tratados, sejam utilizados no sistema de previsão proposto.

Para o aprimoramento dos estudos e do modelo proposto, verifica-se a necessidade de que os dados do Waze e de lentidão da CET sejam obtidos com frequência menor de tempo, se possível com no máximo 5 minutos.

Para melhor entendimento da variação do fluxo pela cidade será necessária a análise comparativa dos dados de lentidão da CET com os dados do Waze e de volumetria dos radares.

## 5 CONCLUSÕES PARCIAIS E PRÓXIMOS PASSOS

### 5.1 CONCLUSÕES PARCIAIS

Quando iniciamos nossos estudos sobre a possibilidade de efetuar a previsão de tráfego tínhamos como visão inicial o uso dos dados dos radares e das ocorrências da CET, como base para alimentar um simulador de tráfego.

Ao longo das pesquisas essa abordagem foi aprimorada, incluindo-se outros dados, como os provenientes do Waze e de Chuva. Além disto, verificamos que a utilização simples dos dados não seria suficiente para um modelo de previsão de boa qualidade, sendo necessária a qualificação do tráfego por trecho de via, de modo que fosse possível indicar ao simulador as características de oferta e demanda a cada momento.

A base teórica verificada nos permitiu a elaboração do modelo a ser seguido, conforme apresentado na Figura 3.2. Todavia, o tempo disponível após a obtenção dos dados não nos permitiu avançar mais no seu tratamento e na montagem de um modelo mais completo de nossa proposta.

Os dados necessários à pesquisa estão disponíveis e acessíveis. Um grande esforço foi colocado na análise preliminar dos dados, o que foi produtivo, pois após esta etapa inicial temos maior compreensão da demanda a ser enfrentada e das necessidades relativas aos softwares e hardwares para a pesquisa.

Embora a análise dos dados obtidos seja preliminar, já foi possível verificar o potencial de uso dos mesmos através de uma análise pontual da Av. 9 de Julho.

Os trabalhos, até aqui desenvolvidos, justificam e servem de base para a próxima etapa de pesquisa, na qual desenvolveremos cada aspecto discutido, de modo mais detalhado e integrado, possibilitando atingir o objetivo de caracterizar o tráfego, viabilizando o uso dessas informações em sistemas de previsão de curto prazo.

## 5.2 CRONOGRAMA DE TRABALHO

A Tabela 5.1 apresenta nossa proposta de continuidade dos estudos

Tabela 5.1 – Cronograma das próximas etapas de trabalho

Período	Atividade
06 a 10/19	Estudos do uso de Linguagem Python e R para aplicação na análise dos dados
11/19 a 04/20	Análise dos dados de Radares com uso de linguagem Python ou R
05/20	Preparo do artigo sobre os dados de radares
06 a 08/20	Análise cruzada dos dados de radares com os dados dos demais sistemas
09/20	Preparo de artigo para congresso
09 a 12/20	Estudos sobre a complementação dos dados ausentes nos sistemas e “outliers”
01 a 04/21	Preparo das Matrizes OD para alocação dinâmica
05 a 07/21	Testes de aplicação dos dados organizados em Simulador de Tráfego
08 a 11/21	Redação do texto final
12/21	Preparo do artigo final
02/22	Defesa da Tese

## REFERÊNCIAS BIBLIOGRÁFICAS

- ABDULLATIF, A.; ROVETTA, S.; MASULLI, F. **Layered ensemble model for short-term traffic flow forecasting with outlier detection**. 2016 IEEE 2nd International Forum on Research and Technologies for Society and Industry Leveraging a Better Tomorrow, RTSI 2016. **Anais...**2016
- AGHAMOHAMMADI, R.; LAVAL, J. A. Dynamic Traffic Assignment using the Macroscopic Fundamental Diagram: A Review of Vehicular and Pedestrian Flow Models. 2018.
- ALFREDO NANTES et al. Real-time traffic state estimation in urban corridors from heterogeneous data. **Transportation Research Part C: Emerging Technologies**, v. 66, p. 99–118, 1 maio 2016.
- ALLSTRÖM, A. et al. Hybrid Approach for Short-Term Traffic State and Travel Time Prediction on Highways. **Transportation Research Record: Journal of the Transportation Research**, v. 2554, p. 60–68, 2016.
- ARMSTRONG, J. S.; COLLOPY, F. Error measures for generalizing about forecasting methods: Empirical comparisons. **International Journal of Forecasting**, v. 8, n. 1, p. 69–80, 1992.
- ASAKURA, Y. et al. Incident detection methods using probe vehicles with on-board GPS equipment. **Transportation Research Part C: Emerging Technologies**, v. 81, 2017.
- ATTANASI, A. et al. Real World Applications Using Parallel Computing Techniques in Dynamic Traffic Assignment and Shortest Path Search. **2015 IEEE 18th International Conference on Intelligent Transportation Systems**, p. 316–321, 2015.
- BAIOCCHI, A. et al. Vehicular Ad-Hoc Networks sampling protocols for traffic monitoring and incident detection in Intelligent Transportation Systems. **Transportation Research Part C: Emerging Technologies**, v. 56, 2015.
- BARROS, O. M. DE. **CIMU - Integrated center for urban mobility São Paulo, Brazil**. 21st World Congress on Intelligent Transport Systems, ITSWC 2014: Reinventing Transportation in Our Connected World. **Anais...**2014
- BARROS, O. M. DE. Uso de Simuladores de Tráfego e Alocação Dinâmica na Previsão de Tráfego de Curto Prazo. **Revista UniCET**, v. 1, p. 23–37, 2018.
- BATTY, M. et al. Smart cities of the future. **THE EUROPEAN PHYSICAL JOURNAL Special Topics The European Physical Journal Special Topics**, v. 214, p. 481–518, 2012.
- BEN-AKIVA, M. et al. Real Time Simulation of Traffic Demand-Supply Interactions within DynaMIT. In: [s.l.] Springer, Boston, MA, 2002. p. 19–36.
- BERNARDI, E. **Os sistemas de identificação veicular, em especial o reconhecimento automático de placas**. [s.l.] Universidade de São Paulo, 2015a.
- BERNARDI, E. **Os sistemas de identificação veicular, em especial o reconhecimento automático de placas**. [s.l.] Universidade de São Paulo, 2015b.
- BLIEMER, M. C. J. et al. Quasi-dynamic traffic assignment with residual point queues incorporating a first order node model. **Transportation Research Part B: Methodological**, v. 68, p. 363–384, 2014.
- BOLSHINSKY, E.; FRIEDMAN, R. **Traffic Flow Forecast Survey**. [s.l.: s.n.]. Disponível em: <<http://www.cs.technion.ac.il/users/wwwb/cgi-bin/tr-info.cgi/2012/CS/CS-2012-06>>. Acesso em: 16

dez. 2018.

BURGHOUT, W. **Mesoscopic Simulation Models for Short-Term Prediction Hybrid microscopic-mesoscopic traffic simulation View project**. linkopings universitet: [s.n.]. Disponível em: <<https://www.researchgate.net/publication/255654806>>. Acesso em: 8 maio. 2019.

BURGHOUT, W.; KOUTSOPOULOS, H. N.; ANDREASSON, I. A Discrete-Event Mesoscopic Traffic Simulation Model for Hybrid Traffic simulation. **Proceedings of the IEEE Intelligent Transportation Systems Conference (ITSC)**, n. September 2014, p. 1102–1107, 2006a.

