



**UNIVERSIDADE FEDERAL DO CEARÁ  
CENTRO DE TECNOLOGIA  
DEPARTAMENTO DE ENGENHARIA DE TRANSPORTES  
PROGRAMA DE MESTRADO EM ENGENHARIA DE TRANSPORTES**

**JOHNY ALVES LIRA**

**AVALIAÇÃO DA QUALIDADE DA ESTIMAÇÃO DE ATRIBUTOS DE FLUXO  
VEICULAR A PARTIR DO PROCESSAMENTO DE IMAGENS**

**FORTALEZA**

**2018**

JOHNY ALVES LIRA

AVALIAÇÃO DA QUALIDADE DA ESTIMAÇÃO DE ATRIBUTOS DE FLUXO  
VEICULAR A PARTIR DO PROCESSAMENTO DE IMAGENS

Dissertação submetida ao Programa de Pós-Graduação em Engenharia de Transportes da Universidade Federal do Ceará como parte dos requisitos para a obtenção do título de Mestre em Ciências (M.Sc.) em Engenharia de Transportes. Área de concentração: Planejamento e Operação de Sistemas de Transportes

Orientador: Prof. Flávio José Craveiro Cunto, Ph.D.

FORTALEZA

2018

Dados Internacionais de Catalogação na Publicação  
Universidade Federal do Ceará  
Biblioteca Universitária

Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

---

L745a Lira, Johny Alves.  
Avaliação da qualidade da estimação de atributos de fluxo veicular a partir do processamento de imagens /  
Johny Alves Lira. – 2018.  
96 f. : il. color.

Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-  
Graduação em Engenharia de Transportes, Fortaleza, 2018.  
Orientação: Prof. Dr. Flávio José Craveiro Cunto.

1. Qualidade de rastreamento veicular. 2. Trajetórias veiculares. 3. Processamento de imagens. I. Título.  
CDD 388

---

JOHNY ALVES LIRA

AVALIAÇÃO DA QUALIDADE DA ESTIMAÇÃO DE ATRIBUTOS DE FLUXO  
VEICULAR A PARTIR DO PROCESSAMENTO DE IMAGENS

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Transportes da Universidade Federal do Ceará, como requisito parcial à obtenção do título de Mestre em Ciências (M.Sc.) em Engenharia de Transportes. Área de concentração: Planejamento e Operação de Sistemas de Transportes

Aprovada em: 28/06/2018

BANCA EXAMINADORA

---

Prof. Dr. Flávio José Craveiro Cunto (Orientador)  
Universidade Federal do Ceará (UFC)

---

Prof. Dr. Francisco Moraes de Oliveira Neto  
Universidade Federal do Ceará (UFC)

---

Prof. Dr. André Luiz Barbosa Nunes da Cunha  
Universidade de São Paulo (USP)

A Deus.

Aos meus pais, Francisco Océlio Lira e Maria

Lêda Alves Lira

## **AGRADECIMENTOS**

Ao Prof. Dr. Flávio José Craveiro Cunto, pela orientação.

À FUNCAP, pelo apoio financeiro com a manutenção da bolsa de auxílio.

Aos colegas da turma de mestrado, pelas reflexões, críticas e sugestões recebidas.

Ao Matheus Lima e ao Lucas Frota, pela grande ajuda na execução do trabalho.

Ao Lucas Sousa, pelo apoio.

À minha esposa Yngrid Lira, pelas considerações que me animavam.

À Deus, por me dar paciência.

## RESUMO

O crescente aumento da frota veicular e dos congestionamentos de veículos e acidentes de trânsito gera necessidade de melhores mecanismos de gerenciamento de tráfego. A possibilidade de análise da trajetória dos veículos em larga escala com maior autonomia é bastante útil para a gestão do tráfego, podendo subsidiar decisões que envolvem o custo gerado pela perda de tempo dos usuários ou pelo dinheiro gasto com vítimas de acidentes. O método da extração de trajetórias veiculares pode conter erros provenientes do ajuste de parâmetros do algoritmo de extração ou dos modelos nele empregados. A avaliação de sua qualidade é importante na medida em que os indicadores de tráfego são gerados a partir dos dados exportados pelo algoritmo. A estimativa de precisão dos indicadores calculados a partir das trajetórias exportadas permite informar a confiabilidade em que se pode ter nas estimativas dos indicadores. Este trabalho objetiva avaliar a qualidade da extração de trajetórias veiculares através do processamento de imagens. Para isso, um algoritmo de rastreamento veicular foi consolidado e ajustado com base em filmagens do microssimulador VISSIM, de modo a avaliar a qualidade do rastreamento através de indicadores de erros exportados por estes. Foram gerados doze cenários para diferentes alturas da câmera, regime de operação de tráfego e fluxo veicular. Foram obtidas informações de posição e tempo de cada veículo a partir dos resultados do algoritmo e da microssimulação no VISSIM pelos quais, visualmente, apresentaram uma boa sobreposição. O modelo de agrupamento para *feature based* que utiliza um sistema de memorização se mostrou eficiente para lidar com regime de fluxo interrompido. Os resultados desta pesquisa apresentaram médias das diferenças entre -0,70m e 0,67m para as estimativas de coordenada, entre -0,85m e 0,11m para o comprimento veicular, entre -3,4% e 5,44% para as de contagem veiculares e abaixo de 0,95km/h e 1,10km/h para velocidades média e instantânea, respectivamente. Foi observado que as velocidades médias da corrente estimada pelo algoritmo e pelo VISSIM foram muito próximas, que o padrão dos erros médios de velocidade diminuiu com o aumento da altura da câmera e que a utilização do VISSIM permitiu uma boa avaliação da qualidade do rastreamento. Excluindo-se as interferências externas, como variação de luminosidade, balanço de câmera, obstáculos e mudança de clima, foi possível avaliar os erros de indicadores de tráfego isoladamente, nos informando a origem e o tamanho dos erros.

**Palavras-chave:** Qualidade de rastreamento. Trajetórias veiculares. Processamento de imagens.

## ABSTRACT

The increasing increase of the vehicular fleet and of the congestion of vehicles and traffic accidents generates need of better mechanisms of traffic management. The possibility of analyzing the trajectory of large-scale vehicles with greater autonomy is very useful for traffic management, and can subsidize decisions that involve the cost generated by the loss of time of users or money spent with accident victims. The method of extraction of vehicular trajectories may contain errors resulting from the adjustment of parameters of the extraction algorithm or the models used in it. The evaluation of its quality is important in that the traffic indicators are generated from the data exported by the algorithm. The estimation of the precision of the indicators calculated from the exported trajectories allows to inform the reliability that can be had in the estimates of the indicators. This work aims to evaluate the quality of vehicle trajectory extraction through image processing. For this, a vehicle tracking algorithm was consolidated and adjusted based on VISSIM microsimulator footage, in order to evaluate the quality of the tracing through error indicators exported by these. Twelve scenarios were generated for different camera heights, traffic operation regime and vehicular flow. Position and time information of each vehicle were obtained from the results of the algorithm and microsimulation in the VISSIM by which, visually, they presented a good overlap. The clustering model for feature based using a storage system proved to be efficient in dealing with interrupted flow regime. The results of this research presented a mean of the differences between -0.70 m and 0.67 m for the coordinate estimates, between -0.85 m and 0.11 m for the vehicular length, between -3.4% and 5.44% for the vehicle counts and below 0.95km / h and 1.10km / h for medium and instantaneous speeds, respectively. It was observed that the average velocities of the current estimated by the algorithm and by VISSIM were very close, that the standard of the average speed errors decreased with the increase of the height of the camera and that the use of VISSIM allowed a good evaluation of the quality of the tracking. Excluding external interferences, such as variation of luminosity, camera balance, obstacles and climate change, it was possible to evaluate traffic indicator errors alone, informing us of the origin and size of the errors.

**Keywords:** Quality of tracking. Vehicular trajectories. Images processing.

## LISTA DE FIGURAS

Figura 1 - Exemplos de resultados de rastreamento veicular .....	22
Figura 2 - Rastreamento de um veículo baseado em contornos .....	23
Figura 3 - Estratégia de rastreamento baseada em regiões .....	24
Figura 4 - Ilustração de uma calibração de câmera .....	27
Figura 5 - Exemplo de homografia.....	28
Figura 6 - Exemplo de subtração de imagens.....	30
Figura 7 - Uso de agrupamento por combinação de trajetórias .....	37
Figura 8 - Estratégia de rastreamento baseada em modelos.....	39
Figura 9 - Fluxograma do método de avaliação da qualidade de rastreamento veicular.....	44
Figura 10 - Diagrama do algoritmo de rastreamento de veículos .....	46
Figura 11 - Exemplo da deformação da imagem e aplicação da transformada perspectiva....	47
Figura 12 - Exemplo de background .....	48
Figura 13 - Quadro recorrente do vídeo .....	48
Figura 14 - Imagem binária .....	49
Figura 15 - Identificação de pontos bons para rastrear.....	49
Figura 16 - Rastreamento veicular a partir do agrupamento de pontos rastreados.....	51
Figura 17 - Sistema de memorização de agrupamentos em regime de tráfego interrompido ..	52
Figura 18 - Imagens representativas dos cenários geradas no VISSIM .....	57
Figura 19 - Tipos de análises comparativas empregadas entre cenários .....	60
Figura 20 - Sobreposição de diagramas espaço-tempo em uma faixa de tráfego.....	65
Figura 21 - Diferenças médias das coordenadas do VISSIM e rastreados ( $\Delta xyvt$ ).....	67
Figura 22 - Diferenças médias de comprimento veicular para cada cenário ( $\Delta lv$ ) .....	68
Figura 23 - Diferenças de velocidade média no espaço ( $\Delta usv$ ) .....	69
Figura 24 - Valores médios das diferenças entre as velocidades instantâneas ( $\Delta uvt$ ).....	69
Figura 25 - Entrada e saída de um veículo no <i>link</i> em diferentes alturas de câmera.....	70
Figura 26 - Valores médios das diferenças das coordenadas em cada regime ( $\Delta xyvt$ ).....	71
Figura 27 - Valores médios das diferenças de comprimento veicular ( $\Delta lv$ ) .....	72
Figura 28 - Diferenças de velocidade média no espaço ( $\Delta usv$ ) .....	73
Figura 29 - Valores médios das diferenças entre as velocidades instantâneas ( $\Delta uvt$ ).....	74

## **LISTA DE TABELAS**

Tabela 1 - Atributos de filmagem e de operação de tráfego de cada cenário simulado .....	45
Tabela 2 - Erros percentuais gerados em seleções de valores ótimos de parâmetros.....	55
Tabela 3 - Resultados obtidos para contagens e velocidades .....	66

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	12
1.1	Problema e questões de pesquisa .....	15
1.2	Objetivo geral .....	16
1.3	Objetivos específicos .....	16
1.4	Estrutura da dissertação .....	16
<b>2</b>	<b>EXTRAÇÃO DE TRAJETÓRIAS VEICULARES</b> .....	17
2.1	Coleta de dados de tráfego veicular .....	17
2.2	Estratégias de rastreamento veicular baseadas em processamento de imagens .....	21
2.2.1	<i>Rastreamento baseado em modelos</i> .....	21
2.2.2	<i>Rastreamento baseado em contornos ativos</i> .....	22
2.2.3	<i>Rastreamento baseado em regiões</i> .....	23
2.3	Rastreamento veicular baseado em características ( <i>feature based</i> ) .....	24
2.3.1	<i>Calibração de câmera e características de filmagem</i> .....	26
2.3.2	<i>Homografia</i> .....	27
2.3.3	<i>Subtração de imagens</i> .....	28
2.3.4	<i>Fluxo ótico, detecção e rastreamento de pontos</i> .....	31
2.3.5	<i>Agrupamento de pontos</i> .....	35
2.4	Métodos de avaliação da qualidade de rastreamento veicular .....	37
2.5	Considerações finais .....	40
<b>3</b>	<b>MÉTODO PROPOSTO</b> .....	42
3.1	Definição e Construção dos Cenários no Microsimulador .....	43
3.2	Consolidação do algoritmo de rastreamento veicular .....	45
3.2.1	<i>Transformada perspectiva</i> .....	46
3.2.2	<i>Subtração de imagens</i> .....	47
3.2.3	<i>Identificação de pontos rastreáveis</i> .....	48
3.2.4	<i>Rastreamento de pontos</i> .....	48
3.2.5	<i>Precisão dada em pixels no conjunto dos reais</i> .....	48
3.2.6	<i>Agrupamento de pontos</i> .....	49
3.2.7	<i>Cuidados com falsos positivos e falsos negativos</i> .....	51
3.3	Execução do plano de simulação, filmagens e exportação de indicadores ...	52

3.4	Análise de sensibilidade dos parâmetros do algoritmo .....	52
3.5	Aplicação do algoritmo de rastreamento veicular .....	55
3.6	Cálculo de indicadores .....	57
3.7	Análise comparativa das estimativas de atributos de fluxo veicular .....	58
3.8	Considerações .....	60
4	<b>RESULTADOS E DISCUSSÕES</b> .....	63
4.1	<b>Qualidade da estratégia de rastreamento utilizada</b> .....	63
4.1.1	<i>Comparação tipo A</i> .....	65
4.1.2	<i>Comparação tipo B</i> .....	69
5	<b>CONSIDERAÇÕES FINAIS E RECOMENDAÇÕES</b> .....	74
	<b>REFERÊNCIAS</b> .....	79
	<b>ANEXO A - QUADRO DE INDICADORES BASEADOS NO TEMPO</b> .....	85
	<b>ANEXO B - QUADRO DE INDICADORES BASEADOS EM DISTÂNCIA</b> .....	87
	<b>ANEXO C - QUADRO DE INDICADORES BASEADOS EM DESACELERAÇÃO</b> .....	88
	<b>ANEXO D - QUADRO DE RESULTADOS EXPORTADOS PELO ALGORITMO</b> .....	89
	<b>ANEXO E - PARÂMETROS DE SEGMENTAÇÃO E DETECÇÃO DE PONTOS</b> .....	90
	<b>ANEXO F - PARÂMETROS DE RASTREAMENTO E AGRUPAMENTO</b> .....	91
	<b>ANEXO G - VALORES DOS PARÂMETROS PARA OS CENÁRIOS PROPOSTOS</b> .....	92
	<b>ANEXO H - VALORES DE TESTE ADOTADOS EM CADA PARÂMETRO</b> .....	93
	<b>ANEXO I - ANÁLISE DOS ERROS OBTIDOS PELA ALTERAÇÃO DOS VALORES</b> .....	94

## 1 INTRODUÇÃO

Segundo o DENATRAN (2017), do ano de 2007 a 2017 a frota de veículos automotores passou, aproximadamente, de 29 milhões para 52 milhões, havendo um crescimento de 81% do total em 10 anos no Brasil, sendo resultado do processo de expansão urbana. A demanda por melhores sistemas de controle e monitoramento de tráfego são grandes, seja no tráfego urbano ou rural, visto que pode haver interações entre diferentes tipos de atores como pedestres, ciclistas, motociclistas e motoristas, havendo muitas interseções para facilitar o escoamento do tráfego. O sistema viário tem muitos pontos de conflitos, grande heterogeneidade do tráfego e pode haver interrupção por mecanismos de gerenciamento nas interseções.

Esforços têm sido fomentados com foco em alternativas melhores para a gestão da fluidez e da segurança do tráfego. Existem diversas estratégias de gestão empregadas como a otimização de corredores de tráfego, detecção automática de incidentes, gestão da velocidade através de limites de velocidade variáveis, fiscalização eletrônica, dentre outros (ABDEL-ATY *et al.*, 2008; ZHAO *et al.*, 2012; OSKARBSKI, 2016). A segurança viária também pode ser monitorada, bem como o mecanismo de falha de acidentes, os quais podem ser avaliados de forma proativa através da observação de interações veiculares e de indicadores espaço-temporais em que são calculados os graus de proximidade espacial e temporal. Quando há um alto risco de colisão, tal risco pode ser classificado como conflito veicular em vez de interação veicular (PERKINS; HARRIS, 1968; ARCHER, 2005).

Para a implantação de técnicas mais avançadas de coleta de dados desagregados para a gestão de tráfego, uma grande quantidade de informações detalhadas e precisas é necessária de modo a permitir que os gestores tomem melhores decisões e as monitorem através de indicadores. O cálculo da estimativa de tais indicadores de tráfego é possível ser obtido, com margem tolerável de erro, através do processamento de imagens (HOOSE, 1992).

A boa precisão espaço-temporal para a estimativa de parâmetros de fluxo de tráfego a partir do processamento de imagens se mostra necessária para a calibração de microsimuladores de tráfego e na geração de indicadores *proxy* de segurança viária (ARCHER, 2005). Tais indicadores tornam possíveis os estudos de análise do desempenho da segurança viária quando há ausência de dados confiáveis de acidentes (HAUER, 1989). A consolidação do uso de alguns indicadores *proxy* de segurança viária depende sobremaneira de sua capacidade de produzir indicadores de tráfego confiáveis em diversas condições

operacionais e atributos de aquisição de vídeo (YAGHOUBI, 2017; ISMAIL *et al.*, 2010a; ISMAIL *et al.*, 2010b).

Um das preocupações é a qualidade da detecção e rastreamento para a extração de trajetórias veiculares e conseqüentemente a estimação dos indicadores microscópicos de fluxo ou conflitos veiculares derivados dessa ferramenta. Para a estimação dos mesmos, não somente é necessária a detecção correta do veículo, mas também a precisão de sua coordenada, velocidade e comprimento em curto período de tempo (Kim *et al.*, 2003).

Apenas com boa precisão na coleta de dados de posição veicular no espaço-tempo é possível, por exemplo, obter-se conhecimento detalhado sobre o perfil de aceleração e desaceleração de motoristas de uma determinada localidade, o espaçamento entre carros e motos em ambiente de tráfego e sobre o fluxo de tráfego em abordagem microscópica. Tais informações podem ser obtidas através de análise de capturas de vídeo (XU *et al.*, 2013).