BURGHOUT, W.; KOUTSOPOULOS, H. N.; ANDREASSON, I. **A discrete-event mesoscopic traffic simulation model for hybrid traffic simulation**. 2006 IEEE Intelligent Transportation Systems Conference. **Anais...IEEE**, 2006bDisponível em: <<http://ieeexplore.ieee.org/document/1707369/>>. Acesso em: 3 nov. 2018

BURGHOUT, W.; KOUTSOPOULOS, H. N.; ANDREASSON, I. Incident Management and Traffic Information Tools and Methods for Simulation-Based Traffic Prediction. **Transportation Research Record**, n. 2161, p. 20–28, 2010.

CALABRESE, F. et al. **The Geography of Taste: Analyzing Cell-Phone Mobility and Social Events**. International Conference on Pervasive Computing. **Anais...Springer**, Berlin, Heidelberg, 2010Disponível em: <[http://link.springer.com/10.1007/978-3-642-12654-3\\_2](http://link.springer.com/10.1007/978-3-642-12654-3_2)>. Acesso em: 29 out. 2017

CALABRESE, F.; LORENZO, G. DI. Estimating Origin- Destination Flows using Mobile phone Location Data. **Pervasive and Mobile Computing**, v. 10, p. 36–44, 2011.

CAMUS, R.; CANTARELLA, G. E.; INAUDI, D. Real-time estimation and prediction of origin—destination matrices per time slice. **International Journal of Forecasting**, v. 13, n. 1, p. 13–19, 1997a.

CAMUS, R.; CANTARELLA, G. E.; INAUDI, D. Real-time estimation and prediction of origin—destination matrices per time slice. **International Journal of Forecasting**, v. 13, n. 1, p. 13–19, 1 mar. 1997b.

CASTILLO, E. et al. A State-of-the-Art Review of the Sensor Location, Flow Observability, Estimation, and Prediction Problems in Traffic Networks. **Journal of Sensors**, v. 2015, p. 1–26, 29 out. 2015.

CASTRO-NETO, M. et al. Expert Systems with Applications Online-SVR for short-term traffic flow prediction under typical and atypical traffic conditions. **Expert Systems With Applications**, v. 36, n. 3, p. 6164–6173, 2009.

CHEN, A. et al. Transport Network Design Problem under Uncertainty: A Review and New Developments. **Transport Reviews**, v. 31, n. 6, p. 743–768, 2011.

CHEN, C. et al. The retrieval of intra-day trend and its influence on traffic prediction. **Transportation Research Part C: Emerging Technologies**, v. 22, p. 103–118, 1 jun. 2012.

CHEN, M.; CHIEN, S. I. J. Dynamic Freeway Travel-Time Prediction with Probe Vehicle Data. **Transportation Research Record**, v. 1768, p. 157–161, 2001.

CHEN, X.; OSORIO, C. **Analytical formulation of the trip travel time distribution**. Transportation Research Procedia. **Anais...2014**

CIPRIANI, E. et al. **A procedure for urban route travel time forecast based on advanced traffic data: Case study of Rome**. 2014 17th IEEE International Conference on Intelligent Transportation Systems, ITSC 2014. **Anais...**2014

CONCEIÇÃO, L.; ROSSETTI, R. J. F. **Multivariate modelling for autonomous vehicles: Research trends in perspective**. IEEE Conference on Intelligent Transportation Systems, Proceedings, ITSC. **Anais...**2016

DE LUCA, G.; GALLO, M. **Artificial neural networks for forecasting user flows in transportation networks: Literature review, limits, potentialities and open challenges**. 5th IEEE International Conference on Models and Technologies for Intelligent Transportation Systems, MT-ITS 2017 - Proceedings. **Anais...**2017

DIA, H.; THOMAS, K. Development and evaluation of arterial incident detection models using fusion of simulated probe vehicle and loop detector data. **Information Fusion**, v. 12, n. 1, p. 20–27, 1 jan. 2011.

ERMAGUN, A.; LEVINSON, D. **Spatiotemporal Traffic Forecasting: Review and Proposed Directions**. 96th Annual Transportation Research Board Meeting. **Anais...**2017Disponível em: <[https://conservancy.umn.edu/bitstream/handle/11299/181541/Spatiotemporal Traffic Forecasting - Review and Directions.pdf?sequence=1](https://conservancy.umn.edu/bitstream/handle/11299/181541/Spatiotemporal%20Traffic%20Forecasting%20-%20Review%20and%20Directions.pdf?sequence=1)>. Acesso em: 4 fev. 2018

ERMAGUN, A.; LEVINSON, D. Spatiotemporal traffic forecasting: review and proposed directions. **Transport Reviews**, v. 38, n. 6, p. 786–814, 2 nov. 2018.

FHWA OFFICE OF HIGHWAY INFORMATION MANAGEMENT. **ITS PROBE VEHICLE TECHNIQUES**. [s.l.: s.n.]. Disponível em: <<https://www.fhwa.dot.gov/ohim/handbook/chap5.pdf>>. Acesso em: 3 nov. 2018.

FRIEDRICH, M. et al. Generating Origin–Destination Matrices from Mobile Phone Trajectories. **Transportation Research Record: Journal of the Transportation Research Board**, v. 2196, n. 1, p. 93–101, 22 jan. 2010.

FUSCO, G. et al. **Short-term traffic predictions on large urban traffic networks: Applications of network-based machine learning models and dynamic traffic assignment models**. 2015 International Conference on Models and Technologies for Intelligent Transportation Systems, MT-ITS 2015. **Anais...**2015

FUSCO, G.; COLOMBARONI, C.; ISAENKO, N. Short-term speed predictions exploiting big data on large urban road networks. **Transportation Research Part C: Emerging Technologies**, v. 73, 2016.

GANG, C.; SHOUHUI, W.; XIAOBO, X. **Review of spatio-temporal models for short-term traffic forecasting**. 2016 IEEE International Conference on Intelligent Transportation Engineering (ICITE). **Anais...**IEEE, ago. 2016Disponível em: <<http://ieeexplore.ieee.org/document/7581298/>>. Acesso em: 20 nov. 2018

GENERAL MOTORS. **OnStar | Uma tecnologia exclusiva Chevrolet**. Disponível em: <<http://www.chevrolet.com.br/onstar.html>>. Acesso em: 26 ago. 2017.

GENTILE, G.; MESCHINI, L. **Using dynamic assignment models for real-time traffic forecast on large urban networks**. In Proceedings of the 2nd International Conference on Models and Technologies for Intelligent Transportation Systems. **Anais...**2011

GENTILI, M.; MIRCHANDANI, P. Survey of Models to Locate Sensors to Estimate Traffic Flows. **Transportation Research Record: Journal of the Transportation Research Board**, v. 2243, n. 2243, p. 108–116, 2011.

GENTILI, M.; MIRCHANDANI, P. B. Review of optimal sensor location models for travel time estimation. **Transportation Research Part C: Emerging Technologies**, v. 90, p. 74–96, 1 maio 2018.

GIACOMO COMO. On resilient control of dynamical flow networks. **Annual Reviews in Control**, v. 43, p. 80–90, 1 jan. 2017.

GLIŠOVIĆ, N. et al. A hybrid model for forecasting the volume of passenger flows on Serbian railways. **Operational Research**, v. 16, n. 2, 2016.

GONÇALVES, E. S. **Análise de padrões operacionais da frota de ônibus de transporte público no município-pio de São Paulo e a influência de fatores climáticos em sua dinâmica**. São Paulo: Biblioteca Digital de Teses e Dissertações da Universidade de São Paulo, 13 mar. 2018.