Os indicadores de tráfego com alta precisão podem ser obtidos através análise manual de imagens, onde há grande gasto de tempo para obter pequena quantidade de informações, além de estarem sujeitos a erros humanos. Há também a possibilidade de coletar dados de posição e tempo em larga escala, com autonomia e qualidade, através do uso de processamento automático de vídeos (SAUNIER *et al.*, 2010).

Com o avanço da tecnologia da computação, e mais precisamente o ramo da visão computacional, tornou-se possível a extração de trajetórias veiculares a partir de processamento de vídeo (BALLARD *et al.*, 1982). O rastreamento de movimentos começou a ser aplicado ao tráfego veicular com o surgimento dos sistemas de transporte inteligente (ITS – *Intelligent Transportation Systems*) e com o tempo houve evoluções nos métodos, técnicas e ferramentas utilizadas para fins de gerenciamento de tráfego veicular (WOOTTON *et al.*, 1995).

Em relação à análise da fluidez de tráfego, a obtenção de trajetórias veiculares pode fornecer diversos indicadores de tráfego veicular que ajudam em seu monitoramento tais como a estimação do espaçamento e *headways* veiculares, análise de ondas de choque, estimação de velocidades instantâneas e médias, fluxo de saturação, acelerações, comprimento veicular, localização da faixa, identificação de veículos líderes e seguidores e conflitos veiculares (ROESS, 2011; SUBIRATS, 2016).

Em relação à segurança viária, o uso de processamento de dados *off-line* de vídeos facilita a coleta mais precisa de conflitos de tráfego por ser feita de forma automática e permitir a coleta de uma amostra grande de conflitos veiculares. O desenvolvimento de estruturas de coleta de conflito mais sofisticadas, nas quais fazem melhor uso das informações

extraídas, fornece melhor direção sobre o nível de base de segurança e, portanto, pode incentivar a larga aplicação deste método (ISMAIL *et al.*, 2009, 2010; AUTEY *et al.*, 2012; SAYED *et al.*, 2013).

Apesar da grande utilidade, a estimação de indicadores microscópicos relacionados à fluidez do tráfego e segurança viária não é uma tarefa trivial em função do nível de detalhamento necessário para sua obtenção e do comportamento potencialmente instável do regime de fluxo (HOOSE, 1992). Quanto à aplicação em ambiente urbano, há um desafio de serem empregadas estratégias que consigam identificar os veículos mesmo quando estes estão muito próximos uns aos outros, já que algumas estratégias que reconhecem os veículos através de formatos geométricos não são apropriadas para tal (BEYMER *et al.*, 1997; SAUNIER; SAYED, 2006).

Quanto à avaliação da qualidade de indicadores espaço-temporais obtidos através do processamento de imagens, há fatores que interferem na qualidade de rastreamento de veículos e na obtenção de melhores valores usados nos modelos presentes no mesmo. A dificuldade do estudo isolado de tais fatores impacta diretamente no desconhecimento da parcela de erros proveniente de cada fator. Consequentemente isso impede uma melhor avaliação das margens de erro no cálculo de indicadores de tráfego e segurança viária. Em relação à avaliação de erros de rastreamento de forma manual, haveria dificuldades para a conferência ao nível de *subpixel* e para a utilização de uma grande amostra de dados em tempo aceitável (BEAUCHEMIN, 1995; DAVID *et al.*, 2006).

Os fatores que influenciam na qualidade das estratégias de rastreamento automático em vídeos extraídos em campo e no processo de ajuste de parâmetros do algoritmo de rastreamento incluem a variação da luminosidade de dia e à noite, variações na fixação da câmera, altura e ângulo de filmagem, qualidade da imagem, ruídos e taxa de *bits* de vídeo, limitação do clima, reflexão de luz, velocidade do veículo e presença de quaisquer objetos que impeçam a visualização de veículos (oclusões), podendo ser até mesmo outros veículos, caso o ângulo de câmera não seja ortogonal ao solo e limitações de processamento para algoritmos complexos (FARAHANI, 2017).

Em meio ao desafio de ajuste de constantes e variáveis nos modelos de identificação e rastreamento de veículos, nota-se grande flexibilidade nos modelos e, portanto, várias possibilidades diferentes de construção de um algoritmo de rastreamento veicular. A construção dos modelos e o ajuste dos parâmetros deles influenciam diretamente na qualidade do rastreamento. Há a hipótese que os ambientes de simulação, permitindo a construção de cenários de tráfego, possam ajudar a permitir um bom ajuste dos modelos e parâmetros para

melhor identificação e rastreamento veicular e uma melhor avaliação dos erros, quando comparado à forma manual.

Entre os melhores microssimuladores de tráfego veicular, se destaca o VISSIM, o qual permite a construção de cenários tornando possível, de forma controlada, variar altura de câmera, demanda veicular, perfil de velocidade e aceleração dos veículos, o regime de operação de tráfego, entre outros atributos de tráfego e de filmagem. Tais atributos podem interferir na qualidade da coleta de dados de tráfego em campo, assim o VISSIM pode ser útil para a estimação da qualidade de indicadores espaço-temporais.

No tocante à análise microscópica da segurança viária, através da coleta de conflitos veiculares em uma abordagem proativa, se faz necessário um método mais eficiente de avaliação da precisão dos indicadores espaço-temporais, tendo em vista que tal precisão pode ser usada para caracterizar os problemas que podem ocorrer num sistema de extração de trajetórias veiculares. As informações provenientes da avaliação de precisão podem ser usadas como indicadores de melhoria no sistema de rastreamento, como medidas-alvo para ajuste de valores dos modelos empregados ou na estimativa de margem de erro no cálculo de indicadores de tráfego e segurança viária.

## **1.1 Problema e questões de pesquisa**

Há uma gama de estudos que tentam aprimorar a estimação de indicadores espaço-temporais, os quais também demandam melhores métodos de avaliação da qualidade, tendo em vista a importância da precisão da coleta de dados para as decisões de gestão. Com os avanços tecnológicos em processamento de imagens e nos ambientes de simulação, surge a possibilidade da obtenção de melhores avaliações de qualidade e até mesmo incluir indicadores que se utilizem do tempo e trecho completo do percurso dos veículos com maior autonomia e qualidade. Frente ao que foi exposto, surgem os seguintes questionamentos:

- Quais as adaptações necessárias a algoritmos de rastreamento veicular baseado em características para o regime de tráfego interrompido e como um microssimulador pode ajudar em tal avaliação?
- Como avaliar a qualidade da extração de trajetórias veiculares?
- Quais os impactos dos atributos de altura de filmagem, de demanda veicular e regime de fluxo na precisão das estimativas de indicadores veiculares espaço-temporais obtidos em ambiente controlado e em larga escala?

## 1.2 Objetivo geral

O objetivo geral deste trabalho é avaliar a qualidade da estimação de atributos veiculares obtidos através de processamento de imagens.

## 1.3 Objetivos específicos

i) Propor adaptações para um algoritmo de detecção e rastreamento veicular baseado em características para o regime de tráfego interrompido que permita a estimação de forma desagregada de indicadores espaço-temporais;

ii) Propor um método de avaliação da qualidade da estimação de indicadores espaço-temporais veiculares desagregados a partir da estratégia de processamento de imagens com base em características;

iii) Avaliar a influência de alturas de filmagem, demanda e regime de fluxo veicular na qualidade da estimação de indicadores espaço-temporais veiculares desagregados;

## 1.4 Estrutura da dissertação

A estrutura desta dissertação consiste em cinco capítulos cuja sequência exprime o processo de desenvolvimento do estudo proposto. O Capítulo 1 apresentou a contextualização da problemática que serviu como motivação para este trabalho, bem como o problema, as questões de pesquisa, o objetivo geral e objetivos específicos desta pesquisa.

O Capítulo 2 tratará da revisão de literatura feita para embasamento teórico, apresentando conceitos e expondo trabalhos predecessores. Por sua vez, o Capítulo 3 apresentará o método proposto para desenvolvimento deste trabalho, apresentando detalhadamente as etapas que o integram.

A seguir, o Capítulo 4 exibirá os resultados alcançados no desenvolvimento desta pesquisa, além de trazer uma discussão acerca dos mesmos. Por fim, o Capítulo 5 trará comentários finais, as principais dificuldades enfrentadas e sugestões para a evolução e aprofundamento desta pesquisa.

## 2 EXTRAÇÃO DE TRAJETÓRIAS VEICULARES

Este capítulo divide-se em três seções para melhor apresentar a fundamentação teórica de cada aspecto envolvido no desenvolvimento deste trabalho. Inicialmente, tem-se uma discussão sobre as estratégias de rastreamento veicular baseadas em processamento de imagens. A seguir, são apresentadas em maiores detalhes a estratégia de rastreamento veicular baseada em características (*feature based*), as principais particularidades e aplicações a sistemas de transporte. Por fim, são apresentados trabalhos relativos à avaliação da qualidade de rastreamento veicular baseado em processamento de imagens.

O objetivo é proporcionar um embasamento teórico sobre os conceitos elementares voltados para análise do tráfego veicular através de processamento de imagens em ambiente urbano ou rural, bem como as particularidades dos métodos de avaliação da qualidade já utilizados.

### 2.1 Coleta de dados de tráfego veicular

Uma das principais etapas para a gestão de sistemas de transporte é a coleta de dados. Entre estes se destacam os dados macroscópicos (agregados), tais como velocidade média, fluxo de tráfego e densidade veicular, e os dados microscópicos (desagregados), tais como posição do veículo, velocidade instantânea, comprimento veicular e espaçamento entre veículos (*gap*). A coleta desses dados é obtida através de técnicas que podem se diferir em custo, qualidade, viabilidade para obtenção de grande amostra e praticidade.

Os dados de rastreamento de veículos podem ser úteis para o controle e o gerenciamento eficiente do tráfego, e podem constituir uma plataforma verificável do mundo real para comparar os resultados da simulação de tráfego. A aquisição de dados de rastreamento de veículos é dispendiosa e tecnicamente complexa, exigindo frequentemente a implantação de sistemas caros de monitoramento de tráfego. Atualmente, as técnicas “baseadas em infra-estrutura” e “não baseadas em infra-estrutura” são usadas para obter dados de tráfego em todo o mundo (GUIDO *et al.*, 2016).

As técnicas baseadas em infra-estrutura envolvem tecnologias de detecção intrusivas, como loops indutivos (COIFFMAN *et al.*, 2003), tubos pneumáticos de estrada (FEDERAL HIGHWAY ADMINISTRATION, 2007; MCGOWEN; SANDERSON, 2011), detectores magnéticos ( KWONG *et al.*, 2009; HAUI *et al.*, 2008), piezoelétrico (LI; YANG, 2006). As técnicas “não baseadas em infra-estrutura” incluem tecnologias de

detecção não intrusivas, como radar de microondas (ZWAHLEN *et al.*, 2005; HO; CHUNG, 2016), infravermelho passivo (NOORALAHYAN *et al.*, 1998; TYAGI *et al.*, 2012; HINZA; STILLA, 2006; GRABNER *et al.*, 2008), ultra-som (KIM, 1998; SONG *et al.*, 2004).

Segundo Guido *et al.*, (2016), os dados obtidos por tais tecnologias de detecção são geralmente agregados por natureza e não fornecem um registro efetivo de faixas de veículos individuais no fluxo de tráfego. Isso limita o uso desses dados na análise do comportamento de condução individual e na calibração e validação de modelos de simulação. Além disso, duas outras técnicas “não baseadas em infra-estrutura” foram aplicadas recentemente, com cada vez mais frequência para observar as condições do fluxo de tráfego: a aquisição de dados a partir de veículos e o processamento de imagens de vídeo.

O primeiro permite observar as trajetórias de veículos individuais, onde medições podem ser obtidas através de dispositivos de rastreamento a bordo, que fornecem informações em tempo real. Seus âmbitos de aplicação são o monitoramento de operações de tráfego em tempo real, a detecção de incidentes e os aplicativos de orientação de rota. Tais sistemas de coleta de dados do veículo da sonda podem ser agrupados em cinco tipos:

- Sistemas Automáticos de Identificação de Veículos (AVI), nos quais os veículos são equipados com etiquetas eletrônicas (SMALLEU *et al.*, 1996);
- Localização Automática de Veículo Baseada em Sinalização (AVL), particularmente usada por agências de trânsito, na qual os veículos sonda se comunicam com transmissores montados em estruturas de sinalização existentes (POLK; PIETRZYK, 1995);
- Navegação de Rádio Baseada em Terra, na qual os dados são coletados através de comunicação entre os veículos sonda e uma infra-estrutura de torre de rádio (VAIDYA *et al.*, 1996);
- Geolocalização celular baseada em transmissões de chamadas telefônicas celulares (SUMMER *et al.*, 1994; ASTARITA *et al.*, 2006);
- Sistema de Posicionamento Global (GPS), no qual os veículos sonda são equipados com receptores GPS (CHOI; CHUNG, 2001; YIM; CAYFORD, 2001).

Tais técnicas não permitem a obtenção de dados de tráfego macroscópicos, como volume de tráfego e densidade, se não forem acoplados a detectores estacionários para estimar as condições de tráfego. Por outro lado, o processamento de imagens de vídeo fornece um procedimento não invasivo de baixo custo para capturar operações individuais de veículos ao longo do tempo e, como tal, fornece uma ferramenta útil para obter dados observacionais para

controle de tráfego, calibração e validação de modelos de simulação de tráfego e até mesmos estudos com relação ao desempenho da segurança viária.

A área da visão computacional engloba vários ramos tais como reconhecimento de padrões geométricos (biometria, busca de rostos, íris), reconstrução de imagens e vídeo (modelagem 3D, recuperação de imagens) e rastreamento de objetos (perfil de deslocamento de objetos, verificação de rotas de objetos e contagem). O uso de câmeras de vídeo para monitoramento de tráfego veicular tornou-se comum com a chegada dos sistemas inteligentes de transportes (ITS – *Intelligent Transportation Systems*).

O processamento de imagens para obter trajetórias veiculares pode ser manual ou automático, além da possibilidade de ser feito *off-line*, quando a captura de vídeo é salva antes de ser posta em processamento no computador, ou *online*, no qual o processamento pode ser realizado em tempo real. Com a evolução das técnicas de rastreamento veicular, subárea da visão computacional, há um crescente potencial das ferramentas de interpretação de dados de tráfego veicular a partir do processamento de vídeos.

As ferramentas são capazes de reconhecer a diferença entre o que se move e o que está parado e a tomar decisões a respeito disso a partir de um conjunto de pixels, no qual é a menor unidade de informação de uma imagem e pode ser representada por um ponto dentro de uma matriz. Uma matriz de pontos é associada a cada quadro do vídeo. No caso da imagem colorida, cada ponto (pixel) tem um conjunto de 3 valores associados a ele que variam de 0 a 255 onde cada valor representa uma das cores vermelho, verde e azul. Na imagem em preto e branco só há um valor para cada pixel variando do preto (zero) ao branco (255).

As aplicações deste avanço computacional têm se tornado cada vez mais frequentes em diversas áreas de pesquisas, incluindo a área da análise de desempenho operacional da segurança viária, onde ajuda a entender o mecanismo de falha na condução dos motoristas a partir de uma perspectiva do lado de fora dos veículos, sendo rastreados as suas posições e cada instante de tempo.

O uso de processamento de imagens automático para a coleta de dados de tráfego veicular pode ser abordado a partir de várias estratégias de rastreamento veicular. Para a realização da extração de trajetórias veiculares é essencial uma pesquisa detalhada a respeito das ferramentas computacionais disponíveis, as estratégias de rastreamento, as características de filmagem que influenciam no processo, e as demais etapas que dependem do tipo de estratégia de rastreamento. O ajuste de parâmetros dos modelos empregados nas etapas de rastreamento, cálculo dos indicadores de tráfego e por fim a avaliação da qualidade de todos em todas as etapas e seu impacto nos resultados.

As estratégias de rastreamento veicular reúnem modelos matemáticos que regem as etapas do processamento como identificação, classificação e rastreamento de veículos. Os modelos matemáticos representam veículos em função de variáveis de entrada, das quais se destacam: as distâncias em *pixels* em relação aos eixos X e Y; o tempo, observado pela quantidade de quadros (*frames*) por segundo gerados na filmagem; e as cores RGB (*Red* – vermelho; *Green* – verde; *Blue* – azul) que determinam a cor de cada *pixel* (menor unidade de resolução).

Quanto ao uso do processamento de imagens na análise do desempenho da segurança viária, este não se restringe apenas à coleta de conflitos veiculares, mas também ao monitoramento automático do tráfego, caracterização do comportamento de condução, e até mesmo a sua associação ao desempenho da segurança viária, como por exemplo, é possível, através da monitoração da mudança de faixa de forma abusiva ou descontrolada, estimar a quantidade de motoristas que desrespeitam a lei dirigindo de forma perigosa, tendo comportamento de condução agressiva no trânsito.

Com a evolução da utilização de imagens em estudos de tráfego, a análise da segurança viária também começou a ser realizada por meio da coleta e caracterização de conflitos veiculares por meio do processamento de imagens (AUTEY *et al.*, 2012). Indicadores espaço-temporais foram usados para estimar potenciais cursos de colisão em termos de proximidade à colisão, seja em espaço ou tempo, e gravidade. Os locais e tipos de conflitos podem ser variados, incluindo *freeways*, rotatórias e interseções.

A análise de rastreamento por vídeo também vem sendo útil para análise preventiva da interação entre os usuários, como no relacionamento entre a travessia de pedestres, ciclistas e a passagem de veículos (Laureshyn *et al.*, 2016; Tageldin *et al.*, 2017). Com o avanço da tecnologia, a análise automática ou semiautomática vem contemplando uma abordagem proativa, em que é realizada em tempo real ou filmagens em horários específicos são realizadas para logo serem processadas (Saunier *et al.*, 2011; Laureshyn *et al.*, 2016).