GRUMERT, E. F.; TAPANI, A. Traffic State Estimation Using Connected Vehicles and Stationary Detectors. **Journal of Advanced Transportation**, v. 2018, p. 1–14, 10 jan. 2018.

GUO, F.; POLAK, J. W.; KRISHNAN, R. Predictor fusion for short-term traffic forecasting. **Transportation Research Part C: Emerging Technologies**, v. 92, p. 90–100, 2018.

GUO, J.; HUANG, W.; WILLIAMS, B. M. Real time traffic flow outlier detection using short-term traffic conditional variance prediction. **Transportation Research Part C: Emerging Technologies**, v. 50, p. 160–172, 1 jan. 2015.

GUPTA, M. et al. **Outlier Detection for Temporal Data**. [s.l.] Morgan & Claypool, 2014.

HABTEMICHAEL, F. G.; CETIN, M. Short-term traffic flow rate forecasting based on identifying similar traffic patterns. **Transportation Research Part C: Emerging Technologies**, v. 66, 2016.

HEILMANN, B. et al. **A data-driven approach for travel time prediction on motorway sections**. 2014 International Conference on Connected Vehicles and Expo, ICCVE 2014 - Proceedings. **Anais...2014**

HIRIOTAPPA, K. et al. A streaming algorithm for online estimation of temporal and spatial extent of delays. **Journal of Advanced Transportation**, v. 2017, 2017.

HORANONT, T. et al. **Deriving dynamic OD matrix from mobile phone CDR for transportation planning in developing country**. Asian Association on Remote Sensing, 2013 Disponível em: <<https://www.scopus.com/record/display.uri?eid=2-s2.0-84903486470&origin=resultslist&sort=plf-f&src=s&st1=cdr+od+traffic&st2=&sid=f2456b6cbf455481d1a464eba42454e3&sort=b&sdt=b&sl=29&s=TITLE-ABS-KEY%28cdr+od+traffic%29&relpos=2&citeCnt=0&searchTerm=>>>. Acesso em: 29 out. 2017

HOU, T. et al. Calibration of Traffic Flow Models under Adverse Weather and Application in Mesoscopic Network Simulation Procedures. **Transportation Research Record**, n. November 2012, p. 23, 2013.

JIANG, S. et al. **Fluctuation Similarity Modeling for Traffic Flow Time Series: A Clustering Approach**. IEEE Conference on Intelligent Transportation Systems, Proceedings, ITSC. **Anais...2015**

KARLAFTIS, M. G.; VLAHOGIANNI, E. 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.

KAWASAKI, Y. et al. Real-time simulation of dynamic traffic flow with traffic data assimilation approach. **Journal of Disaster Research**, v. 11, n. 2, 2016.

KIM, K. et al. Dynamic Vehicular Route Guidance Using Traffic Prediction Information. **Mobile Information Systems**, v. 2016, p. 1–11, 4 jul. 2016.

KON, F. **About Us | INCT | Interscity**. Disponível em: <<http://interscity.org/about/>>. Acesso em: 19 mar. 2019.

KUANG, W.; AN, S.; JIANG, H. Detecting Traffic Anomalies in Urban Areas Using Taxi GPS Data. **Mathematical Problems in Engineering**, v. 2015, p. 1–13, 2015.

KUCHARSKI, R.; KOSTIC, B.; GENTILE, G. **Real-time traffic forecasting with recent DTA methods**. 2017 5th IEEE International Conference on Models and Technologies for Intelligent Transportation Systems (MT-ITS). **Anais...IEEE**, jun. 2017Disponível em: <<http://ieeexplore.ieee.org/document/8005719/>>. Acesso em: 7 jan. 2018

LADINO, A. et al. **Travel time forecasting from clustered time series via optimal fusion strategy**. 2016 European Control Conference, ECC 2016. **Anais...2017**

LAÑA, I. et al. Road Traffic Forecasting : Recent Advances and New Challenges. **IEEE Intelligent Transportation Systems Magazine**, n. April, p. 93–109, 2018.

LAURA MUIIOZ et al. **Traffic Density Estimation with the Cell Transmission Modell**. Proceedings of the American Control Conference . **Anais...Denver: 2003**Disponível em: <<http://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=1240418>>. Acesso em: 29 out. 2017

LI, L. et al. **Traffic prediction, data compression, abnormal data detection and missing data imputation: An integrated study based on the decomposition of traffic time series**. 2014 17th IEEE International Conference on Intelligent Transportation Systems, ITSC 2014. **Anais...2014**

LI, L. et al. Trend modeling for traffic time series analysis: An integrated study. **IEEE Transactions on Intelligent Transportation Systems**, v. 16, n. 6, 2015.

LI, L.; LI, Y.; LI, Z. Efficient missing data imputing for traffic flow by considering temporal and spatial dependence. **Transportation Research Part C: Emerging Technologies**, v. 34, p. 108–120, 1 set. 2013.

LI QU et al. PPCA-Based Missing Data Imputation for Traffic Flow Volume: A Systematical Approach. **IEEE Transactions on Intelligent Transportation Systems**, v. 10, n. 3, p. 512–522, set. 2009.

LOPEZ-GARCIA, P. et al. A Hybrid Method for Short-Term Traffic Congestion Forecasting Using Genetic Algorithms and Cross Entropy. **IEEE Transactions on Intelligent Transportation Systems**, v. 17, n. 2, 2016.

LU, B.; NI, S.; WASHBURN, S. S. A support vector regression approach for investigating multianticipative driving behavior. **Mathematical Problems in Engineering**, v. 2015, 2015.

LU, Y. et al. **DynaMIT2.0: Architecture Design and Preliminary Results on Real-Time Data Fusion for Traffic Prediction and Crisis Management**. 2015 IEEE 18th International Conference on Intelligent Transportation Systems. **Anais...IEEE**, set. 2015Disponível em:

<<http://ieeexplore.ieee.org/document/7313455/>>. Acesso em: 8 maio. 2019

MACÊDO BATISTA, D. et al. **InterSCity: Addressing Future Internet Research Challenges for Smart Cities**. International Conference on Network of the future. **Anais...2016**Disponível em: <<http://interscity.org>>. Acesso em: 19 mar. 2019

MALLET, A. **Tecnologia salvando vidas | 192 SMART**. Disponível em: <<https://www.192smart.com.br/>>. Acesso em: 17 mar. 2019.

MD. SHAHADAT IQBAL et al. Development of origin–destination matrices using mobile phone call data. **Transportation Research Part C: Emerging Technologies**, v. 40, p. 63–74, 1 mar. 2014.

MEIER, J.; WEHLAN, H. **Section-wise modeling of traffic flow and its application in traffic state estimation**. ITSC 2001. 2001 IEEE Intelligent Transportation Systems. Proceedings (Cat. No.01TH8585). **Anais...Oakland: IEEE, 2001**Disponível em: <<http://ieeexplore.ieee.org/document/948697/>>. Acesso em: 5 jan. 2019

MENA-YEDRA, R.; GAVALDÀ, R.; CASAS, J. Adarules: Learning rules for real-time road-traffic prediction. **Transportation Research Procedia**, v. 27, n. 00, p. 11–18, 1 jan. 2017.

MESCHINI, L.; GENTILE, G. **Real-time traffic monitoring and forecast through OPTIMA -Optimal Path Travel Information for Mobility Actions**. Models and Technologies for Intelligent Transportation Systems, International Conference Rome. **Anais...Roma: G Fusco, 2009**Disponível em: <[https://www.researchgate.net/profile/Guido\\_Gentile/publication/265617025\\_Real-time\\_traffic\\_monitoring\\_and\\_forecast\\_through\\_OPTIMA\\_-\\_Optimal\\_Path\\_Travel\\_Information\\_for\\_Mobility\\_Actions/links/54c4b58c0cf256ed5a956234.pdf](https://www.researchgate.net/profile/Guido_Gentile/publication/265617025_Real-time_traffic_monitoring_and_forecast_through_OPTIMA_-_Optimal_Path_Travel_Information_for_Mobility_Actions/links/54c4b58c0cf256ed5a956234.pdf)>. Acesso em: 7 jan. 2018

METRÔ, C. DO M. DE S. P. **Pesquisa Origem**. [s.l.: s.n.]. Disponível em: <[http://www.metro.sp.gov.br/pesquisa-od/arquivos/2018\\_12\\_12\\_Balanco\\_OD2017\\_Instituto\\_de\\_Engenharia\\_site\\_metro.pdf](http://www.metro.sp.gov.br/pesquisa-od/arquivos/2018_12_12_Balanco_OD2017_Instituto_de_Engenharia_site_metro.pdf)>. Acesso em: 4 jan. 2019.

MIRCHANDANI, P. B.; LI, P.; ZHOU, X. **INTEGRATING MESO-AND MICRO-SIMULATION MODELS TO EVALUATE TRAFFIC MANAGEMENT STRATEGIES, YEAR 2**. Reno, Nevada: SOLARIS Consortium, 4 jul. 2017. Disponível em: <<https://rosap.ntl.bts.gov/view/dot/35675>>. Acesso em: 2 nov. 2018.

MITSAKIS, E.; SALANOVA, J. M.; GIANNOPOULOS, G. Combined dynamic traffic assignment and urban traffic control models. **Procedia - Social and Behavioral Sciences**, v. 20, p. 427–436, 1 jan. 2011.

MOAYEDI, H. Z.; MASNADI-SHIRAZI, M. A. **Arima model for network traffic prediction and anomaly detection**. Proceedings - International Symposium on Information Technology 2008, ITSIm. **Anais...2008**

MUSSONE, L. **Analysis of entering flows in the congestion pricing area C of Milan**. Conference Proceedings - 2017 17th IEEE International Conference on Environment and Electrical Engineering and 2017 1st IEEE Industrial and Commercial Power Systems Europe, EEEIC / I and CPS Europe 2017. **Anais...2017**

NATIONAL RESEARCH COUNCIL (U.S.). TRANSPORTATION RESEARCH BOARD. **Highway capacity manual**. [s.l.] Transportation Research Board, National Research Council, 2000.

NUZZOLO, A. et al. A mesoscopic transit assignment model including real-time predictive information

on crowding. **Journal of Intelligent Transportation Systems: Technology, Planning, and Operations**, v. 20, n. 4, 2016.

OH, S. et al. Short-term travel-time prediction on highway: A review on model-based approach. **KSCE Journal of Civil Engineering**, p. 1–13, 5 maio 2017.

ORTÚZAR, J. DE D.; WILLUMSEN, L. G. **Modelling transport**. [s.l.] Wiley-Blackwell, 2011.

PAN, B. et al. **Forecasting Spatiotemporal Impact of Traffic Incidents on Road Networks**. 2013 IEEE 13th International Conference on Data Mining. **Anais...IEEE**, dez. 2013Disponível em: <<http://ieeexplore.ieee.org/document/6729543/>>. Acesso em: 19 nov. 2018

PARK, E.; OH, H. **Automatic identification of spatio-temporal highway congestion patterns using historic database**. [s.l.: s.n.]. v. 330

PARK, S. et al. Experimental Analysis on control constraints for connected vehicles using Vissim. **Transportation Research Procedia**, v. 21, p. 269–280, 1 jan. 2017.

PAVLYUK, D. **Short-term Traffic Forecasting Using Multivariate Autoregressive Models**. *Procedia Engineering*. **Anais...2017**

PAVLYUK, D. Feature selection and extraction in spatiotemporal traffic forecasting: a systematic literature review. **European Transport Research Review**, v. 11, n. 1, p. 6, 24 dez. 2019.

PELL, A.; MEINGAST, A.; SCHAUER, O. Trends in Real-time Traffic Simulation. **Transportation Research Procedia**, v. 25, p. 1477–1484, 1 jan. 2017.

PORTUGAL, L. DA S. **Simulação de Tráfego: Conceitos e Técnicas de Modelagem**. [s.l.] Editora Interciência Ltda., 2005.

PTV GROUP. **PTV OPTIMA PRODUCT DESCRIPTION**. [s.l.: s.n.]. Disponível em: <[http://images.discover.ptvgroup.com/Web/PTV/%7B130ae4f4-7e19-41c1-bd1e-d8099b90ea47%7D\\_PTV\\_Optima\\_Product\\_Description\\_EN\\_2017.pdf](http://images.discover.ptvgroup.com/Web/PTV/%7B130ae4f4-7e19-41c1-bd1e-d8099b90ea47%7D_PTV_Optima_Product_Description_EN_2017.pdf)>. Acesso em: 16 set. 2017.

QIU, T. Z. et al. Estimation of Freeway Traffic Density with Loop Detector and Probe Vehicle Data. **Transportation Research Record: Journal of the Transportation Research Board**, v. 2178, p. 21–29, 2010.

R.X.ZHONG et al. Forecasting journey time distribution with consideration to abnormal traffic conditions. **Transportation Research Part C: Emerging Technologies**, v. 85, p. 292–311, 1 dez. 2017.

RAKHA, H.; GAO, Y. **CALIBRATION OF STEADY-STATE CAR-FOLLOWING MODELS USING MACROSCOPIC LOOP DETECTOR DATA FINAL REPORT**. Virginia: [s.n.]. Disponível em: <<https://pdfs.semanticscholar.org/e9ce/dca8b19cb57b88742c4212156f2837051f42.pdf>>. Acesso em: 19 abr. 2019a.

RAKHA, H.; GAO, Y. **CALIBRATION OF STEADY-STATE CAR-FOLLOWING MODELS USING MACROSCOPIC LOOP DETECTOR DATA FINAL REPORT**. Virginia: [s.n.].

RASHEED, F.; ALHAJJ, R. A Framework for Periodic Outlier Pattern Detection in Time-Series Sequences. **IEEE Transactions on Cybernetics**, v. 44, n. 5, p. 569–582, maio 2014.

SAHA, P. et al. Application of Principal Component Analysis for Outlier Detection in Heterogeneous

Traffic Data. **Procedia Computer Science**, v. 83, p. 107–114, 1 jan. 2016.

SALAMANIS, A. et al. Identifying patterns under both normal and abnormal traffic conditions for short-term traffic prediction. **Transportation Research Procedia**, v. 22, p. 665–674, 1 jan. 2017.

SANTANA, F. E. Z. **InterSCSimulator: A Scalable, Open Source, Smart City Simulator**. [s.l.] Universidade de São Paulo - USP, 2019.

SCHIMBINSCHI, F. et al. Topology-regularized universal vector autoregression for traffic forecasting in large urban areas. **Expert Systems with Applications**, v. 82, p. 301–316, 1 out. 2017.

SEO, T. et al. Traffic state estimation on highway: A comprehensive survey. **Annual Reviews in Control**, v. 43, p. 128–151, 2017a.