A correta detecção de veículos em interseções diante de condições climáticas adversas ou câmeras de baixa resolução e o tempo de processamento das informações formam um grande desafio, pois o rastreamento veicular é feito continuamente ou ao longo de grandes intervalos de tempo (LESSARD *et al.*, 2016; ZHANG *et al.*, 2017). Daí é possível notar que há uma necessidade de métodos consolidados para a avaliação da qualidade de algoritmos de extração de trajetórias veiculares, a fim de melhorar os métodos de rastreamento. Os indicadores calculados a partir da coleta de dados devem expressar a realidade do

comportamento de condução dos motoristas com qualidade e autonomia, para não haver grandes vieses nos resultados.

## **2.2 Estratégias de rastreamento veicular baseadas em processamento de imagens**

Dentre as principais estratégias de rastreamento veicular a partir de processamento de imagens destacam-se o rastreamento baseado em modelos (*model based*) (Koller et al., 1993; Baker e Sullivan, 1992; Schlosser et al., 2003), o rastreamento baseado em contornos ativos (Koller et al., 1994; Mondal *et al.*, 2014), o rastreamento baseado em regiões (*region based*) (Zhang et al., 1993; Oh et al., 2009) e o rastreamento baseado em características (*feature based*) (Beymer *et al.*, 1997; Coiffman *et al.*, 1998; Kanhere e Birchfield, 2008). A diferença básica entre as estratégias está no método utilizado para identificar as partes veiculares ao longo da sequência de quadros (*frames*).

### **2.2.1 Rastreamento baseado em modelos**

Na estratégia baseada em modelos os veículos são identificados através de blocos pré-definidos em 2D ou 3D. Hödlmoser *et al.* (2013) apresentaram uma proposta de rastreamento e estimativa de pose de veículos em vídeos (

Figura 1). Foi abordado o problema de rastreamento de veículos como possível ordenação de poses para cada quadro e conectando poses subsequentes por explorar um modelo de movimento viável ao longo do tempo. Foi utilizado o chamado campo aleatório de Markov para garantir a escolha da pose perfeita ao longo do tempo e do veículo para seguir um movimento viável. As experiências realizadas contaram com uma grande variação de tipos de veículos, e a proposta alcançou resultados semelhantes em menos tempo computacional em comparação com outros métodos baseados em modelos.

Figura 1 - Exemplos de resultados de rastreamento veicular



Fonte: Hödlmoser *et al.* (2013)

Entre as desvantagens do uso da estratégia *model based* se destaca a apresentação de problemas para rastrear veículos que não estejam incluídos nos blocos pré-definidos em 2D ou 3D, portanto, a grande variação de modelos de veículos ou até mesmo o modo como estes se apresentam nas imagens pode prejudicar o rastreamento, não identificando o que deve ser rastreado além de elevar o tempo de processamento. Outro problema é que essa estratégia não lida bem com oclusões, pois apenas a imagem completa do veículo pode garantir um bom rastreamento.

### 2.2.2 Rastreamento baseado em contornos ativos

O rastreamento baseado em contornos ativos (Figura 2) toma o contorno do veículo como referência para os instantes seguintes. A estratégia gera uma descrição detalhada dos objetos e apresentando uma maior simplicidade computacional do que na estratégia baseado em modelos. Mondal *et al.* (2014), apresentaram um algoritmo que pode rastrear o contorno extraído da silhueta do objeto em movimento de uma determinada sequência de vídeo usando informações de vizinhança local e classificador de k-vizinhos mais próximos.

A classificação das amostras não rotuladas no quadro de destino forneceu regiões de objeto (silhueta do objeto) e de fundo (não objeto). Os pixels de transição da região sem objeto para a silhueta do objeto e vice-versa foram tratados como pixels de contorno ou de contorno do objeto. O contorno ou limite do objeto foi extraído conectando os pixels de limite e o objeto é rastreado com esse contorno no quadro de destino. Os resultados podem ser observados na Figura 2.

Figura 2 - Rastreamento de um veículo baseado em contornos



Fonte: Mondal *et al.*, (2014)

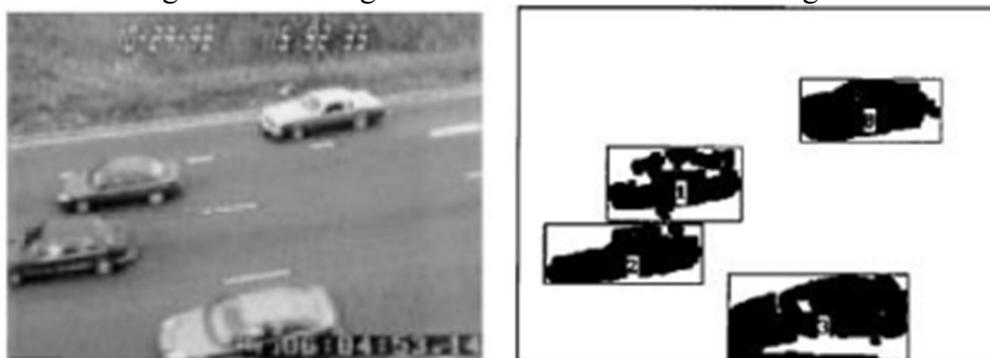
Um dos grandes problemas de tal estratégia é não conseguir lidar bem com oclusão, porque se as imagens dos veículos se interceptam no vídeo, o que ocorre dependendo do ângulo de câmera, vários veículos podem ser aglomerados como sendo um só, já que a imagem mostra seus contornos se interceptando.

### 2.2.3 Rastreamento baseado em regiões

No rastreamento veicular baseado em reconhecimento de regiões (Figura 3), os veículos são considerados áreas em movimento (*blobs*) a partir da diferença entre a tonalidade dos pixels em cada quadro do vídeo e a tonalidade dos *pixels* de um fundo previamente preparado, de forma a separar o que se move do que está parado. Um valor limite  $\alpha$  é tomado como base a fim de classificar as diferenças de tonalidade de cada *pixel*, em que estes podem pertencer ao *background* (o que está parado) ou ao *foreground* (o que se move).

A estratégia baseada em regiões identifica os *pixels* com tal diferença de intensidade similar, agrupando-os como '*blobs*' que enfim são apresentados como veículos. Essas regiões são obtidas a partir da subtração de *background*, e então rastreadas com base em suas informações, dentre as quais estão o tamanho, formato, movimento, e a posição do centroide.

Figura 3 - Estratégia de rastreamento baseada em regiões



Fonte: Gupte *et al.* (2002)

Câmara (2014) avaliou a precisão de um algoritmo de rastreamento e detecção veicular baseado em regiões quando utilizado em área urbana da cidade de Fortaleza. Foram analisados 45 vídeos classificados conforme o fluxo apresentado (alto, médio, baixo), e a análise de cada vídeo levou entre 7 e 15 minutos.

Dentre as principais limitações observadas, estão: a segmentação de veículos de maior porte, sendo essas contabilizadas repetidas vezes, e a baixa detecção de motos. Essas limitações são consequências da grande diversidade de veículos nos vídeos analisados e da utilização de um parâmetro de dimensão mínima do *blob*, nem sempre atingido pelos veículos menores (motos e bicicletas).

Um dos problemas que podem acontecer em tal estratégia é a identificação de um veículo como se fosse mais de um. Os veículos, quando representados na subtração do *background*, podem formar mais de um *blob*, o que acontece quando a diferença de intensidade entre os *pixels* do veículo e os *pixels* do asfalto é pequena, não separando muito bem o que se move do que está parado. Esse processo gera, portanto, o rastreamento de falsos positivos.

Assim como a estratégia baseada em contornos ativos, o *region based* pode não lidar bem com oclusão, porque se as imagens dos veículos se interceptam no vídeo, dependendo do ângulo de câmera, vários veículos podem ser agrupados como sendo um só, já que a imagem mostra as regiões se interceptando.

### 2.3 Rastreamento veicular baseado em características (*feature based*)

Uma abordagem substituta para rastrear abandona o plano de rastrear o veículo como um todo e, como alternativa, rastreia sub-características (*features*), como pontos discerníveis ou aparência no objeto. A vantagem disso é que, mesmo estando em oclusão parcial, algumas das características do veículo ficam perceptíveis. Além disso, o mesmo algoritmo pode ser usado para rastreamento em ambiente diurno ou noturno.

Embora a detecção e o rastreamento das características do veículo tornem a classificação mais difícil em oclusão parcial, ainda assim, o veículo terá muitas características ainda rastreáveis. Isso introduz uma nova situação na qual há uma necessidade de agrupamento de tais características. Para lidar com esse problema, usa-se critérios de agrupamento que podem classificar cada *feature* através de semelhanças, levando a determinar a que carro cada qual pertence.

A estratégia de rastreamento veicular baseada em características inclui inicialmente a etapa de subtração de background, presente também nas estratégias baseadas em regiões e em contornos ativos. Logo depois é realizada a identificação, rastreamento e agrupamento de pontos ou retas presentes nos veículos em todo o trecho do vídeo.

Na identificação de pontos, realizada com a imagem binária obtida da subtração de *background*, cada ponto de cada quadro do vídeo muda de intensidade e o padrão de mudança é modelado matematicamente. Assim, pontos que representam superfície pontiaguda são detectados e sua qualidade para tal é classificada através de modelos matemáticos. Os pontos pontiagudos podem representar os cantos (*corners*) dos veículos, que são características “marcantes” o suficiente para haver um bom rastreamento.

No rastreamento de *features*, estas são associadas, em cada quadro do vídeo, à *features* do quadro anterior, de forma a estabelecer os trajetos de cada uma delas, os quais são identificados por atribuição de Ids. O modo como elas são associadas envolve modelos matemáticos que estabelecem também se uma *feature* deixou de existir ou se reapareceu ao longo do vídeo, através do controle de distribuição de IDs.

No agrupamento de *features*, critérios são usados para estabelecer quais delas pertencem ao mesmo veículo. Entre os principais critérios se destacam a velocidade média, proximidade espacial e direção do movimento, mas também podem ser usadas técnicas estatísticas de *clustering* como HMM (*Hidden Markov Model* – Cadeias Ocultas de Markov). Por fim as informações de trajetórias veiculares e estimação de comprimento veicular e

velocidade é feita com base no conjunto de *features* agrupadas, as quais simbolizam os veículos.

Quanto à aplicação em ambiente urbano, onde os automóveis podem se situar próximos uns aos outros, as estratégias baseadas em regiões e em contorno podem agrupar veículos como sendo um só, visto que os critérios de agrupamento consideram apenas o formato do objeto (BEYMER *et al.*, 1997; SAUNIER; SAYED, 2006). A estratégia de rastreamento veicular *feature based* lida melhor com esse problema, pois os critérios para diferenciação de veículos estão em propriedades observadas em pontos ou retas localizados nos mesmo.

### **2.3.1 Calibração de câmera e características de filmagem**

No planejamento do experimento que envolve coletas de vídeo para análise de extração de trajetórias veiculares, deve ser observada a duração dos tempos de filmagem, seus respectivos horários, a quantidade de filmagens, localização da câmera envolvendo a altura e ângulo de câmera assim como observadas as restrições de filmagem que influenciam na qualidade da coleta ou o processamento dela (Hadi *et al.*, 2014). Os atributos de filmagem geralmente são escolhidos de acordo com as possibilidades técnicas de calibração de câmera e de modo a minimizar a influência dos fatores externos que possivelmente podem prejudicar a filmagem ou posteriormente o seu processamento.

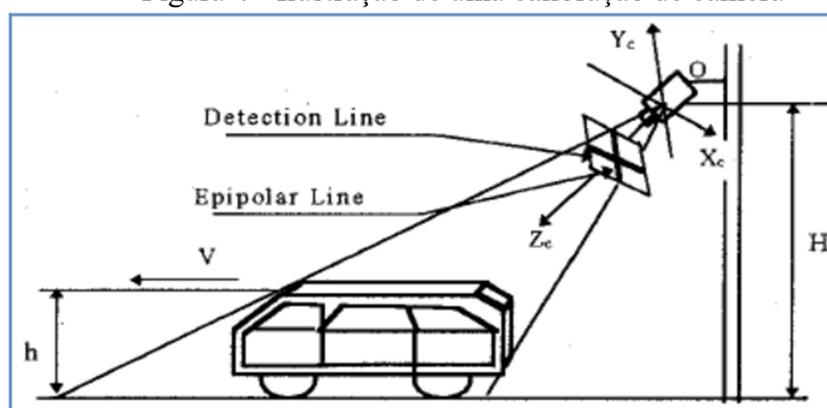
Quanto à técnica de calibração de câmera, os possíveis problemas a serem evitados são relacionados ao mau ajuste de correspondência entre as medidas reais em campo e o que pode ser processado pela filmagem, na qual envolve altura e angulação de câmera e as medições de referências de distâncias no campo e no vídeo. Em casos que a câmera não é ortogonal ao plano do solo, é necessária uma informação sobre os tamanhos dos veículos para que seja possível estimar alguns indicadores como os espaçamentos entre eles (*gap*), conforme mostra a

Figura 4 (Hadi *et al.*, 2014).

Quanto ao posicionamento de câmera é escolhido o ângulo e altura ideais e o tipo de estabilidade da câmera (se fixa ou móvel pelo uso de drones), de forma a abranger a maior região possível, capturar o espaçamento entre os veículos (Chen *et al.*, 2015). É importante notar que deve ser avaliada a relação entre ângulo de câmera e extensão de trecho filmado, pois à medida que a linha de filmagem se aproxima de ser paralela ao solo, o espaçamento

entre os veículo vai parecer cada vez menor no vídeo, sendo necessário um cálculo de correção da distância mostrada na filmagem para a distância real. Essa correção só pode ser realizada estimando-se alturas dos veículos e se a filmagem abranger o comprimento do veículo como um todo (Kanhare *et al.*, 2008).

Figura 4 - Ilustração de uma calibração de câmera



Fonte: Hadi *et al.*, (2014).

Quanto à estimação da correspondência pixels/metros deve ser tomado como referência algo na imagem e estimado o tamanho real de forma a ser possível transformar cada unidade de pixel do vídeo para um tamanho real em metros. Pode ser considerada a largura de uma faixa de tráfego para estimar o tamanho real correspondente a uma distância medida no vídeo. Essa estimação pode depender da resolução do vídeo e da distância da posição da câmera ao local filmado.

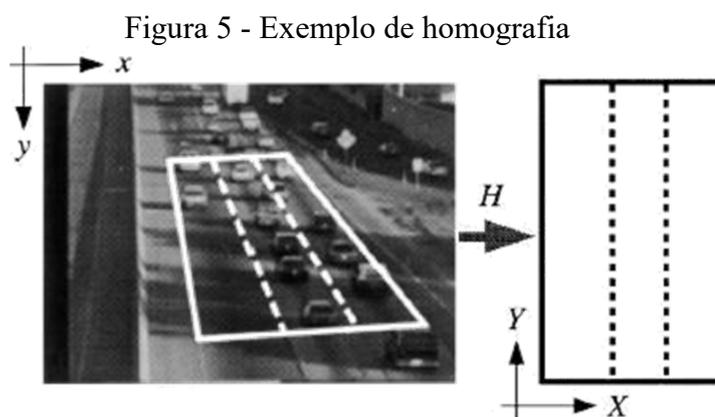
Os atributos de filmagem devem ser levados em conta, pois eles moldam o input que será posteriormente adicionado ao algoritmo e, portanto, pode alterar os resultados. Por exemplo, se for ajustado uma baixa resolução da câmera, o algoritmo poderá funcionar com maior velocidade, possibilitando um processamento mais rápido da coleta realizada. Em compensação a baixa resolução aumentará o fator de transformação dado em metros por pixel, baixando a precisão espacial dos resultados.

Em relação aos fatores externos, é necessário um bom planejamento dos locais a serem filmados e uma observância da situação climática no momento de filmagem. Sombras de objetos, reflexão da luz em direção à câmera e interferências climáticas como chuva e vento são exemplos de fatores externos que podem provocar problemas nas coletas de vídeo.

### 2.3.2 Homografia

Quaisquer duas imagens de mesma superfície planar no espaço podem ser relacionadas por uma homografia. Isso tem muitas aplicações práticas, como retificação de imagem, registro de imagem ou computação do movimento da câmera - rotação e translação - entre duas imagens. Depois que a rotação e a translação de câmera forem extraídas de uma matriz de homografia estimada, essas informações podem ser usadas para navegação ou para inserir modelos de objetos 3D em uma imagem ou vídeo, para que sejam renderizados com a perspectiva correta e pareça ter sido parte da cena original.

Em outras palavras, homografia é um processo que pode ser utilizado para correção de deformações na imagem em função do ângulo de captura de modo à ortorretificá-la. Deformações desse tipo resultam em variação no tamanho dos veículos conforme se movimentam, aumentando as dificuldades da etapa de reconhecimento do veículo assim como as estimações dos parâmetros de tráfego (Figura 5).



Fonte: Coiffman *et al.*, (1998).

Com a homografia, o plano do solo no vídeo é mapeado a fim de que seja realizada uma correspondência entre os *pixels* da imagem com as coordenadas em  $x$  e  $y$ . Quando a filmagem não faz um ângulo reto com o solo, a homografia retifica a imagem de forma a compensar a deformação em virtude do ângulo de câmera. Assim, torna-se possível que cada mínima distância em *pixels* entre dois pontos quaisquer na imagem ortorretificada corresponda a uma única distância real podendo ser dada em metros.

Existem métodos de calibração da câmera que consideram a calibração da distorção da lente, havendo maior precisão no processo. A transformada perspectiva é menos precisa que esses métodos, porém sua facilidade de uso na prática a torna mais conveniente (WORRAL *et al.*, 1994). A transformada perspectiva pode ser realizada na região de interesse

(no caso a via) para obter o mapeamento da imagem retangular definida pelo usuário. O mapeamento é feito entre pontos conhecidos no mundo real e os pontos da imagem.

### 2.3.3 Subtração de imagens

Outra etapa necessária ao rastreamento veicular é o de subtração da imagem de fundo (*background*) de cada quadro do vídeo, tendo como resultado uma imagem binária obtida pelo destacamento dos objetos que se movem (*foreground*). O *background* contém todos os elementos da via exceto os objetos que se movem (veículos que se deseja rastrear), e o *foreground* é o resultado da subtração de imagens (Intel, 2010).

Mais especificamente, a subtração de imagens é um processo que envolve a seleção de todos os pixels da imagem atual cujos valores de RGB (*Red, Green, Blue*) sejam estatisticamente diferentes dos valores de RGB do pixel correspondente no *background*, de forma a reconhecer se esse pixel é de algum objeto que se moveu. Caso seja um pixel diferente, poderá ser atribuído um determinado valor que o identifique, e caso não, pode ser atribuído outro valor que o diferencie. Há um valor limite que deve ser calibrado, no qual é estabelecido um rigor para o pixel ser considerado *background* ou *foreground*. Caso este valor limite seja mal calibrado, a imagem binária pode ter muitos ruídos provenientes da variação de luminosidade ou qualquer outro objeto na imagem que está se movendo, dificultando a identificação de veículos e a posterior extração de conflitos veiculares.

Existem algumas técnicas para subtração de imagens (ou segmentação), as quais deve incluir o uso de uma imagem fixa proveniente do vídeo para ser o *background*. Nesse caso deveria necessariamente haver um momento do vídeo que não houvesse veículos na via e isso limitaria bastante a aplicação do algoritmo em ambientes urbanos em horários de pico. Além disso, o fato do *background* ser fixo, o algoritmo não iria lidar com a mudança de luminosidade do dia para a noite, pois tudo passaria a ser *foreground*.

A utilização de *background* fixo é um processo em que cada quadro recorrente do vídeo, os valores dos pixels que formam tais imagens são subtraídos pelos valores de posição corresponde na matriz da imagem de fundo fixo e posteriormente essa diferença é comparada a um valor limite na qual é tomada uma decisão pra cada pixel separando os pixels que não pertencem ao fundo fixo caso o valor de tal diferença supere um valor limite estipulado.

O uso de fundo fixo tem vantagens e desvantagens. Como vantagens de seu uso podemos destacar o menor tempo de processamento comparado à outros métodos, a simplicidade de construção e aplicação e a possibilidade de funcionamento para tráfego

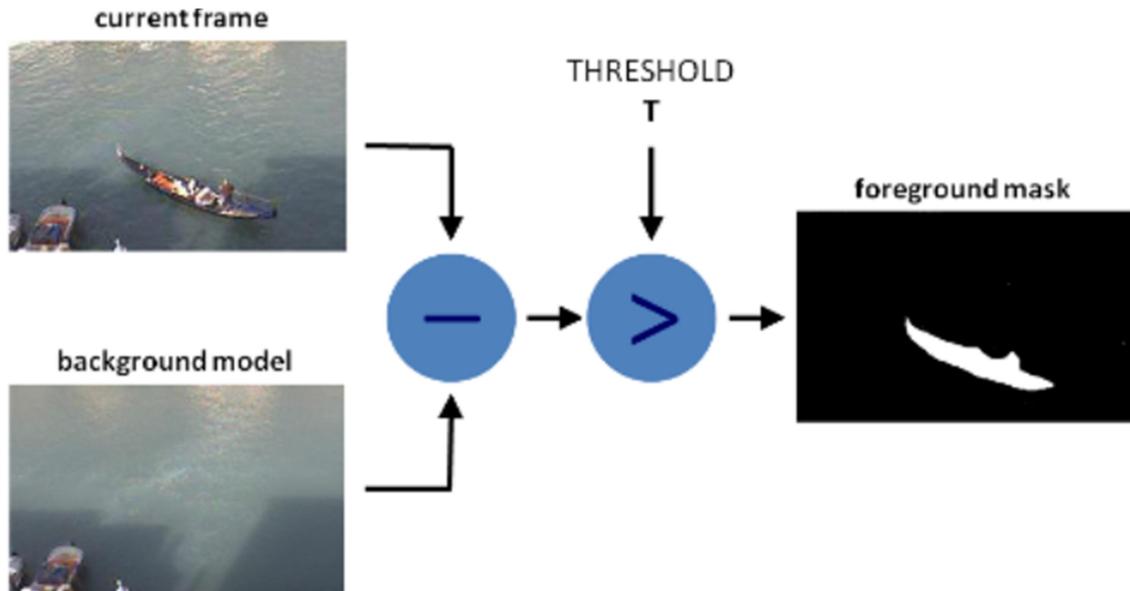
interrompido. Quanto às desvantagens de seu uso podemos destacar a necessidade de obtenção de um fundo fixo por montagem manual ou de iniciar o processamento das imagens apenas quando não haver nenhum veículo na via, além de não ser útil quando há muitas mudanças na imagem recorrente, como mudança de iluminação do dia para a noite ou balanço de câmera, por exemplo.

No processo de subtração entre *frames* consecutivos, é feita uma comparação da imagem recorrente do vídeo com a imagem imediatamente anterior a ela e a decisão de consideração de *background* ou *foreground* é feita baseada em um valor limite em que valores de subtração acima deste faz o pixel ser considerado *foreground*.

São contadas como vantagens desse método um razoável tempo de processamento comparado a outros métodos a simplicidade de construção e aplicação e reage melhor que o fundo fixo quanto à balanço de câmera. Entre as desvantagens destacam-se uma pior definição de *foreground* quando comparado a outros métodos, pois se o veículo rastreado tiver em pequena velocidade ou até mesmo parado, haverá pouca mudança do quadro de vídeo recorrente em relação ao anterior, não funcionando bem para tráfego interrompido como o de fundo fixo, visto que pode não haver nenhuma diferença entre o quadro recorrente do vídeo e o anterior quando o veículo permanecer estático.

A Figura 6 apresenta a subtração de fundo fornecida pelo OpenCV (Intel, 2010), obtida através da função *cv2.BackgroundSubtractorMOG2*, a qual implementa um modelo melhorado de mistura Gaussiana adaptada para subtração de fundo. Esta função conta com diversos atributos que permitem o controle do algoritmo, que são: *nmixtures*; *backgroundRatio*; *varThresholdGen*; *fVarInit*; *fVarMin*; *fVarMax*; *fCT*; *nShadowDetection*; *fTau*.

Figura 6 - Exemplo de subtração de imagens



Fonte: Intel, (2010).

Apesar da robustez da função `cv2.BackgroundSubtractorMOG2`, esta não funciona bem para ser usada para tráfego interrompido, porque o veículo desaparece do *background* quando está parado por um certo tempo no vídeo. Isso acontece porque a função usa o histórico de quadros para realizar a subtração de fundo.

### 2.3.4 Fluxo óptico, detecção e rastreamento de pontos

O conceito de fluxo óptico foi introduzido pelo psicólogo americano James Gibson na década de 1940 para descrever o estímulo visual fornecido aos animais que se deslocam pelo mundo (Gibson, 1950). O fluxo óptico é o padrão de movimento aparente de objetos, superfícies e bordas em uma cena visual causada pelo movimento relativo entre um observador e uma cena (Burton *et al.*, 1978; Warren *et al.*, 1985). Gibson enfatizou a importância do fluxo óptico para a percepção do *affordance*, a capacidade de discernir as possibilidades de ação dentro do meio ambiente. Os seguidores de Gibson e sua abordagem ecológica à psicologia demonstraram ainda o papel do estímulo do fluxo óptico para a percepção do movimento pelo observador no mundo; percepção da forma, distância e movimento de objetos no mundo; e o controle da locomoção (Royden *et al.*, 2012).

A aplicação do fluxo óptico inclui o problema de inferir não apenas o movimento do observador e os objetos na cena, mas também a estrutura dos objetos e do meio ambiente. Uma vez que a consciência do movimento e a geração de mapas mentais da estrutura do nosso meio ambiente são componentes fundamentais da visão animal (e humana), a conversão dessa

capacidade inata para a capacidade de um computador é igualmente crucial no campo da visão de máquina (Brown, 1987).

A estimativa de movimento e a compressão de vídeo se desenvolveram como um dos principais aspectos da pesquisa de fluxo óptico. Enquanto o campo de fluxo óptico é superficialmente semelhante a um campo de movimento denso derivado das técnicas de estimativa de movimento, o fluxo óptico é o estudo não apenas da determinação do próprio campo de fluxo óptico, mas também da sua utilização na estimativa da natureza tridimensional e estrutura da cena, bem como o movimento 3D de objetos e o observador em relação à cena, a maioria usando matriz jacobiana (Aires *et al.*, 2008).

A estimativa do fluxo óptico baseia-se em dois pressupostos: a Intensidade constante do objeto rastreado e a persistência temporal do movimento. A primeira hipótese significa que a intensidade do objeto rastreado não muda durante o movimento, enquanto a segunda suposição enfatiza que o movimento do objeto entre dois quadros sucessivos é insignificante. Supondo que estamos calculando o movimento de um objeto entre dois quadros de imagem tomados no tempo  $t$  e  $t + dt$ , e as localizações do objeto nos quadros de acordo são  $(x, y)$  e  $(x + dt, y + dt)$ .  $I$  é a intensidade do *pixel* que varia de 0 a 255 em escala de cinza. Baseado no segundo pressuposto nós podemos aplicar série de Taylor para as 3 variáveis em função da intensidade e obter a seguinte equação 1.

$$I_x V_x + I_y V_y = \nabla I^T \cdot \vec{V} = -I_t \quad (1)$$

Onde  $V_x$  e  $V_y$  são os componentes x e y da velocidade ou fluxo óptico e as derivadas de  $I$  em relação a  $x$  e  $y$  são as derivadas da imagem no ponto  $(x, y, t)$  na direção correspondente. Esta é uma equação de duas incógnitas e não pode ser resolvida como tal. Isso é conhecido como o problema de abertura dos algoritmos de fluxo óptico (*aperture problem*). Para encontrar o fluxo óptico, vetor  $(V_x, V_y)$ , é necessário outro conjunto de equações, dado por alguma restrição adicional. Todos os métodos de fluxo óptico introduzem condições adicionais para estimar o fluxo real.

Existem vários métodos para resolução do tal problema. Dentre eles se destaca o método de Lucas e Kanade, (1981). O método de Lucas-Kanade utiliza uma terceira suposição de que os pontos vizinhos em uma cena pertencem à mesma superfície, têm movimento semelhante e projetam pontos próximos no plano da imagem sendo chamada de hipótese de coerência espacial Bradski e Kaehler (2008). A partir desta condição, a equação de

fluxo óptico é aplicada para todos os pontos  $q_i$  dentro de uma janela centrada num dado ponto  $p$  e passa a existir um conjunto de equações a serem resolvidas.

A resolução de Lucas-Kanade se dá por meio do método dos mínimos quadrados, gerando o vetor velocidade na forma matricial. Etapas para a implementação do método Lucas-Kanade: recebimento do vídeo da câmera ou do arquivo, quadro a quadro; conversão dos quadros em escala de cinza; procura de bons pontos para rastrear (os pontos que têm grandes valores próprios, como cantos ou texturas) e rastreamento dos pontos encontrados em janelas (vizinhanças de *pixels*).

O algoritmo de detecção de canto Shi-Tomasi conta com um autovalor inferior mínimo aceitável e distância euclidiana mínima entre dois pontos. A solução simples de mínimos quadrados acima dá a mesma importância para todos os  $n$  pixels  $q_i$  na janela. Na prática, geralmente é melhor dar mais peso aos pixels que estão mais próximos do pixel central  $p$ . Para isso, usa-se a versão ponderada da equação de mínimos quadrados, conforme mostrado na equação 2 e equação 3.

$$v = (A^T W A)^{-1} A^T W b \quad (2)$$

$$\begin{bmatrix} V_x \\ V_y \end{bmatrix} = \begin{bmatrix} \sum_i w_i I_x(q_i)^2 & \sum_i w_i I_x(q_i) I_y(q_i) \\ \sum_i w_i I_x(q_i) I_y(q_i) & \sum_i w_i I_y(q_i)^2 \end{bmatrix}^{-1} \begin{bmatrix} -\sum_i w_i I_x(q_i) I_t(q_i) \\ -\sum_i w_i I_y(q_i) I_t(q_i) \end{bmatrix} \quad (3)$$

$W$  é uma matriz diagonal com peso a ser atribuído à equação de pixel  $q$ . O peso geralmente é uma função gaussiana da distância entre  $p$  e  $q$ . Uma das principais hipóteses para este método é que o movimento é pequeno (menos de 1 pixel entre duas imagens, por exemplo). Se o movimento é grande e viola essa suposição, uma técnica é reduzir primeiro a resolução das imagens e, em seguida, aplicar o método Lucas-Kanade (Bouguet, 2001).

Embora a diminuição da resolução do vídeo aumente a robustez de rastreamento de pontos e diminua o tempo de processamento, é importante notar que isso pode impactar bastante na qualidade da precisão de rastreamento veicular, visto que cada *pixel* iria representar um valor real maior, podendo ser dado em metros.

Segundo Bouguet, (2001), os dois componentes principais para qualquer rastreador de recursos são precisão e robustez. O componente de precisão relaciona-se com a precisão do subpixel local anexada ao rastreamento (BEAUCHEMIN, 1995). Intuitivamente, uma pequena janela de integração seria preferível para não "suavizar" os detalhes contidos nas

imagens. Isso é especialmente necessário nas áreas de oclusão nas imagens onde dois elementos podem se mover com velocidades muito diferentes.

O componente de robustez relaciona-se com a sensibilidade do rastreamento em relação às mudanças de iluminação e tamanho do movimento da imagem. Para lidar com grandes movimentos, é intuitivamente preferível escolher uma grande janela de integração, ou seja, para uma distância movida de um ponto em  $\omega$  pixels a janela de integração deve ser pelo menos  $(2\omega_x + 1, 2\omega_y + 1)$ .

Existe, portanto, uma compensação natural entre a precisão local e a robustez ao escolher o tamanho da janela de integração. Para fornecer uma solução para esse problema, Bouguet, (2001) propôs uma implementação piramidal do algoritmo clássico Lucas-Kanade. A implementação iterativa da computação de fluxo óptico Lucas-Kanade fornece uma precisão de rastreamento local suficiente, sendo útil para rastreamento de veículos para grandes velocidades, para vídeos com agregação tempo em *fps* reduzida (fotos por segundo), vídeos com resoluções mais altas ou para baixas alturas de câmera.

Para a implementação piramidal de interações, primeiro são definidos o número máximo de níveis da pirâmide onde são executadas as interações começando do nível mais alto até o nível 0 (mais baixo). O nível mais baixo da pirâmide representa a resolução do vídeo, conforme aumentam os níveis, a resolução é dividida em 4 subimagens de tamanhos iguais, depois 8, e 16 e assim por diante. Posteriormente é calculado o vetor deslocamento que minimiza o somatório dos quadrados das diferenças de intensidade de cada par de *pixel* correspondente das imagens no tempo  $t$  e  $t + I$ , ou seja, minimizar o erro de correspondência dessas pequenas imagens da pirâmide em dois quadros consecutivos.

Os resultados de  $g$  são levados para um nível mais baixo e então recalculados. Se as janelas de integração de Lucas-Kanade estiverem dentro da mesma subimagem em dois quadros consecutivos, precisa-se aumentar o nível da pirâmide para que elas passem a estar em subimagens diferentes.

Posteriormente para cada nível da pirâmide é realizado alguns passos e depois uma série de interações. Primeiro são calculadas as derivadas da intensidade dos *pixels* baseado na média dos *pixels* anterior e posterior tanto na direção  $x$  quanto na  $y$  a partir disso, é criada uma matriz gradiente espacial  $G$ .

Finalmente são feitas uma série de iterações com um número de vezes a ser calibrado e um limite de erro tolerável para o cálculo da distância do ponto rastreado nos quadros consecutivos, dada ao nível de *subpixel*. As iterações param quando o limite é chegado ou o número de iterações termina. A matriz  $G$  invertida é usada no processo sendo

multiplicada pelo vetor de “incompatibilidade de imagem” o qual é calculado com base na diferença de intensidade dos pixels das janelas de integração e suas derivadas. O resultado dessa multiplicação é a estimativa do vetor deslocamento a ser estimado. A formação da matriz  $G$  e o processo de iteração são repetidos a cada nível da pirâmide e o vetor deslocamento estimado é somado ao vetor anterior até o último nível da pirâmide.

É absolutamente essencial manter toda a computação em um nível de precisão de subpixel. Portanto, é necessário calcular os valores de brilho da imagem em locais entre pixels inteiros. Para calcular o brilho da imagem em locais de subpixel, Bouguet, (2001) propôs a utilização de interpolação bilinear.

Existem dois casos que devem dar origem a um ponto "perdido": quando o ponto está fora da imagem e quando o caminho em torno do ponto rastreado varia muito entre a imagem anterior  $I$  e a imagem posterior  $J$ , assim o ponto desaparece devido à oclusão. Esta condição é muito mais desafiadora para quantificar que a precisão. Por exemplo, um ponto pode ser declarado "perdido" se a função de custo final for maior que um valor de parâmetro. Ocorre um problema ao decidir sobre um limite. Uma excelente técnica para combinar uma abordagem de rastreamento tradicional com uma correspondência de imagem para reconhecer pontos falsos é apresentada por Shi e Tomasi (1994).