SEO, T. et al. Traffic state estimation on highway: A comprehensive survey. **Annual Reviews in Control**, v. 43, p. 128–151, 1 jan. 2017b.

SERNEELS, S.; VERDONCK, T. Principal component analysis for data containing outliers and missing elements. **Computational Statistics & Data Analysis**, v. 52, n. 3, p. 1712–1727, 1 jan. 2008.

SESHADRI, R. **DynaMIT 2.0: Real-Time Model System for Network Management and Emergency Response | INTELLIGENT TRANSPORTATION SYSTEMS LAB**. Disponível em: <<https://its.mit.edu/dynamit>>. Acesso em: 17 abr. 2019.

SETM, S. E. DOS T. M.; METRÔ, C. DO M. DE S. P. **Pesquisa Origem Destino 2017 - 50 anos**. São Paulo: [s.n.]. Disponível em: <[http://www.metro.sp.gov.br/pesquisa-od/arquivos/2018\\_12\\_12\\_Balanco\\_OD2017\\_Instituto\\_de\\_Engenharia\\_site\\_metro.pdf](http://www.metro.sp.gov.br/pesquisa-od/arquivos/2018_12_12_Balanco_OD2017_Instituto_de_Engenharia_site_metro.pdf)>. Acesso em: 4 jan. 2019.

SHAFIEI, S.; SABERI, M. **Simultaneous Estimation of Dynamic Origin–Destination Demand and Traffic Signal Timing**. TRB Annual Meeting . **Anais...** Washington: 2018 Disponível em: <<https://trid.trb.org/view/1495966>>. Acesso em: 2 nov. 2018

SHANG, Q. et al. A hybrid short-term traffic flow prediction model based on singular spectrum analysis and kernel extreme learning machine. **PLoS ONE**, v. 11, n. 8, 2016.

SHAO, H. et al. Demand-Driven Traffic Assignment Problem Based on Travel Time Reliability. **Transportation Research**, v. 2, n. 1985, p. 220–230, 2006.

SLOBODEN, J. et al. **Guidebook on the Utilization of Dynamic Traffic Assignment in Modeling**. [s.l.: s.n.]. Disponível em: <<https://ops.fhwa.dot.gov/publications/fhwahop13015/fhwahop13015.pdf>>. Acesso em: 14 jan. 2018.

STARTUPI. **Waze lança serviço de caronas no Brasil**. Disponível em: <<https://startupi.com.br/2018/08/waze-lanca-servico-de-caronas-no-brasil/>>. Acesso em: 12 nov. 2018.

STATHOPOULOS, A.; KARLAFTIS, M. **Temporal and Spatial Variations of Real-Time Traffic Data in Urban Areas**. [s.l.: s.n.]. Disponível em: <[www.transport.ntua.gr/map/en/mobile.html](http://www.transport.ntua.gr/map/en/mobile.html)>. Acesso em: 30 dez. 2018.

STATHOPOULOS, A.; KARLAFTIS, M. 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, 1 abr. 2003.

SUN, Y.; LENG, B.; GUAN, W. A novel wavelet-SVM short-time passenger flow prediction in Beijing subway system. **Neurocomputing**, v. 166, p. 109–121, 2015.

T. DARWISH; K. ABU BAKAR. Traffic density estimation in vehicular ad hoc networks: A review. **Ad Hoc Networks**, v. 24, p. 337–351, 1 jan. 2015.

TANG, J. et al. An Improved Fuzzy Neural Network for Traffic Speed Prediction Considering Periodic Characteristic. **IEEE Transactions on Intelligent Transportation Systems**, v. 18, n. 9, 2017.

TANISHITA, M.; VAN WEE, B. Impact of vehicle speeds and changes in mean speeds on per vehicle-kilometer traffic accident rates in Japan. **IATSS Research**, v. 41, n. 3, p. 107–112, 1 out. 2017.

TASCIKARAOGLU, A. Evaluation of spatio-temporal forecasting methods in various smart city applications. **Renewable and Sustainable Energy Reviews**, v. 82, 2018.

TELECO. **teleco.com.br**. Disponível em: <<http://www.teleco.com.br/ncelddd.asp>>. Acesso em: 11 nov. 2018.

TETTAMANTI, T.; HORVÁTH, M. T.; VARGA, I. Road traffic measurement and related data fusion methodology for traffic estimation. **Transport and Telecommunication**, v. 15, n. 4, 2014.

TOLOUEI, R.; PSARRAS, S.; PRINCE, R. Origin-Destination Trip Matrix Development: Conventional Methods versus Mobile Phone Data. **Transportation Research Procedia**, v. 26, p. 39–52, 1 jan. 2017.

TRANSPORTATION RESEARCH BOARD. **Highway Capacity Manual, Sixth Edition: A Guide for Multimodal Mobility Analysis**. 6. ed. Washington: [s.n.].

TRB. **75 Years of the Fundamental Diagram for Traffic Flow Theory - Greenshields Symposium**: Circular. Woods Hole, Massachusetts: [s.n.]. Disponível em: <[www.TRB.org](http://www.TRB.org)>. Acesso em: 19 abr. 2019a.

TRB. **75 Years of the Fundamental Diagram for Traffic Flow Theory - Greenshields Symposium**: Circular. Woods Hole, Massachusetts: [s.n.].

TSELENTIS, D. I.; VLAHOIANNI, E. I.; KARLAFTIS, M. G. Improving short-term traffic forecasts: To combine models or not to combine? **IET Intelligent Transport Systems**, v. 9, n. 2, 2015.

UOL. **Estudo prova que Waze e Google Maps, na verdade, atrapalham o trânsito - Notícias - Tecnologia**. Disponível em: <<https://tecnologia.uol.com.br/noticias/redacao/2018/03/16/estudo-prova-que-waze-e-google-maps-na-verdade-atrapalham-o-transito.htm>>. Acesso em: 29 abr. 2018.

VAN LINT, J. W. C.; HOOGENDOORN, S. P.; VAN ZUYLEN, H. J. Accurate freeway travel time prediction with state-space neural networks under missing data. **Transportation Research Part C: Emerging Technologies**, v. 13, n. 5–6, p. 347–369, 1 out. 2005.

VLAHOIANNI, E. I. **Computational intelligence and optimization for transportation big data: Challenges and opportunities**. [s.l.: s.n.]. v. 38

VLAHOIANNI, E. I.; KARLAFTIS, M. G.; GOLIAS, J. C. Short-term traffic forecasting: Where we are and where we're going. **Transportation Research Part C: Emerging Technologies**, v. 43, n. Part C, p. 3–19, 2014.