Os meios para selecionar o ponto  $u$  em  $I$  é chamado de seleção de *feature* (ponto). O passo central do rastreamento é a computação do vetor de fluxo óptico  $\eta_k$ . Naquela etapa, a matriz  $G$  deve ser reversível, ou seja, o valor próprio mínimo de  $G$  deve ser suficientemente grande (maior que um limite). Isso caracteriza pixels que são "fáceis de rastrear". Portanto, o processo de seleção é o seguinte:

1. Calcule a matriz  $G$  e seu autovalor mínimo  $\lambda_m$  em cada pixel na imagem  $I$
2. Chame de  $\lambda_{max}$  o valor máximo de  $\lambda_m$  em toda a imagem.
3. Mantenha os pixels da imagem que têm um valor  $\lambda_m$  maior do que uma porcentagem de  $\lambda_{max}$ . Esta porcentagem pode ser 10% ou 5%.
4. A partir desses pixels, mantenha os *pixels* máximos locais (um pixel é mantido se o seu valor  $\lambda_m$  for maior que o de qualquer outro pixel em sua vizinhança  $3 \times 3$ ).
5. Mantenha o subconjunto desses pixels de modo que a distância mínima entre qualquer par de pixels seja maior do que uma determinada distância limiar.

### 2.3.5 Agrupamento de pontos

O propósito da etapa de agrupamento é unir os pontos pertencentes ao mesmo veículo, dos quais em etapas anteriores estes foram detectados e rastreados. *Features* que se movem juntas e que têm propriedades semelhantes são ligadas entre si a fim de representar a trajetória de cada veículo. O método de agrupamento é composto por modelos matemáticos de resposta binária (agrupar ou não).

Existem métodos de agrupamento simples, que consideram o estado das *features* a cada quadro do vídeo, os quais consomem menos tempo de processamento e podem ser suficientes em regimes de baixo fluxo ininterrupto, e métodos os mais elaborados, que consideram o estado das *features* ao longo do tempo, consumindo mais tempo de processamento e geralmente necessário em locais com fluxo interrompido e intenso.

Um exemplo de método de agrupamento é a medição de semelhança de velocidade e posição no espaço através de valores de tolerância, a serem ajustados conforme melhor for o resultado. Ou seja, *features* com velocidades semelhantes e que se encontram próximas são agrupadas simbolizando pertencimento a um mesmo veículo. Em meio ao ajuste de valores de tolerância, podem ser observados erros de falsos positivos, onde um agrupamento acontece indevidamente, ou erros de falsos negativos, onde veículos deixam de ser agrupados. No caso das velocidades serem médias é considerado o histórico de posição das *features*.

Um dos problemas de usar a velocidade média dos veículos como critério para o agrupamento é quando se lida com o tráfego interrompido, em que a velocidade média dos veículos tende a zero. Quando isso ocorre há uma tendência de todos os veículos, quando pararem, serem agrupados como sendo apenas um, já que o algoritmo não consegue lidar com a diferenciação de pertencimento das *features*.

Entre os métodos mais robustos de agrupamento encontrados na literatura são os de combinação de trajetórias das *features*, em que o formato geométrico de tais trajetórias é aproximado por funções matemáticas envolvendo as posições X e Y e o tempo. São ajustados os coeficientes das funções a cada quadro do vídeo. Os pontos cujas funções têm coeficientes semelhantes são agrupados. Modelos de tolerância para tal “semelhança” são usados para a determinação de agrupar ou não cada par de pontos testados a cada quadro do vídeo. A formação do agrupamento pode ser feita testando-se cada trajetória par a par ou de forma mais sistematizada, onde cada trajetória de *feature* é comparada com a trajetória do centroide das *features* formado em cada quadro do vídeo.

Jung (2001) propôs um sistema de rastreamento veicular baseado em características para vigilância inteligente de tráfego. O rastreamento de *features* foi baseado

na filtragem linear de Kalman. O método de agrupamento usado foi a combinação de trajetórias com a finalidade de ser robusto o bastante para separar veículos em tráfego congestionado. O autor concluiu que o sistema teve sucesso.

Para o ajuste da função que aproximava o rastro do centroide e de cada *feature*, foi usado a equação 4. Onde ‘n’ representa a ordem, e ‘a’ são os coeficientes dos modelos. O número de coeficientes é ‘n+1’. A ordem utilizada pelo autor foi 3. Os coeficientes foram encontrados automaticamente a cada quadro do vídeo pelo método dos mínimos quadrados.

$$x(t) = a_0 + a_{x1}t + a_{x2}t^2 + \dots + a_{xn}t^n ; \quad y(t) = a_0 + a_{y1}t + a_{y2}t^2 + \dots + a_{yn}t^n \quad (4)$$

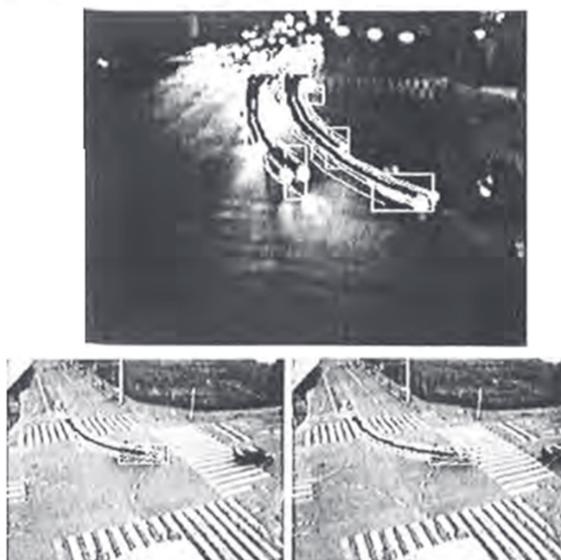
Depois de ajustados os modelos que expressam o formato geométrico das trajetórias foram geradas medidas de similaridade direcional, usadas para fins de comparação de trajetórias (equações 5 e 6). Os pesos ‘w’ servem para ajustar a importância de cada coeficiente para a medida de similaridade. Se a similaridade SM entre os coeficientes das funções de duas *features* fossem menor que um determinado valor limite estabelecido, tais *features* seriam agrupadas.

$$SM_x = w_0(a_{x0} - a'_{x0})^2 + w_1(a_{x1} - a'_{x1})^2 + w_2(a_{x2} - a'_{x2})^2 + w_3(a_{x3} - a'_{x3})^2 \quad (5)$$

$$SM_y = w_0(a_{y0} - a'_{y0})^2 + w_1(a_{y1} - a'_{y1})^2 + w_2(a_{y2} - a'_{y2})^2 + w_3(a_{y3} - a'_{y3})^2 \quad (6)$$

As avaliações de Jung (2001) foram qualitativas. Ele aplicou o algoritmo de dia e à noite como se pode ver na Figura 7. Apesar de haver relativo sucesso, não quantificado pelo autor, o mesmo citou alguns erros que aconteceram quando veículos ficavam muito próximos uns aos outros e quando ocorriam grandes oclusões.

Figura 7 - Uso de agrupamento por combinação de trajetórias



Fonte: Jung (2001)

Quanto aos testes realizados à noite, o método de agrupamento foi eficiente, apesar de apresentar erros relacionados às mudanças de luminosidade proveniente dos faróis dos veículos. O autor atribuiu alguns erros a outras fontes que não a etapa de agrupamento, apesar de não apresentar embasamento suficiente para a conclusão.

Saunier *et al.*, (2007) utilizaram HMM (*Hidden Markov Models* – Modelos de Markov Oculto) para encontrar o número de agrupamentos de pontos (*features*) em cada frame, usando uma abordagem *K-means* e uma heurística simples. Conflitos de tráfego puderam ser detectados identificando e adaptando pares de modelos de trajetórias conflitantes. Apesar do modelo de Markov lidar relativamente bem com obstáculos, reconstruindo o reconhecimento do veículo quando este passa por trás de um obstáculo, por exemplo, o método adotado tem a desvantagem de formar agrupamentos instáveis, já que o processo de agrupamento dos pontos depende do movimento das features em todos os quadros do vídeo.

## 2.4 Métodos de avaliação da qualidade de rastreamento veicular

A consolidação da visão computacional aplicada à análise operacional do tráfego depende sobremaneira de sua capacidade de produzir indicadores de tráfego confiáveis em diversas condições operacionais e atributos de aquisição de vídeo. A qualidade da utilização do algoritmo de extração das trajetórias veiculares pode influenciar, por exemplo, numa possível calibração de microssimuladores de tráfego. É importante que as estimativas geradas

sejam fiéis às que ocorrem em campo, e em especial no meio urbano onde há tráfego interrompido com uma grande diversidade de veículos e usuários do sistema.

Buch *et al.* (2009) avaliaram a qualidade do rastreamento de um algoritmo a partir de modelos 3D (Figura 8), em que a detecção e classificação dos veículos foi realizada entre os veículos e o conjunto de modelos básicos (*wire frames*). Os veículos tiveram suas trajetórias extraídas em que foram detectadas 144 trajetórias, onde 94 foram corretas. As principais falhas observadas foram a não-detecção de trajetórias ocorrendo 6 vezes, a detecção de falsas trajetórias ocorrendo 27 vezes e 10 mudanças de ID dos veículos analisados.

Figura 8 - Estratégia de rastreamento baseada em modelos



Fonte: Buch *et al.* (2009).

Beymer *et al.* (1997) verificaram a adequabilidade do *feature based* para detecção veicular e estimação de parâmetros de tráfego em tempo real. Na detecção, obtiveram taxas de acerto de aproximadamente 74% em vídeos de congestionamento pesado, 85% em imagens de interseções urbanas, 90% em vídeos noturnos, e 94% para vídeos envolvendo fluxo livre e congestionamento. Em 44 horas de vídeos analisados, foram obtidos erros de menos de 15% para fluxo, erros de 2% para velocidade e espaçamento e densidade em praticamente 80% das amostras. Percebeu-se que os erros em estimação de fluxo, densidade e espaçamento estavam associados a veículos não contados e duplas contagens. Ao fim, percebeu-se que o algoritmo teve sucesso em obter os parâmetros de tráfego através do *feature based*.

Saunier e Sayed (2006) avaliaram o *Feature-based tracking* em para interseções urbanas. Os resultados apresentaram uma média de acertos de veículos corretamente detectados de 88%. Neste estudo, as fontes de erros foram às longas distâncias que provocavam perdas de características, segmentação de veículos longos e vibração da câmera. Por outro lado, observou-se o correto rastreamento de pedestres e cadeirantes cruzando as vias.

Coifman *et al.* (1998) trabalharam em um sistema computacional em tempo real para rastreamento de veículos e vigilância de tráfego. Eles avaliaram o desempenho de uma estratégia baseada em características aplicada em um trecho de rodovia de pista dupla (*Highway*) na Califórnia. Para avaliação do desempenho foram utilizados indicadores macroscópicos de fluxo (velocidade, densidade e fluxo). Os valores considerados como referência (*ground truth*) foram obtidos a partir de laços indutivos e a área de rastreamento utilizada foi de aproximadamente 100m. Além dos indicadores acima, diagramas espaço-tempo foram estimados. Os resultados encontrados para 48 intervalos de observação de 15 minutos e indicaram erros menores que 5% para 95% das observações de velocidade, 31% das observações de fluxo e 33% das observações de densidade.

Cunha (2013) desenvolveu um algoritmo para estimar atributos de fluxo veicular para fluxo ininterrupto a partir da biblioteca de visão computacional denominada OpenCV. O algoritmo foi avaliado em um estudo de caso desenvolvido para a Rodovia SP-310 em São Carlos, São Paulo. Foram feitas comparações entre as velocidades instantâneas, fluxo e comprimento veicular. Os valores de referência para as respectivas variáveis foram estimados a partir de radares manuais (*speed gun*), contagem manual do vídeo e medições manuais de pixels no vídeo produzido. Os resultados indicaram erros abaixo de 6% em 60% das observações para a velocidade. Com relação ao fluxo veicular, os resultados apresentados pela detecção automática subestimaram a contagem real.

Guido *et al.* (2016) apresentaram uma metodologia para rastrear veículos em movimento que integra veículos aéreos não tripulados com técnicas de processamento de vídeo. Os autores investigaram a utilidade dos veículos aéreos não tripulados para capturar dados confiáveis de veículos individuais utilizando a tecnologia GPS como referência. Um algoritmo de processamento de vídeo para aquisição de trajetória de veículos é introduzido. O algoritmo é baseado em bibliotecas OpenCV. Para avaliar a precisão do algoritmo de processamento de vídeo proposto, um veículo instrumentado foi equipado com um GPS de alta precisão. As experiências de captura de vídeo foram realizadas em dois estudos de caso. Em campo, foram adquiridos cerca de 24.000 dados de posicionamento para a análise. Os erros de estimativa de velocidade foram avaliados através de GPS e a raiz quadrada dos erros médios foi de 3,96%.

Entre os três últimos estudos citados, observa-se que a qualidade dos sistemas de rastreamento foi avaliada de forma parcial, analisando apenas variáveis macroscópicas, ou velocidade instantânea e coordenadas não considerando os possíveis vieses nos erros

provenientes dos sistemas de avaliação de erros. A causa dos erros também não foi bem explorada.

O cálculo de indicadores de segurança viária, onde podem ser utilizadas informações de coordenada do para-choque dianteiro, comprimento veicular, perfis de velocidade e aceleração. Para isso, é demandado um grande rigor da qualidade da extração de trajetórias veiculares, visto que o cálculo de tais indicadores pode ser sensível o suficiente para alterar os resultados da análise. Um resumo adaptado do trabalho de Mahmud *et al.* (2016) o qual contém os indicadores proxy de segurança viária que podem ser estimados a partir do processamento de imagens estão dispostos nos anexos A, B e C.

Segundo Farahani (2017), as pesquisas recentes estão trabalhando em limitações que diminuem a precisão dos algoritmos de rastreamento veicular. Entre essas limitações, se destacam: movimentação ou fixação de câmera; calibração dinâmica de câmera; qualidade da imagem, ruídos e taxa de *bits* de vídeo; luminosidade de dia e à noite; limitação do clima; reflexão de luz; velocidade do veículo; distância de câmera; oclusões; limitações de processamento para algoritmos complexos.

## 2.5 Considerações Finais

Tendo em vista a grande evolução na tecnologia dos computadores e softwares, frente às recentes opções de ferramentas de programação de computador adequadas para a extração de informações de forma automática ou semiautomática de vídeo, percebe-se o grande potencial do uso da visão computacional na análise de trajetórias veiculares, pelas quais são calculados indicadores espaço-temporais úteis para a análise dos sistemas de transporte.

Baseado na literatura pode-se afirmar que o rastreamento semiautomático é melhor frente à abordagem de análise manual dos vídeos para extrair o fluxo de tráfego, posição, tempo, dimensões dos veículos e os IDs dos veículos líder e seguidor após retificar as imagens de vídeo pela homografia. Isso pode melhorar o tempo de coleta e análise dos dados, além de diminuir possíveis erros humanos. A precisão dos indicadores pode ser suficiente para os objetivos da análise e, portanto, torna-se conveniente o rastreamento veicular partindo do processamento automático ou semiautomático de imagens.

Para que a qualidade das filmagens seja adequada ao processamento e extração de informações, que no caso são as trajetórias veiculares, deve ser levado em conta os fatores

relacionados à calibração de câmera e ao planejamento do experimento de modo a escolher adequadamente os atributos de câmera e condições do ambiente de filmagens.

Conforme a revisão da literatura a respeito de estratégias de rastreamento veicular, a que é mais adequada para ambientes urbanos é a baseada em características, a qual lida melhor com a identificação de veículos quando se apresentam próximos uns aos outros na imagem binária.

As limitações da estratégia *feature based* se restringem à dificuldade de funcionamento na presença de obstáculos como postes de luz entre a câmera e os veículos; longas distâncias de filmagem; segmentação de veículos longos e vibração da câmera. Apesar das limitações o uso dessa estratégia de rastreamento é útil para a obtenção das trajetórias veiculares consumindo menos tempo que a análise manual, possibilitando a coleta de uma amostra maior e mais precisa.

### 3 MÉTODO PROPOSTO

No decorrer deste capítulo é apresentado o procedimento metodológico proposto para obtenção da qualidade de extração de dados desagregados de movimentos veiculares em diversos cenários de filmagem, bem como o seu impacto no cálculo de indicadores espaço-temporais. São apresentadas e discutidas também as etapas deste método, estabelecidas de acordo com os objetivos específicos e visando atingir a proposta geral da pesquisa.