- WADDOO, S. A. et al. **Prediction of traffic density from wireless cellular data**. 2016 IEEE 19th International Conference on Intelligent Transportation Systems (ITSC). **Anais...IEEE**, nov. 2016Disponível em: <<http://ieeexplore.ieee.org/document/7795611/>>. Acesso em: 4 fev. 2018
- WANG, S. et al. A Mesoscopic Traffic Data Assimilation Framework for Vehicle Density Estimation on Urban Traffic Networks Based on Particle Filters. **Entropy**, v. 21, n. 4, p. 358, 3 abr. 2019.
- WANG, S.; MAO, G. Missing Data Estimation for Traffic Volume by Searching an Optimum Closed Cut in Urban Networks. **IEEE Transactions on Intelligent Transportation Systems**, v. 20, n. 1, p. 75–86, jan. 2019.
- WANG, Y. et al. Dynamic traffic assignment: A review of the methodological advances for environmentally sustainable road transportation applications. **Transportation Research Part B**, v. 111, p. 370–394, 2018.
- WANG, Y.; PAPAGEORGIOU, M.; MESSMER, A. RENAISSANCE – A unified macroscopic model-based approach to real-time freeway network traffic surveillance. **Transportation Research Part C: Emerging Technologies**, v. 14, n. 3, p. 190–212, 1 jun. 2006.
- WANG, Z.; QI, X.; JIANG, H. Estimating the spatiotemporal impact of traffic incidents: An integer programming approach consistent with the propagation of shockwaves. **Transportation Research Part B: Methodological**, v. 111, p. 356–369, 1 maio 2018.
- WAZE. **Waze | Usuários**. Disponível em: <<https://www.waze.com/brands/pt-BR/drivers/>>. Acesso em: 12 nov. 2018.
- WOO, S.; TAK, S.; YEO, H. Data-Driven Prediction Methodology of Origin–Destination Demand in Large Network for Real-Time Service. **Transportation Research Record: Journal of the Transportation Research Board**, v. 2567, n. 1, p. 47–56, 25 jan. 2016.
- XING, X. et al. **Traffic Flow Decomposition and Prediction Based on Robust Principal Component Analysis**. IEEE Conference on Intelligent Transportation Systems, Proceedings, ITSC. **Anais...2015**
- XIONG, Z. et al. Intelligent transportation systems for smart cities: a progress review. **Science China Information Sciences**, v. 55, n. 12, p. 2908–2914, 24 dez. 2012.
- XU, Y.; KONG, Q.-J.; LIU, Y. **Comparison of urban traffic prediction methods between UTN-based spatial model and time series models**. 2012 15th International IEEE Conference on Intelligent Transportation Systems. **Anais...Anchorage: IEEE**, set. 2012Disponível em: <<http://ieeexplore.ieee.org/document/6338652/>>. Acesso em: 6 jan. 2019
- YANG, J. et al. Grey coupled prediction model for traffic flow with panel data characteristics. **Entropy**, v. 18, n. 12, 2016.
- YAO, W.-H.; FANG, R.-X.; ZHANG, X.-D. Traffic flow forecasting based on optimized SVR with hybrid artificial fish swarm algorithm. **Dalian Ligong Daxue Xuebao/Journal of Dalian University of Technology**, v. 55, n. 6, 2015.
- ZHU, J. et al. Prediction of Urban Rail Traffic Flow Based on Multiply Wavelet-ARIMA Model. In: [s.l.] Springer, Singapore, 2018. p. 561–576.
- ZHU, S. et al. **Field Data Based Data Fusion Methodologies to Estimate Dynamic Origin-Destination Demand Matrices from Multiple Sensing and Tracking Technologies**. [s.l.: s.n.]. Disponível em:

<[https://www.purdue.edu/discoverypark/nextrans/assets/docs/109PUY2.1\\_Summary and Final Technical Report.pdf](https://www.purdue.edu/discoverypark/nextrans/assets/docs/109PUY2.1_Summary and Final Technical Report.pdf)>. Acesso em: 31 dez. 2018a.

ZHU, S. et al. Optimal Heterogeneous Sensor Deployment Strategy for Dynamic Origin–Destination Demand Estimation. **Transportation Research Record: Journal of the Transportation Research Board**, v. 2567, n. 1, p. 18–27, 25 jan. 2016b.

ZHU, S. et al. Integrating Optimal Heterogeneous Sensor Deployment and Operation Strategies for Dynamic Origin-Destination Demand Estimation. **Sensors**, v. 17, n. 8, p. 1767, 2 ago. 2017.

ZOU, Y. et al. Hybrid short-term freeway speed prediction methods based on periodic analysis. **Canadian Journal of Civil Engineering**, v. 42, n. 8, 2015.

Anexo A – Ocorrências registradas pela CET no segundo semestre de 2018

Tabela A.1 – Quantidade de Ocorrências por tipo com destaque “em negrito” para as ocorrências mantidas no estudo (1/5)

		OCORRÊNCIA			QUANTIDADES						% por Tipo
Tipo de Ocorrência	CÓDIGO	DESCRIÇÃO	jul	ago	set	out	nov	dez	Total		
Incidentes	<b>201</b>	<b>PEDESTRES OCUPANDO A VIA</b>	<b>53</b>	<b>60</b>	<b>56</b>	<b>60</b>	<b>47</b>	<b>48</b>	<b>324</b>	<b>0,20%</b>	
	<b>202</b>	<b>ENTRELAÇAMENTO VEICULAR</b>	<b>59</b>	<b>121</b>	<b>70</b>	<b>82</b>	<b>117</b>	<b>109</b>	<b>558</b>	<b>0,40%</b>	
	<b>204</b>	<b>VEÍCULO ABANDONADO</b>	<b>793</b>	<b>743</b>	<b>702</b>	<b>755</b>	<b>899</b>	<b>715</b>	<b>4607</b>	<b>3,40%</b>	
	<b>205</b>	<b>AUTO MOTO OU UTILITÁRIO IMOBILIZADO NA VIA</b>	<b>4419</b>	<b>5133</b>	<b>4852</b>	<b>5256</b>	<b>4879</b>	<b>5460</b>	<b>29999</b>	<b>22,10%</b>	
	<b>206</b>	<b>ÔNIBUS IMOBILIZADO NA VIA</b>	<b>744</b>	<b>976</b>	<b>945</b>	<b>1043</b>	<b>998</b>	<b>911</b>	<b>5617</b>	<b>4,10%</b>	
	<b>207</b>	<b>CAMINHÃO IMOBILIZADO NA VIA</b>	<b>1561</b>	<b>1905</b>	<b>1693</b>	<b>1789</b>	<b>1771</b>	<b>1917</b>	<b>10636</b>	<b>7,80%</b>	
	<b>208</b>	<b>VEÍCULO COM EXCESSO</b>	<b>65</b>	<b>78</b>	<b>65</b>	<b>83</b>	<b>90</b>	<b>95</b>	<b>476</b>	<b>0,40%</b>	
	209	CONDIÇÕES DE TRÂNSITO	907	1600	1208	1426	1637	1296	8074	5,90%	
	210	CHAPA DE AÇO SOLTA	25	27	16	31	44	51	194	0,10%	
	211	CAIXA COLETORA DE ÁGUAS PLUVIAIS COM PROBLEMAS	143	111	172	241	294	307	1268	0,90%	
	212	RADAR FIXO DANIFICADO	12	7	7	7	10	8	51	0,00%	
	213	LOMBADA ELETRÔNICA DANIFICADA	14	23	17	10	13	41	118	0,10%	
	215	ILUMINAÇÃO PÚBLICA APAGADA	307	268	237	281	216	258	1567	1,20%	
	216	LOMBADA CLANDESTINA		1				1	2	0,00%	
		<b>217</b>	<b>OCORRÊNCIA ESPECIAL PROGRAMADA SERVIÇOS</b>	<b>2549</b>	<b>2442</b>	<b>2238</b>	<b>2379</b>	<b>1838</b>	<b>2090</b>	<b>13536</b>	<b>10,00%</b>
		<b>218</b>	<b>OBRAS</b>	<b>794</b>	<b>729</b>	<b>707</b>	<b>740</b>	<b>745</b>	<b>791</b>	<b>4506</b>	<b>3,30%</b>
		219	SOLAPAMENTO	288	370	366	673	716	803	3216	2,40%
		220	BURACO NA VIA	1978	2686	2892	5312	6363	6714	25945	19,10%
	222	PV COM PROBLEMA	745	751	634	977	1111	1133	5351	3,90%	
	223	CAPA ASFÁLTICA COM PROBLEMA	99	112	76	81	134	121	623	0,50%	
	<b>224</b>	<b>VIA ESCORREGADIA</b>	<b>301</b>	<b>295</b>	<b>238</b>	<b>263</b>	<b>232</b>	<b>323</b>	<b>1652</b>	<b>1,20%</b>	
	225	BUEIRO COM PROBLEMA	323	404	471	577	585	555	2915	2,10%	
	226	CAIXA DE INSPEÇÃO DANIFICADA	51	71	82	97	95	87	483	0,40%	