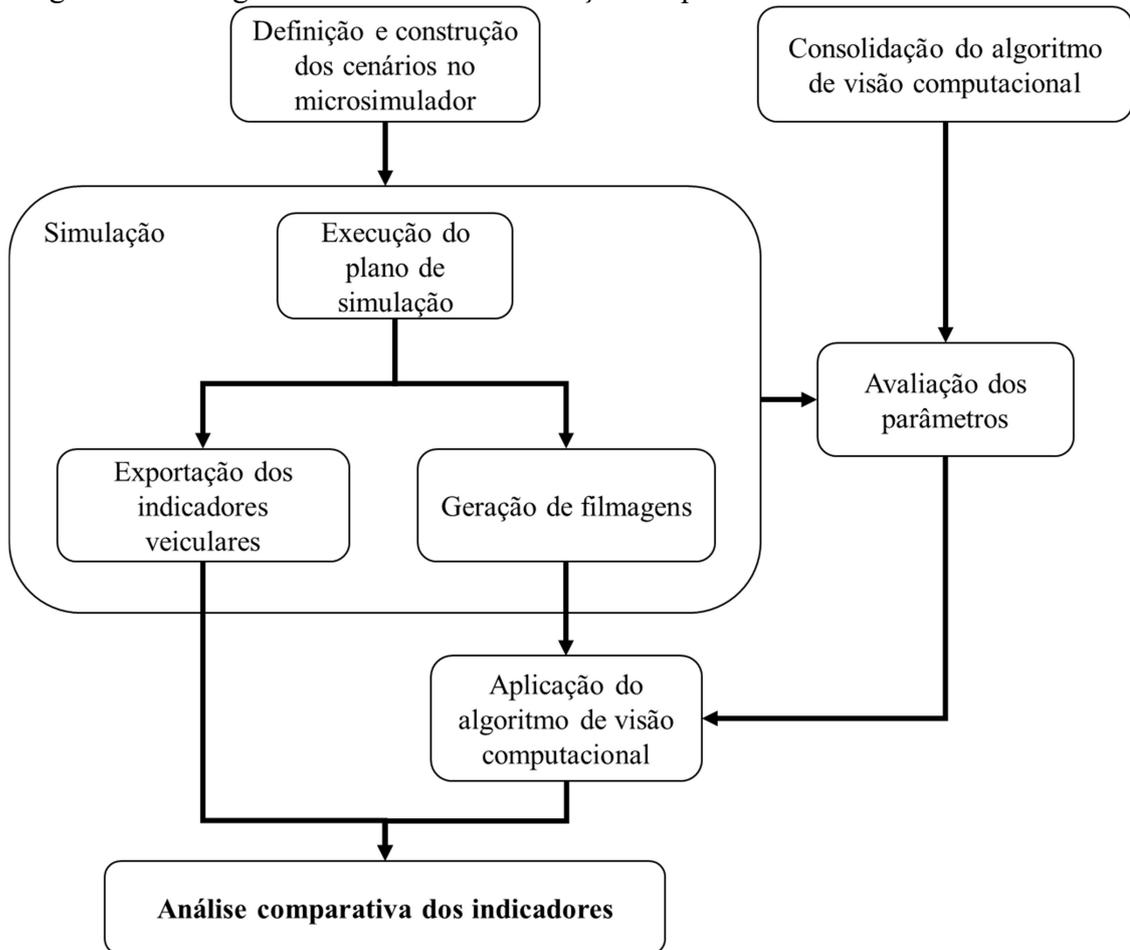
Um das preocupações é a qualidade da detecção e rastreamento para a estimação dos indicadores espaço-temporais derivados dessa ferramenta. Para a estimação de conflitos veiculares, por exemplo, não somente a detecção correta do veículo, mas também a precisão de sua coordenada e comprimento é crucial para a determinação de indicadores de tráfego.

A maioria dos pacotes computacionais de simulação microscópica como VISSIM, PARAMICS, AIMSUN, permite a representação da movimentação veicular em 2D e 3D através de filmagens em um ambiente consideravelmente controlado. Com o uso de filmagens de um microssimulador de tráfego é possível classificar melhor os diversos tipos de erros e avaliar melhor o ajuste do sistema de rastreamento.

Com isso, uma das formas de avaliar a qualidade dos modelos empregados nas etapas de um algoritmo de rastreamento veicular, seria utilizando imagens provenientes de um microssimulador, sendo possível isolar todo o efeito da variação nos erros em meio aos diferentes atributos de câmera ou do tráfego. Ainda que o objetivo final do algoritmo de extração de trajetórias veiculares seja o seu uso em campo, as diferentes variações de iluminação, sombra e possíveis interferências no ambiente filmado poderiam interferir na análise da qualidade de forma a prejudicar um pouco o conhecimento da origem dos erros e suas distribuições em relação a atributos de câmera e aspectos do tráfego, tais como altura de câmera, fluxo veicular e regime de operação do tráfego.

O fluxograma que ilustra as sequências utilizadas para analisar a qualidade do rastreamento veicular executada pelo algoritmo proposto está exposto na Figura 9. As etapas para a avaliação da qualidade são: 1) Definição e construção dos cenários de filmagem do microssimulador; 2) Execução do plano de simulação com a geração das filmagens e exportação dos indicadores espaço-temporais; 3) Consolidação do algoritmo de visão computacional baseado em características; 4) Avaliação dos parâmetros do algoritmo; 5) Aplicação do algoritmo e 6) Análise comparativa dos indicadores de rastreamento.

Figura 9 - Fluxograma do método de avaliação da qualidade de rastreamento veicular



Fonte: Elaborada pelo autor.

### 3.1 Definição e Construção dos Cenários no Microsimulador

O processo de construção iniciou-se a partir da definição dos cenários que seriam utilizados. Essa escolha foi baseada nos indicadores que seriam observados, considerando-se também a necessidade de se obter um ambiente controlado, sujeito à menor interferência externa possível, diferentemente do que ocorre em câmeras reais de fiscalização. Desse modo, controlados os fatores externos, pode-se ter como hipótese inicial que a grande maioria das diferenças nos cálculos dos indicadores resulte da própria ferramenta utilizada.

Como o objeto de estudo se trata de diagramas espaço-tempo, os principais indicadores a serem utilizados na análise comparativa seriam as coordenadas de um ponto do automóvel, no caso o ponto médio do para-choque dianteiro e a velocidade medidos a cada instante de tempo. Além do mais, seria interessante a observação da influência de fatores como a altura da câmera na filmagem e o *headway* entre os veículos.

Foram então, construídos nove cenários, em função do fluxo veicular, altura de filmagem e comportamento do fluxo. Em relação ao fluxo veicular foram utilizados os fluxos veiculares de 500 veículos por hora por faixa (vphpf) e 1000vphpf. Foram avaliadas três alturas de filmagem selecionadas para permitir uma amplitude de filmagem (extensão de via) de 50m, 100m e 200m. Desta forma as alturas de câmera foram de 21m, 38m e 68m respectivamente.

Com o intuito de se observar a qualidade do algoritmo quanto a variações bruscas de velocidade, provocando maiores distorções no diagrama espaço-tempo dos veículos, foram simulados e filmados cenários variando o tipo de regime de fluxo com a introdução de zonas de redução de velocidade do microssimulador. Também foram simulados cenários com o regime de tráfego interrompido, visando avaliar a influência da parada total dos veículos na qualidade do rastreamento. A Tabela 1 apresenta os requisitos de cada cenário proposto.

Tabela 1 - Atributos de filmagem e de operação de tráfego de cada cenário simulado

Cenário	Fluxo Veicular (vphpf)	Altura de Câmera (m)/amplitude de filmagem (m)	Regime de Fluxo veicular
1	500	21/50	Ininterrupto
2	500	38/100	Ininterrupto
3	500	68/200	Ininterrupto
4	1000	21/50	Ininterrupto
5	1000	38/100	Ininterrupto
6	1000	68/200	Ininterrupto
7	500	21/50	Ininterrupto*
8	500	38/100	Ininterrupto*
9	500	68/200	Ininterrupto*
10	500	21/50	Interrompido
11	500	38/100	Interrompido
12	500	68/200	Interrompido

(\*) Ininterrupto com redução da velocidade

Fonte: Elaborada pelo autor.

Sendo definidos os cenários de análise, os mesmos foram criados no software PTV Vissim v. 9.0©. Foram construídos três links, com tamanhos de 50, 100 e 200 metros, todos com três faixas e completamente na horizontal. As alturas de câmera correspondem aos trechos foram obtidas a partir do modo de simulação 3D do microssimulador.

As zonas de redução de velocidade foram construídas em todas as três faixas de cada trecho, localizadas próximas ao meio do link, com comprimentos variando de acordo com a extensão do trecho. Para uma abrangência de 50, 100 e 200 metros, os comprimentos da zona de redução foram de, respectivamente, 5, 15 e 20 metros. Os veículos, ao se

aproximarem dessas regiões, deveriam desacelerar de tal modo que sua velocidade estivesse menor ou igual a 15 quilômetros por hora, com uma desaceleração máxima de  $2 \text{ m/s}^2$  e, ao sair dessas zonas, voltavam a acelerar até a faixa de velocidade definida nos critérios padrões do microssimulador.

Para os cenários 10, 11 e 12 de regime de tráfego interrompido, foi considerado um ciclo semafórico de 60 segundos, sendo 30 segundos reservados ao escoamento de veículos. O semáforo para pedestres foi adicionado na metade dos trechos.

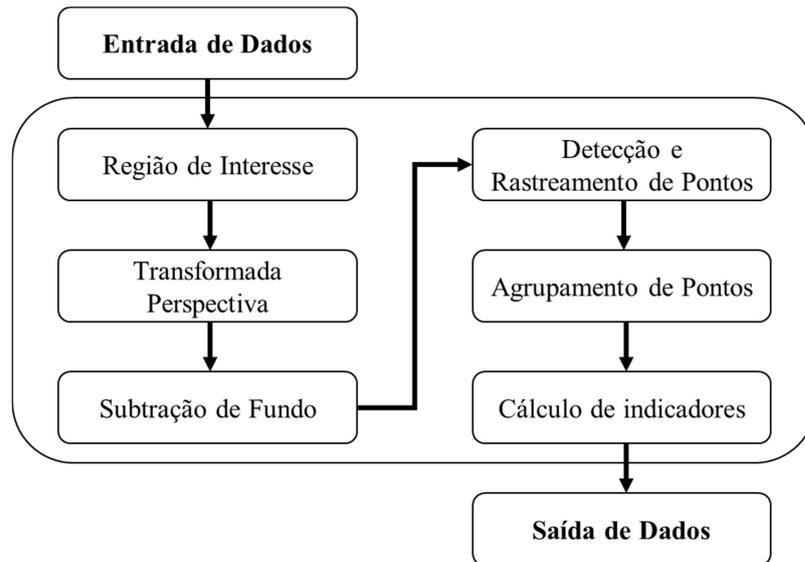
### 3.2 Consolidação do algoritmo de rastreamento veicular

Para a construção do algoritmo, foi utilizada a biblioteca OpenCV, a qual conta com mais de 2500 algoritmos computacionais que podem ser empregados em diversas aplicações na área de Visão Computacional, incluindo detecção e reconhecimento de objetos, rastreamento de movimentos e classificação de ações humanas registradas em vídeo (Intel, 2010).

Foi usado um dos Ambientes de Desenvolvimento Integrado (*Integrated Development Environment – IDE*), mais especificamente o *Spyder*. Foram fatores relevantes na escolha do ambiente de programação os recursos necessários, os quais estiveram de acordo com os objetivos do projeto, e a experiência de uso do mesmo.

A Figura 10 apresenta a sequência de passos da etapa de consolidação do algoritmo de extração de trajetórias veiculares. Após a entrada de dados, que são os vídeos a serem processados e os valores dos parâmetros, é escolhida uma região de interesse no vídeo, realizada a homografia para mapear as coordenadas reais, obtidas pelo VISSIM, nos *pixels* da imagem, é feita uma subtração entre a região da área de interesse que se move e a região parada, são detectados pontos a partir da imagem gerada na subtração de fundo, posteriormente esses pontos são rastreados e agrupados a partir de critérios pré-definidos e calibrados, são identificados os veículos líder e seguidor, calculados os indicadores de tráfego e tais informações são exportadas para uma planilha de arquivo *csv*.

Figura 10 - Diagrama do algoritmo de rastreamento de veículos



Fonte: Elaborada pelo autor.

### 3.2.1 Transformada perspectiva

No algoritmo, foram utilizadas as funções *cv2.getPerspectiveTransform* e *cv2.warpPerspective*. Esta primeira serve para encontrar uma matriz de transformação 3x3. As linhas retas permanecem retas mesmo após a transformação. Para encontrar esta matriz de transformação, é necessário a escolha de 4 pontos na imagem de entrada e pontos correspondentes na imagem de saída. Entre esses 4 pontos, 3 deles não devem ser colineares (Figura 11). Em seguida, é aplicada a função *cv2.warpPerspective* a partir da matriz de transformação 3x3 obtida com a função anterior.

Na Figura 11 há um exemplo da aplicação da transformada perspectiva, onde são mapeadas as coordenadas reais no solo mostrado no vídeo. O algoritmo também executa a rotação da imagem e a transformação em uma perspectiva desejada.

Figura 11 - Exemplo da deformação da imagem e aplicação da transformada perspectiva.



Fonte: Elaborada pelo autor.

Para aplicações do algoritmo em um ângulo de câmera ortogonal ao solo não foi perceptível distorções na imagem, visto que para este caso, qualquer dada distância entre dois pontos no vídeo é correspondente a uma mesma distância na realidade, podendo, portanto o algoritmo executar apenas rotações na imagem conforme desejado.

### 3.2.2 Subtração de imagens

A função do OpenCV para modelagem do *background* ainda não é completamente ideal para o rastreamento de veículos, pois como o fundo é adaptativo, quando os veículos param, estes passam a fazer parte do background, comprometendo o rastreamento. Para fins de economia de tempo de processamento a utilização de um fundo fixo foi suficientemente boa para a obtenção do processamento dos cenários propostos.

A subtração de imagens, ou segmentação, foi feita a partir de uma imagem de “fundo” (*background*), sem conter nenhum veículo, da imagem recorrente. A Figura 12 ilustra um *background*, Figura 13 mostra o quadro recorrente e a

Figura 14 mostra a geração de uma imagem binária (*foreground*) proveniente da segmentação.

Figura 12 - Exemplo de background



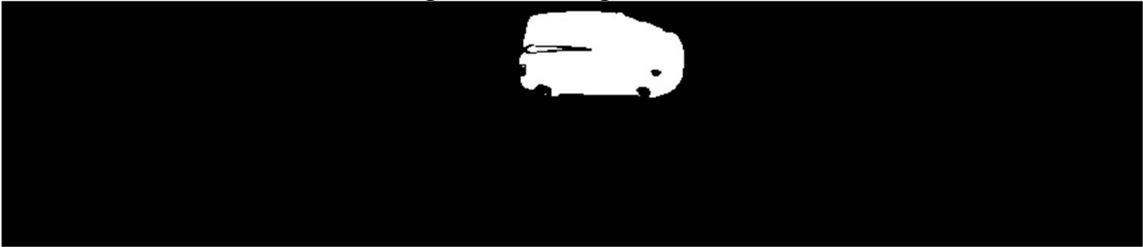
Fonte: Elaborada pelo autor.

Figura 13 - Quadro recorrente do vídeo



Fonte: Elaborada pelo autor.

Figura 14 - Imagem binária



Fonte: Elaborada pelo autor.

### 3.2.3 Identificação de pontos rastreáveis

A partir da imagem binária gerada na subtração de fundo são identificados pontos bons para rastrear através da função `cv2.GoodFeaturesToTrack`. Uma ilustração está disposta na Figura 15.

Figura 15 - Identificação de pontos bons para rastrear



Fonte: Elaborada pelo autor.

### 3.2.4 Rastreamento de pontos

No rastreamento dos pontos detectados pelo algoritmo Shi-Tomasi Corners Detector, é usada a função `cv2.calcOpticalFlowPyrLK()` do OpenCV. Ela é resultado do desenvolvimento dos trabalhos de Lucas e Kanade (1981). O algoritmo deles faz uma

atualização dos pontos detectados quadro a quadro, cujo resultado é a trajetória dos pontos que permanecem em movimento na região de interesse do vídeo até atingir a região de saída.

### ***3.2.5 Precisão dada em pixels no conjunto dos reais***

O cálculo de quantos metros há em cada pixel de um vídeo tem relação com a resolução do vídeo e a distância da câmera para o solo filmado ou a extensão em metros entre os limites de enquadramento da imagem. A precisão máxima do algoritmo poderia ser calculada como a metade do valor em metros que cada pixel no vídeo representa.

A precisão real poderia ser dada de forma discreta em pixels ou em metros. Apesar da menor unidade da imagem ser dada em pixels, as coordenadas exportadas pelo algoritmo são dadas dentro dos reais. Isso acontece por existir um modelo de previsão por interpolação e cálculo de probabilidade presente na função do OpenCV. Teoricamente esse método de estimativa da coordenada aumentaria bastante a precisão da coordenada, velocidade e principalmente da aceleração de veículos rastreados.

### ***3.2.6 Agrupamento de pontos***

A partir da entrada de dados (aquisição de vídeo) e da escolha da região de interesse, a homografia foi aplicada e a subtração de fundo definida foi a de *background* fixo, devido ao melhor desempenho quanto ao tempo de processamento. Na etapa de agrupamento de pontos, os critérios definidos foram: 1) proximidade entre pontos, isto é, se a diferença entre as coordenadas em x e y fossem menores que um limite estipulado; 2) região percentual e absoluta de velocidade média; 3) posição relativa dos pontos; 4) memorização das relações entre pontos.

O critério da proximidade dos pontos tem base no fato de que pontos que estão longe uns dos outros não pertencem ao mesmo veículo. Tal critério tem a desvantagem de perder agrupamentos em veículos muito compridos como ônibus e caminhões, mas isso só aconteceria se não houvesse uma “ponte” de pontos ao longo do veículo, portanto é necessário que os pontos detectados não se disponham apenas na dianteira e traseira dos veículos, mas ao longo destes.

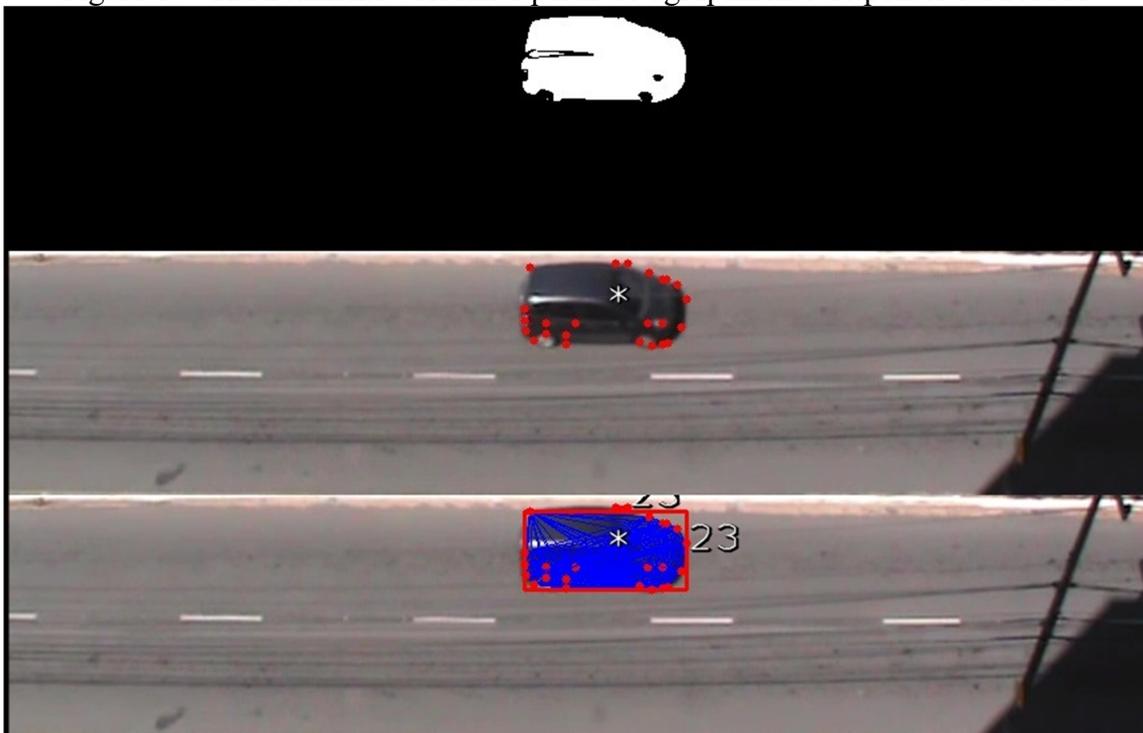
No algoritmo codificado, os pontos rastreados têm velocidades ligeiramente diferentes, logo, outro critério de agrupamento é uma margem percentual da velocidade média de um ponto deve conter a velocidade média de outro ponto caso este pertença ao mesmo

veículo. Este critério tem a desvantagem de não conseguir entender a diferença entre dois veículos com pontos de mesma velocidade média, embora esse caso aconteça poucas vezes. Além da margem percentual, o algoritmo conta com uma margem absoluta de velocidade média, dada em km/h. Esse critério adicional ajuda a segregar veículos quando estes estão a uma velocidade baixa.

O agrupamento de pontos é necessário também para a delimitação da extensão do veículo, para que o cálculo da velocidade do veículo seja dado a partir da média da amostra de pontos rastreados e para que o veículo possa ser contado corretamente. Para tal são usados critérios de agrupamento com base na velocidade dos pontos rastreados e no padrão de movimento dos mesmos.

Salienta-se que os critérios estabelecidos são modelos que têm como *output* um resultado binário, na qual responde se duas *features* pertencem a um mesmo veículo ou não. Um valor limite deve ser considerado para que a partir do qual seja rejeitada ou não a hipótese de cada par de pontos serem pertencentes ao mesmo veículo. A Figura 16 dispõe o resultado gráfico das ligações entre os pontos rastreados através dos critérios a serem mencionados com maior nível de detalhes na próxima seção.

Figura 16 - Rastreamento veicular a partir do agrupamento de pontos rastreados



Fonte: Elaborada pelo autor.

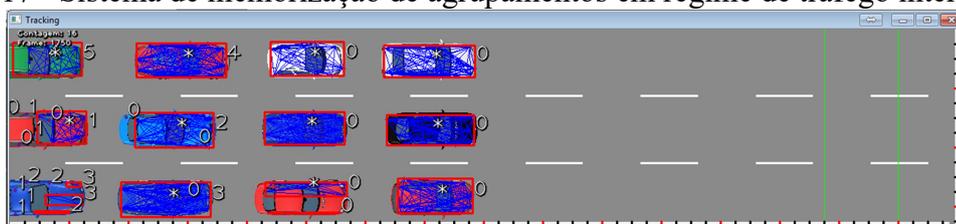
Apesar dos critérios já existentes, foi observado que há a possibilidade de veículos estarem próximos uns dos outros e com velocidade média similar, mas estes não necessariamente estariam percorrendo a via lado a lado, podendo haver ligações de *features* em direção diagonal. Pensando nisso, o critério da posição relativa foi criado de modo que o algoritmo só reconhece que dois pontos pertencem ao mesmo veículo se a reta que os liga seja aproximadamente paralela ao eixo x ou a eixo y. Para isso foi dado que o ângulo da posição relativa entre dois pontos estejam entre limites pré-definidos.

Com todos os critérios incorporados, o algoritmo consegue lidar bem com tráfego ininterrupto para grandes e pequenas velocidades de corrente de tráfego. Apesar disso, os veículos param próximos uns aos outros, lado a lado e com velocidades médias próximas a zero. Para contornar tal problema, foi criado um sistema de memorização dos agrupamentos já firmados em algum quadro anterior do vídeo, de modo a já considerar agrupados os pontos pertencentes aos veículos que em outro momento estavam em movimento.

Além disso, os pontos com velocidade abaixo de certo limite não são testados, para evitar que estes se liguem com outros veículos. Quando os veículos voltam a percorrer o trecho onde estavam parados, os pontos voltam a ser testados. Com o sistema de memorização foi possível identificar separadamente veículos que paravam no regime de fluxo interrompido. No anexo D, está disposto um exemplo de exportação de resultados do algoritmo, já incluso o sistema de memorização.

Foram usados vídeos em ambiente simulado para testar o possível funcionamento do sistema. A Figura 17 mostra os veículos com velocidade média, considerando-se os últimos 50 quadros do vídeo, tendendo a zero por estarem parados. É possível observar que os mesmos não são agrupados apesar de estarem próximos uns aos outros e com velocidades muito semelhantes.

Figura 17 - Sistema de memorização de agrupamentos em regime de tráfego interrompido



Fonte: Elaborada pelo autor

### 3.2.7 Cuidados com falsos positivos e falsos negativos

É possível surgir erros como os falsos positivos, quando os modelos/critérios respondem que dados dois pontos são do mesmo veículo quando na realidade não são, e como os falsos negativos, quando os modelos-critério respondem que dados dois pontos não fazem parte do mesmo automóvel quando na realidade eles fazem parte.

Os erros falsos negativos não são tão danosos e considerou-se menor rigor para estes visto que para que os limites do veículo sejam bem delimitados, são necessárias apenas duas *features* ligadas corretamente em extremidades opostas do veículo, como por exemplo, uma na dianteira do lado direito e outra na traseira do lado esquerdo. Já os erros que são falsos positivos são extremamente danosos já que basta um erro deste tipo para que dois veículos sejam considerados como um só e invalide o rastreamento de dado veículo pelo menos momentaneamente. Para amenizar os efeitos dos erros, foi necessário ponderar a criação de novos modelos e conseqüentemente novos parâmetros com o esforço adicional de ajustar os mesmos em função do tempo de processamento, qualidade das etapas de rastreamento e de todo o processo metodológico.

### **3.3 Execução do plano de simulação, filmagens e exportação de indicadores**

As simulações foram executadas com duração de 900 segundos para todos os cenários com o fator de lapso de tempo no VISSIM© igual a 1, significando que a simulação seguia em velocidade real. As faixas padrões de velocidade do software foram obedecidas e a composição do fluxo veicular utilizada foi a default do próprio software de simulação, onde os carros de passeio correspondem a 98% do fluxo e os veículos pesados a 2%.

Os vídeos foram gerados a partir da função *screen record* do aplicativo gratuito Atube Catcher v.3.8.8007, com taxa de amostragem de 29,97003fps. A resolução dos vídeos foi de 1624 x 336 pixels para as filmagens de altura 21m, de 2064 x 216 pixels e 2064 x 104 pixels para as alturas de 38 e 68 metros respectivamente. Foram definidas janelas de captura a partir da imagem de projeção do monitor para garantir que a pista abrangeria toda a janela de reprodução do vídeo, evitando-se uma possível etapa de edição do mesmo.

Como resultado da simulação, além das filmagens, obteve-se o arquivo correspondente aos dados brutos de registro de veículos agregados a cada 0,1 segundos contendo atributos sobre número do veículo, número da faixa, coordenada da dianteira, comprimento veicular e velocidade.

### 3.4 Análise de sensibilidade dos parâmetros do algoritmo

Após a construção do algoritmo de rastreamento veicular, procurou-se obter um melhor entendimento dos parâmetros dos modelos empregados nas funções disponíveis na biblioteca OpenCV, que estavam presentes no algoritmo. Além dos parâmetros provenientes de tais funções, existem outros parâmetros criados para o completo funcionamento do algoritmo que também foram avaliados.

É importante notar que em microssimuladores como o VISSIM, a existência dos parâmetros que podem ser calibrados pelo usuário é definida pelos próprios fabricantes, embasadas pelos modelos que utilizam os valores de tais parâmetros para a representação gráfica e matemática dos veículos. Portanto, cabe aos usuários escolher os parâmetros a serem calibrados e validados, tendo em vista um leque limitado de parâmetros a serem usados nos microssimuladores.

Diferente dos microssimuladores, a identificação, rastreamento e representação dos veículos partindo de programação de computador e processamento de imagens, permite maior flexibilidade quanto à escolha dos modelos que são empregados dentro da estratégia *feature based* e quanto às definições de valores presentes nestes, os quais podem ser considerados variáveis, constantes, dinâmicos ao longo do tempo ou fixos para cada regime de tráfego ou atributo de câmera. Pela grande flexibilidade de construção do algoritmo, refletida na extensa possibilidade de troca de modelos e parâmetros, a avaliação dos parâmetros do algoritmo desenvolvido foi, em sua maior parte, qualitativa.

O algoritmo de rastreamento conta com 26 parâmetros (Anexos E a F) distribuídos nas sub-etapas de subtração de fundo (*cv2.createBackgroundSubtractorMOG2*), detecção de características (*cv2.goodFeaturesToTrack*), rastreamento de características (*cv2.calcOpticalFlowPyrLK*) e agrupamento dos veículos. Analisando a definição conceitual dos parâmetros e em função da qualidade dos vídeos gerados, i.e., estabilidades da câmera, ângulo de filmagem e ausência de sombras, 22 parâmetros foram selecionados para o processo de ajuste (Anexo H).

Para a avaliação dos parâmetros do algoritmo utilizado, primeiramente o significado de cada parâmetro foi pesquisado na documentação da biblioteca do OpenCV, onde valores baixos, altos e *default* foram estipulados para cada parâmetro. Por fim, foram realizados testes de processamento de vídeo usando os 3 cenários de fluxo interrompido obtidos na etapa 3.3.

Cada vídeo correspondeu à uma execução de simulação de um parâmetro variado isoladamente. Cada parâmetro foi testado uma vez com valor baixo e outra com valor alto para cada um dos 3 vídeos correspondentes aos cenários 10, 11 e 12, que têm diferentes alturas de câmeras. Ao total, foram executados 135 processamentos de vídeo de simulação, sendo 44 processamentos de vídeo para cada altura de câmera em que, destes, 22 foram para os valores baixos e 22 para valores altos. Também foram realizados 3 processamentos de um único conjunto de valores *default*, sendo um processamento de vídeo para cada cenário filmado, de forma a permitir a comparação do erro dos cenários *default* com os erros obtidos pela alteração do parâmetro para os valores alto ou baixo.

Ao final de todos os processamentos de vídeo, foi possível analisar os erros de percentual de veículos efetivamente rastreados em todo o trecho mediante a variação isolada de cada parâmetro. Procurou-se gerar hipóteses sobre a possibilidade de uso de um único conjunto de valores *default* para todos os cenários. Os valores gerados nos testes, disponíveis no Anexo H, mostraram que os erros se diferenciaram bastante entre cada cenário de altura de câmera diferente, como consta no Anexo I.

Após a verificação das diferentes variações de valores entre os cenários, procurou-se escolher entre os valores baixos ou altos de cada parâmetro em cada cenário, de forma a escolher o valor que resultou num menor erro percentual. Dessa forma foram gerados 3 grupos de valores default em dois tipos de seleções e novamente, foram processados os 3 vídeos correspondentes aos 3 cenários de alturas de câmera diferentes. Os resultados estão conforme a Tabela 2. Houve uma seleção entre todos os parâmetros, escolhendo-se os de menores erros (seleção 1) e houve uma seleção escolhendo apenas entre os parâmetros que mais variaram (seleção 2), os quais estão em negrito a média das diferenças absolutas entre o erro *default* e cada limite (inferior e superior) no Anexo I. Na seleção 2 do cenário 10 houve um elevado tempo de processamento a ponto de inviabilizar a obtenção do resultado.

Tabela 2 - Erros percentuais gerados em seleções de valores ótimos de parâmetros

<b>Cenário</b>	<b>Seleção 1</b>	<b>Seleção 2</b>
10	-7%	-----
11	2%	4%
12	-70%	-66%

Fonte: Elaborada pelo autor

É importante notar que só foi utilizada uma perspectiva de análise, usando apenas um indicador (percentual de veículos rastreados efetivamente), mas estes erros podem

apresentar variações diferentes para outros indicadores de qualidade ou para modelos diferentes nas etapas de rastreamento. Entre outros indicadores possíveis se destacam o tempo de processamento, precisão da coordenada, velocidade, comprimento veicular e espaçamento de veículos.

Apesar de a presente avaliação não se mostrar conclusiva para haver confiança em afirmar quais parâmetros são de fato significativos, ela foi útil para entender, de modo geral, o significado dos parâmetros e o impacto da variação destes na eficácia de rastreamento em todo o percurso. Uma análise da influência da variação dos valores de parâmetros na qualidade do algoritmo seria completa apenas se realizada em conjunto com a construção do algoritmo. Em contrapartida os objetivos deste trabalho buscam contribuição no método de avaliação dos erros através da aplicação do algoritmo utilizando uma adaptação dos modelos já existentes de rastreamento veicular.

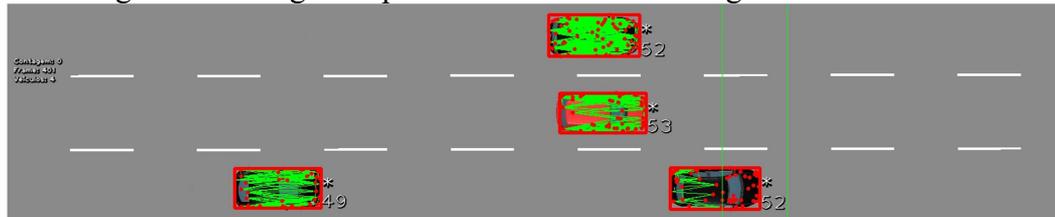
### **3.5 Aplicação do algoritmo de rastreamento veicular**

Inicialmente foi necessário um processo de ajuste dos parâmetros do algoritmo, em que foi aplicado o método da tentativa e erro. O tempo de processamento e os erros de detecção, identificação e rastreamento de *features* provenientes de cada mudança nos parâmetros foram visualizados e avaliados através de recursos visuais. Tais avaliações serviram de base para a escolha de valores ajustados para cada cenário. Posteriormente ao ajuste de parâmetros, foi realizada a aplicação do algoritmo de rastreamento nos cenários propostos, de modo a gerar as estimativas dos atributos de fluxo veicular provenientes do algoritmo ajustado.

Entre os recursos visuais utilizados está a visualização de pontos (*features*), representados por círculos preenchidos, onde foi possível observar a distribuição e a quantidade desses em torno dos veículos. Outro recurso visual utilizado é a representação do agrupamento de pontos através de linhas que ligavam um ponto a outro, onde ajudava a identificar falsos positivos e falsos negativos de agrupamento. Havia também o recurso visual da identificação veicular, representado por retângulos vermelhos que envolviam os veículos. Isto mostrava se havia dupla identificação de veículos e se o comprimento dos veículos estava sendo coletado corretamente. Um último recurso visual usado é a visualização em texto, na tela de processamento, do percentual de veículos rastreados em todo o percurso, que mostrava a eficácia do rastreamento em todo o trecho, já que era possível que veículos começassem a ser rastreados ao entrar, mas ao longo do trecho o agrupamento de pontos se desfizesse.

A Figura 18 ilustra a tela de processamento do algoritmo ajustado com destaque para as características (pequenos círculos vermelhos), ligação das *features* (segmentos em verde) e os agrupamentos (retângulos vermelhos). Os números ao lado dos veículos exibem a velocidade média destes, estimada pelo algoritmo e útil para entender falsos positivos e falsos negativos de agrupamento de *features*.

Figura 18 - Imagens representativas dos cenários geradas no VISSIM



(a) - Altura de filmagem = 21m.



(b) - Altura de filmagem = 38m.



(c) - Altura de filmagem = 68m.

Fonte: Lira *et al.*, (2017).

Com os recursos visuais, o ajuste de parâmetros do algoritmo por tentativa e erro visou: 1) uniformizar a distribuição de pontos, garantindo quantidade suficiente em cada veículo; 2) maximizar a qualidade do agrupamento das características (*features*) as quais definem as dimensões do veículo; 3) minimizar as diferenças na contagem veicular; 4) garantir que os veículos são rastreados durante toda a região de interesse e 5) reduzir o tempo de processamento. Os critérios de parada para o fim do processo de ajuste dos parâmetros foram a meta do percentual de veículos rastreados até o fim ser menor ou igual a 5%, em valores arredondados e tempo de processamento menor que 2 horas por cenário.

Foi assumida a premissa de que se obtivéssemos boa avaliação visual da detecção, identificação e rastreamento de *features*, também obteríamos uma boa qualidade na estimação dos atributos de fluxo veicular. Tal premissa permitiu um rápido diagnóstico visual de cada aplicação de conjunto de valores para os parâmetros. Por ser rápido, tornou-se viável a aplicação do algoritmo nos diversos cenários propostos para obtenção dos atributos de fluxo veicular.

O ajuste de parâmetros foi baseado na detecção, identificação e rastreamento de *features* ao invés de ser baseado nas estimativas de atributos de fluxo veicular. Assim, houve um enorme ganho de tempo pelo uso de análise visual da qualidade das etapas de rastreamento. Não necessariamente isso prejudica a qualidade da posterior comparação das estimativas de atributos de fluxo veicular emitidas pelo VISSIM e Python, já que a estimativa de tais atributos é consequência imediata da qualidade das etapas de rastreamento veicular, refletida pelos recursos visuais utilizados.