227	MOBILIÁRIO URBANO DANIFICADO	89	100	94	109	171	159	722	0,50%
<b>228</b>	<b>ENTULHO OBJETO MATERIAL DE SINALIZ NA VIA</b>	<b>817</b>	<b>731</b>	<b>799</b>	<b>930</b>	<b>1140</b>	<b>1135</b>	<b>5552</b>	<b>4,10%</b>
<b>229</b>	<b>CAÇAMBA DE ENTULHO</b>	<b>131</b>	<b>168</b>	<b>162</b>	<b>158</b>	<b>157</b>	<b>143</b>	<b>919</b>	<b>0,70%</b>
<b>230</b>	<b>ÁRVORE INTERFERINDO NA VIA SINALIZAÇÃO</b>	<b>215</b>	<b>183</b>	<b>189</b>	<b>274</b>	<b>297</b>	<b>267</b>	<b>1425</b>	<b>1,00%</b>
233	VAZAMENTO NA VIA	199	187	162	214	185	201	1148	0,80%
234	ANIMAL INTERFERINDO NA VIA FLUIDEZ	33	27	34	40	30	44	208	0,20%
235	TRAVESSIA DE PEDESTRE(S) EM SITUAÇÃO DE RISCO	19	14	6	13	11	8	71	0,10%
<b>237</b>	<b>BLOQUEIO POLICIAL OUTROS ÓRGÃOS</b>	<b>147</b>	<b>115</b>	<b>145</b>	<b>102</b>	<b>127</b>	<b>79</b>	<b>715</b>	<b>0,50%</b>
247	SUJEIRA NA VIA DECORRENTE DE ALAGAMENTOS		1				3	4	0,00%
251	RESERVA IRREGULAR DE VAGA(S)	275	255	192	257	161	276	1416	1,00%
252	IRREG POSTOS DE VENDA TALÕES ZA	1	2				2	5	0,00%
253	MONITORAMENTO PORTARIAS E DECRETOS		1					1	0,00%
255	CONCENTRAÇÃO PÚBLICA EVENTO	328	263	397	324	236	323	1871	1,40%
<b>Sub-Total</b>		<b>18484</b>	<b>20960</b>	<b>19924</b>	<b>24584</b>	<b>25349</b>	<b>26474</b>	<b>135775</b>	

Fonte: Próprio autor com base nos dados fornecidos pela CET

Tabela A.1 – Quantidade de Ocorrências por tipo com destaque “em negrito” para as ocorrências mantidas no estudo (3/5)

OCORRÊNCIA		QUANTIDADES							% por Tipo	
Tipo de Ocorrência	CÓDIGO	DESCRIÇÃO	jul	ago	set	out	nov	dez		Total
Emergências	<b>301</b>	<b>ACIDENTE COM AERONAVE</b>	<b>2</b>	<b>4</b>			<b>8</b>	<b>3</b>	<b>17</b>	<b>0,10%</b>
	<b>302</b>	<b>ACIDENTE DE TRÂNSITO COM VÍTIMA</b>	<b>973</b>	<b>1059</b>	<b>943</b>	<b>1051</b>	<b>921</b>	<b>973</b>	<b>5920</b>	<b>23,40%</b>
	<b>303</b>	<b>ACIDENTE DE TRÂNSITO SEM VÍTIMA</b>	<b>1357</b>	<b>1585</b>	<b>1462</b>	<b>1509</b>	<b>1397</b>	<b>1588</b>	<b>8898</b>	<b>35,20%</b>
	<b>304</b>	<b>ATROPELAMENTO</b>	<b>171</b>	<b>163</b>	<b>161</b>	<b>202</b>	<b>170</b>	<b>189</b>	<b>1056</b>	<b>4,20%</b>
	<b>305</b>	<b>MUNÍCIPE COM MAL SÚBITO OU FERIDO</b>	<b>81</b>	<b>113</b>	<b>112</b>	<b>114</b>	<b>88</b>	<b>76</b>	<b>584</b>	<b>2,30%</b>
	306	INFORMAÇÃO PARA RECOLHA DE PESSOA EM SITUAÇÃO DE RUA	5	10	3	7	3	1	29	0,10%
	<b>308</b>	<b>ACIDENTE ENVOLVENDO VEÍCULO COM EXCESSO</b>	<b>6</b>	<b>8</b>	<b>10</b>	<b>4</b>	<b>8</b>	<b>10</b>	<b>46</b>	<b>0,20%</b>
	<b>310</b>	<b>INCÊNDIO EM VEÍCULO</b>	<b>19</b>	<b>38</b>	<b>43</b>	<b>36</b>	<b>40</b>	<b>40</b>	<b>216</b>	<b>0,90%</b>
	<b>311</b>	<b>OCORRÊNCIA ENVOLVENDO CARGA</b>	<b>28</b>	<b>26</b>	<b>26</b>	<b>20</b>	<b>22</b>	<b>18</b>	<b>140</b>	<b>0,60%</b>
	<b>312</b>	<b>OCORRÊNCIA ENVOLVENDO PRODUTO PERIGOSO</b>		<b>1</b>	<b>1</b>	<b>8</b>	<b>1</b>	<b>1</b>	<b>12</b>	<b>0,00%</b>
	313	MUNÍCIPE ALTERADO	18	13	6	14	15	12	78	0,30%
	314	DESINTELIGÊNCIA	27	23	19	19	11	11	110	0,40%
	<b>316</b>	<b>INCÊNDIO</b>	<b>79</b>	<b>42</b>	<b>62</b>	<b>22</b>	<b>65</b>	<b>60</b>	<b>330</b>	<b>1,30%</b>
	<b>317</b>	<b>ALAGAMENTO</b>	<b>31</b>	<b>8</b>	<b>84</b>	<b>68</b>	<b>82</b>	<b>133</b>	<b>406</b>	<b>1,60%</b>
	<b>318</b>	<b>OCORRÊNCIA COM OBRA DE ARTE CIVIL</b>	<b>8</b>	<b>10</b>	<b>9</b>	<b>1</b>	<b>24</b>	<b>13</b>	<b>65</b>	<b>0,30%</b>
	<b>319</b>	<b>DESMORONAMENTO DESLIZAMENTO</b>	<b>9</b>	<b>17</b>	<b>22</b>	<b>16</b>	<b>18</b>	<b>43</b>	<b>125</b>	<b>0,50%</b>
	<b>321</b>	<b>MANIFESTAÇÃO</b>	<b>76</b>	<b>151</b>	<b>74</b>	<b>135</b>	<b>46</b>	<b>64</b>	<b>546</b>	<b>2,20%</b>
	<b>325</b>	<b>ROMPIMENTO ADUTORA</b>	<b>12</b>	<b>7</b>	<b>7</b>	<b>7</b>	<b>2</b>	<b>9</b>	<b>44</b>	<b>0,20%</b>
	<b>331</b>	<b>QUEDA DE ÁRVORE</b>	<b>57</b>	<b>85</b>	<b>136</b>	<b>296</b>	<b>777</b>	<b>260</b>	<b>1611</b>	<b>6,40%</b>
	<b>334</b>	<b>REDE TRÓLEBUS COM PROBLEMAS</b>	<b>35</b>	<b>26</b>	<b>25</b>	<b>19</b>	<b>20</b>	<b>32</b>	<b>157</b>	<b>0,60%</b>
335	FIAÇÃO TRANSFORMADOR COM PROBLEMAS	251	315	297	290	422	368	1943	7,70%	
<b>337</b>	<b>OCORRÊNCIA POLICIAL</b>	<b>162</b>	<b>142</b>	<b>178</b>	<b>160</b>	<b>185</b>	<b>156</b>	<b>983</b>	<b>3,90%</b>	
348	SINALIZAÇÃO COM PROBLEMAS (HV)	268	311	342	320	374	318	1933	7,70%	
<b>Sub-Total</b>			<b>3675</b>	<b>4157</b>	<b>4022</b>	<b>4318</b>	<b>4699</b>	<b>4378</b>	<b>25249</b>	

Tabela A.1 – Quantidade de Ocorrências por tipo com destaque “em negrito” para as ocorrências mantidas no estudo (4/5)

OCORRÊNCIA			QUANTIDADES							% por Tipo
Tipo de Ocorrência	CÓDIGO	DESCRIÇÃO	jul	ago	set	out	nov	dez	Total	
<b>Falhas Semafóricas</b>	503	TRAVESSIA ILUMINADA COM PROBLEMA	305	327	243	343	277	159	1654	2,70%
	504	PLACA LOS ANGELES COM PROBLEMA	2	6	8	4	11	6	37	0,10%
	505	PROBLEMA NA PROGRAMAÇÃO SEMAFÓRICA	56	81	41	50	57	49	334	0,50%
	509	CÂMERA COM PROBLEMA	5	6	7	5	6	5	34	0,10%
	510	PMV COM PROBLEMA	5	16	10	29	30	35	125	0,20%
	517	RELÓGIO COM PROBLEMA	19	18	22	53	44	19	175	0,30%
	554	LAÇO DETECTOR COM PROBLEMA	4	2	1		1	2	10	0,00%
	<b>561</b>	<b>SEMÁFORO APAGADO</b>	<b>2952</b>	<b>2840</b>	<b>2728</b>	<b>2952</b>	<b>3514</b>	<b>3404</b>	<b>18390</b>	<b>30,00%</b>
	562	SEMÁFORO EMBANDEIRADO	82	95	86	98	90	99	550	0,90%
	<b>563</b>	<b>SEMÁFORO ESTACIONADO</b>	<b>363</b>	<b>392</b>	<b>389</b>	<b>336</b>	<b>338</b>	<b>292</b>	<b>2110</b>	<b>3,40%</b>
	564	SEMÁFORO CONFLITANTE	73	65	76	76	99	72	461	0,80%
	<b>565</b>	<b>SEMÁFORO EM AMARELO INTERMITENTE</b>	<b>2587</b>	<b>2614</b>	<b>2795</b>	<b>2904</b>	<b>3067</b>	<b>3239</b>	<b>17206</b>	<b>28,10%</b>
	567	SEMÁFORO COM FASE INVERTIDA	4	5	11	14	14	6	54	0,10%
	568	FIAÇÃO SEMAFÓRICA COM PROBLEMA	13	9	17	11	14	7	71	0,10%
	569	SEMÁFORO COM FASE APAGADA	276	195	159	216	234	239	1319	2,20%
	570	PISCANTE DE ALERTA APAGADO	79	83	90	107	60	102	521	0,90%
	571	COLUNA SEMAFORICA COM PROBLEMA	153	257	355	401	1122	595	2883	4,70%
	572	CONTROLADOR COM PROBLEMA	120	134	155	146	178	132	865	1,40%
	576	REDE SEM SINCRONISMO	168	218	182	196	275	207	1246	2,00%
	577	GRUPO FOCAL COM PROBLEMA	545	957	911	987	1480	995	5875	9,60%
578	BOTOEIRA COM PROBLEMA	306	495	283	362	293	226	1965	3,20%	
585	LÂMPADA SEMAFÓRICA QUEIMADA	822	1013	1011	733	762	768	5109	8,30%	
593	CAIXA DE INSPEÇÃO SEMAFÓRICA COM PROBLEMA	59	34	27	34	50	59	263	0,40%	
<b>Sub-Total</b>			<b>8998</b>	<b>9862</b>	<b>9607</b>	<b>10057</b>	<b>12016</b>	<b>10717</b>	<b>61257</b>	

Tabela A.1 – Quantidade de Ocorrências por tipo com destaque “em negrito” para as ocorrências mantidas no estudo (5/5)

OCORRÊNCIA			QUANTIDADES							% por Tipo
Tipo de Ocorrência	CÓDIGO	DESCRIÇÃO	jul	ago	set	out	nov	dez	Total	
<b>Fiscalização</b>  309.352  58,20%	<b>603</b>	FISCALIZAÇÃO SUPERDIMENSIONADOS	130	112	148	235	172	181	<b>978</b>	0,30%
	<b>604</b>	GUINCHAMENTO RVC	2191	4580	3783	4083	2988	3035	<b>20660</b>	6,70%
	<b>605</b>	FISCALIZAÇÃO PORTARIAS DECRETOS	43	35	36	36	57	36	<b>243</b>	0,10%
	<b>608</b>	FISCALIZAÇÃO PRODUTOS PERIGOSOS	145	129	134	215	158	189	<b>970</b>	0,30%
	<b>610</b>	INFRAÇÕES ESTACIONAMENTO PARADA	26237	33230	29801	30834	27001	26942	<b>174045</b>	56,30%
	<b>611</b>	INFRAÇÕES EM MOVIMENTO	8954	10835	10318	11466	10579	10321	<b>62473</b>	20,20%
	<b>618</b>	FISCALIZAÇÃO OBRAS	8137	8685	8466	8958	8188	7549	<b>49983</b>	16,20%
<b>Sub-Total</b>			45837	57606	52686	55827	49143	48253	<b>309352</b>	

Fonte: Próprio autor com base nos dados fornecidos pela CET

Tabela A.2 – Resumo da quantidade de ocorrências mantidas no estudo

Tipo de Ocorrência	CÓDIGO	jul	ago	set	out	nov	dez	Total	% por Tipo
<b>Incidentes</b>	Incluído	12648	13679	12861	13914	13337	14083	80522	59,3%
	Total	18484	20960	19924	24584	25349	26474	135775	
<b>Emergências</b>	Incluído	3106	3484	3354	3660	3873	3667	21144	83,7%
	Total	3675	4157	4022	4318	4699	4378	25249	
<b>Falhas</b>	Incluído	5902	5846	5912	6192	6919	6935	37706	61,6%
	Total	8998	9862	9607	10057	12016	10717	61257	
<b>Semafóricas Fiscalização</b>	Incluído	0	0	0	0	0	0	0	0,0%
	Total	45837	57606	52686	55827	49143	48253	309352	
<b>Total Geral</b>	Incluído	21656	23009	22127	23766	24129	24685	139372	26,2%
	Total	<b>76994</b>	<b>92585</b>	<b>86239</b>	<b>94786</b>	<b>91207</b>	<b>89822</b>	<b>531633</b>	

Fonte: Próprio autor com base nos dados fornecidos pela CET