A heurística de ajuste foi limitada em função do tempo de processamento dos vídeos, que foi em torno de 1 hora para 15 minutos de vídeo para cada mudança individual de valor de parâmetro, e dos objetivos do trabalho. Os parâmetros foram ajustados individualmente sendo observados seus significados e os aspectos descritos anteriormente. Acredita-se que o melhoramento do processo de ajuste desses parâmetros poderia gerar melhor funcionamento das etapas de rastreamento.

Após o ajuste de parâmetros realizado para cada cenário (Anexo G), o algoritmo foi executado com a finalidade de obter-se a qualidade das estimativas de atributos de fluxo veicular. Os resultados de saída (arquivo do tipo .csv) foram exportados para uma planilha do Excel juntamente ao arquivo de saída do VISSIM (.fzp) e no Excel foi possível combinar os dados de veículos do VISSIM com os seus respectivos pares no algoritmo.

Como a agregação temporal dos dados do VISSIM é feita em intervalos de 0,1s e a filmagem ocorreu a uma taxa de aproximadamente 0,0334s (1/29.97003 frames), o algoritmo de rastreamento foi ajustado para analisar somente um a cada três frames da filmagem. Esse ajuste ainda não garantiu um mapeamento perfeito entre o arquivo de saída do VISSIM e o arquivo de saída do algoritmo uma vez que a taxa de amostragem precisa ficou de 0,1001s. Para ajustar essa diferença foi realizado um ajuste temporal no arquivo de saída do algoritmo, sendo excluídos os pontos de dados duplicados pelo algoritmo em virtude do vídeo.

Os dados foram então ordenados por faixa e depois por ID do veículo, certificando-se que cada linha de dados provenientes do .fzp (VISSIM) se relacionasse a respectiva linha de dados vindos do .csv (Algoritmo em Python). Após essa correspondência, foram utilizados fatores de ajuste do sistema de coordenadas dos dois arquivos e então, foram selecionados aleatoriamente 10 veículos de cada uma das três faixas, totalizando 30 veículos por cenário.

### 3.6 Cálculo de indicadores

Com a estratégia *feature based*, o cálculo dos indicadores espaço-temporais como a velocidade no espaço ou no tempo foi obtido com a média das velocidades dos pontos rastreados (*features*). Para a obtenção de indicadores espaço-temporais foi necessário que o algoritmo de rastreamento de veículos exportasse também um ID para cada veículo de modo que para cada informação de saída de dados atribuída a cada veículo em cada instante de tempo seja atribuído o ID de cada veículo líder e veículo seguidor.

A partir das informações de fluxo de tráfego, posição, tempo, dimensões dos veículos e os IDs dos veículos líder e seguidor para cada veículo em cada instante de tempo, puderam ser calculados indicadores espaço-temporais.

### 3.7 Análise comparativa das estimativas de atributos de fluxo veicular

Inicialmente foi realizada uma análise de dados agregados, compreendendo uma validação visual dos diagramas espaço-tempo sobrepostos. Nesta validação é possível observar “defasagens” entre as trajetórias, veículos que não são rastreados até o final do trecho e veículos que são segmentados. Em seguida foram comparados os valores de contagem volumétrica de veículos, além de média e desvio-padrão da velocidade dos veículos no trecho, comparando-os com os obtidos no arquivo .fzp do VISSIM em cada cenário.

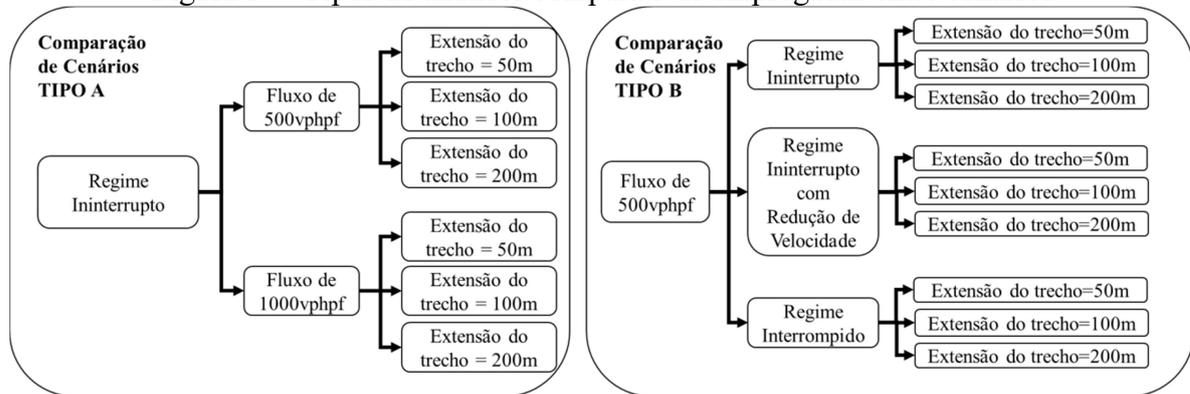
Logo depois foi realizada uma análise desagregada para a qualidade do rastreamento dos veículos em cada cenário. Para a posição veicular, foram estimadas as diferenças das coordenadas do VISSIM e as rastreadas ( $\Delta_{xyvt}$ ) de cada veículo a cada intervalo de 0,1s. Ao final de cada passagem obteve-se a diferença média da posição de cada veículo. Em relação à precisão da velocidade foram utilizadas duas métricas. A primeira métrica foi a diferença entre a velocidade média no espaço ( $\Delta_{usv}$ ) de cada veículo no VISSIM (*ground-truth*) e no algoritmo e a segunda foi a média das diferenças entre as velocidades instantâneas ( $\Delta_{uvt}$ ), i.e., a cada 0,1s. Finalmente foi ainda verificada a diferença entre o comprimento dos veículos do VISSIM e os obtidos com a ferramenta ( $\Delta_{lv}$ ).

As comparações entre cenários foram classificadas em tipo A e tipo B (Figura 19). Primeiro foi realizada a comparação tipo A, onde foi avaliado o impacto do aumento de fluxo veicular na qualidade do rastreamento em 3 alturas de câmera, totalizando 6 cenários comparados entre si (cenários 1,2,3,4,5 e 6). Houve a hipótese de que em cenários de maior

fluxo, a probabilidade de haver falsos positivos de agrupamento aumentasse diminuindo assim, a qualidade do rastreamento. Isso justificou a inclusão do teste de aumento de fluxo no experimento.

Na comparação do tipo B, foi avaliado o impacto de 3 regimes de tráfego na qualidade do rastreamento, para 3 alturas de câmera, totalizando 9 cenários comparados entre si (cenários 1,2,3,7,8,9,10,11 e 12). Houve a hipótese de que o modo como a velocidade da corrente de tráfego é aletrada pelos motoristas e até mesmo a parada dos veículos influencia na qualidade do rastreamento. Além disso, houve a hipótese da qualidade do rastreamento veicular nos cenários de tráfego interrompido refletir o funcionamento da proposta de adaptação do algoritmo para tráfego interrompido, o qual inclui o sistema de memorização de *features*.

Figura 19 - Tipos de análises comparativas empregadas entre cenários



Fonte: Elaborada pelo autor

Para cada um dos 6 cenários da compração tipo A e para cada um dos 9 cenários da comparação tipo B foram extraídas as diferenças de *output* (Python menos VISSIM) de 4 indicadores: coordenada no eixo X do parachoque dianteiro de cada veículo, comprimento veicular, velocidade instantânea e velocidade média. Foram escolhidos aleatoriamente 30 veículos de cada cenário para comparar os *outputs*. Correspondente a cada veículo, foram exportadas em torno de 50 a 200 observações de coordenada veicular, comprimento veicular e velocidade instantânea, além de exportada 1 obsevação por veículo correspondente à velocidade média.

As diferenças de coordenadas veiculares foram escolhidas por expressarem a precisão com que o algoritmo consegue obter a posição de cada veículo no tempo, tendo em vista a variação do fluxo veicular, das alturas de câmera e dos regimes de tráfego. Apesar da estimativa de velocidade instântanea ser dependente da estimativa de coordenada veicular, os erros das estimativas de um são independentes dos erros da estimativa do outro. O algoritmo

pode errar a estimativa de posição de um veículo em 50cm num quadro 'n' do vídeo, além de errar os mesmos 50cm no quadro posterior 'n+1' onde o erro da estimativa de velocidade seria zero.

A precisão das estimativas de comprimento veicular também são independentes da precisão de coordenada e de velocidade e são importantes para o cálculo de indicadores que podem ser usados por analistas da segurança viária e para o entendimento da composição de tráfego para usar como *input* em microssimuladores.

### 3.8 Considerações

As etapas do método proposto para a avaliação da qualidade contaram com uma definição e construção dos cenários de filmagem do microssimulador VISSIM, que serviu de base para a obtenção do *ground truth* (valores tomados como verdade). Houve uma execução do plano de simulação com a geração das filmagens e exportação dos indicadores espaço-temporais, a consolidação do algoritmo de rastreamento veicular baseado em características, uma avaliação dos parâmetros do mesmo, e seu posterior ajuste para aplicação nos cenários propostos obtidos pelas filmagens do VISSIM. Como resultado, os indicadores espaço-temporais gerados pelo algoritmo foram avaliados pela sua comparação com os indicadores espaço-temporais obtidos pelo VISSIM em diversos regimes de tráfego veicular e alturas de câmera.

A utilização de microssimulador para a avaliação da qualidade de indicadores espaço-temporais obtidos por processamento de imagens não foi encontrada na literatura. O VISSIM foi escolhido para a presente avaliação da qualidade por permitir boa flexibilidade para construção de cenários de tráfego veicular em 3D, permitir o isolamento dos efeitos de atributos de tráfego veicular e atributos de filmagem como altura de câmera, além de exportar indicadores espaço-temporais com um bom nível de agregação e em larga escala.

O microssimulador VISSIM também permite a simulação de outros fatores que interferem no rastreamento veicular através de algoritmo de processamento de imagens, se este fosse aplicado em campo. Contam como fatores possíveis de ser simulados no VISSIM, que interferem no rastreamento veicular, mas não foram objetos de estudo nesta pesquisa os seguintes: objetos que podem ficar entre a câmera virtual e os veículos como portes, fios e semáforos; variações na iluminação ambiente; presença de sombras; diversos ângulos de câmera e pedestres que podem interferir no tráfego veicular. Embora o VISSIM tenha muitas

funcionalidades, nem todas foram exploradas no método proposto por causa da limitação do escopo desta pesquisa.

Existem fatores em campo que o microssimulador não representa bem e, portanto, limitam a avaliação da qualidade a partir de seu uso. Entre estes se destacam alguns poucos, como a possibilidade de desestabilização da câmera pelo vento, a presença de chuva, a reflexão da luz por objetos que funcionam como espelhos, a heterogeneidade de cores presentes em campo nos veículos e na via e pequenos objetos móveis que podem ficar na via como lixo por exemplo. Apesar das limitações, o uso do microssimulador para avaliação da qualidade de rastreamento veicular mostra-se uma poderosa ferramenta para assumir o papel de *ground truth*.

Quanto à consolidação do algoritmo de rastreamento veicular baseado em características, foram usados os modelos presentes na biblioteca OpenCV, com uma exceção na etapa de agrupamento de características, no qual houveram adaptações necessárias para a aplicação do algoritmo em regime de fluxo interrompido.

Os critérios da etapa de agrupamento tais como a estimativa de velocidade média e proximidade de pontos, tinham limitações que se apresentavam quando os veículos paravam. Quando isso acontecia, todos os veículos eram agrupados como se fosse um único veículo, pois tinham velocidades iguais (que era 0) e estavam próximos uns aos outros, dificultando a identificação de qual *feature* pertencia a qual veículo. Com a inserção do artifício de memorização dos agrupamentos no algoritmo esse problema foi reparado. A partir da inserção do artifício, quando os veículos se encontravam em movimento, o algoritmo memorizava os agrupamentos a partir das identidades das *features*. Assim, quando estes veículos que, outrora estavam em movimento, paravam, os agrupamentos se mantinham.

Com a finalidade de entender e avaliar melhor os parâmetros do algoritmo foram realizados testes que envolviam o comportamento dos erros de uma métrica, julgada a mais importante e adequada, mediante a alteração dos valores dos parâmetros de um valor *default* definido para valores considerados altos e baixos. A métrica usada foi o percentual de veículos rastreados em todo o percurso. Esta foi escolhida em face de sua boa expressividade da eficácia do rastreamento veicular de modo geral, além da facilidade de coleta, por conta da contagem veicular ser mostrada na tela ao qual era gravada ao final de cada processamento de vídeo. Cada veículo contado no final do trecho não tinha grande perda de pontos rastreáveis, e tinha um comprimento suficientemente grande para ser contado como veículo.

A avaliação dos parâmetros restringiu-se a apenas uma métrica pela limitação de tempo de análise e do escopo da pesquisa a ser realizada. O foco desta pesquisa se concentrou

na qualidade dos indicadores espaço-temporais em cada cenário proposto e não na modificação de modelos presentes nas etapas de rastreamento veicular. Apesar disso, a avaliação dos parâmetros do algoritmo, tendo em vista os testes realizados e a compreensão de seus significados, permitiu um melhor ajuste do algoritmo. Tal ajuste foi baseado em recursos visuais para tornar possível a aplicação do algoritmo em *feature based*. Os recursos visuais visaram a qualidade da identificação, agrupamento e rastreamento de pontos, os quais refletiam diretamente na qualidade dos atributos de fluxo veicular, obtida pela comparação dos resultados do VISSIM e Python em cada cenário proposto.

A comparação entre os resultados exportados do VISSIM e Python foi proposta de modo a tornar possível o entendimento do efeito isolado que cada regime de operação de tráfego e impactaria na qualidade dos indicadores espaço-temporais, além da variação de fluxo veicular e altura de câmera. Espera-se que o método proposto contribua para uma melhor avaliação dos erros presentes na coleta de indicadores espaço-temporais. Tal contribuição impacta diretamente, por exemplo, na confiança das estimativas de conflitos veiculares, que necessitam de precisão na coleta de dados microscópicos de tráfego.

## 4 RESULTADOS E DISCUSSÕES

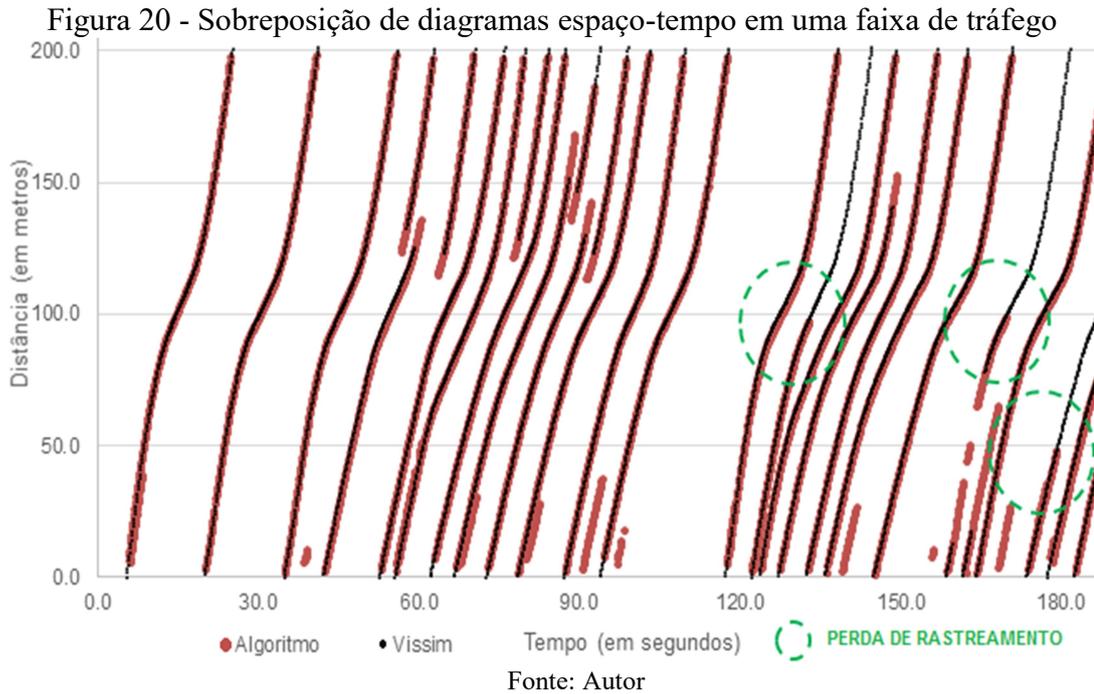
No decorrer deste capítulo serão apresentados os resultados da qualidade de extração de dados agregados e desagregados de movimentos veiculares em doze cenários de filmagem. Serão apresentadas e discutidas as origens e possíveis problemas que levaram aos erros apresentados, visando atingir a proposta geral da pesquisa.

### 4.1 Qualidade da estratégia de rastreamento utilizada

Antes da comparação tipo A e tipo B já mencionado no capítulo 3, foi realizada uma contextualização geral da eficiência de rastreamento veicular para a estimação de dados macroscópicos. Tal contextualização inclui a sobreposição de diagrama espaço-tempo gerada pelo algoritmo proposto em diagramas gerados pelo VISSIM, além da avaliação dos erros das estimativas de fluxo veicular e velocidade da corrente de tráfego.

Observa-se no gráfico (Figura 20) que apesar de todos os veículos não serem rastreados até o fim do trecho de 200 metros, os diagramas espaço-tempo estão bem sobrepostos. Pode-se observar que alguns veículos permanecem na faixa por todo o percurso e outros mudam de faixa. O encaixe da largura e comprimento veicular é mal colocado pelo algoritmo quando estes se encontram mudando de faixa, em posição diagonal em relação aos limites da região de interesse. Assim, pelos diagramas não é possível avaliar bem o rastreamento quando veículos estão mudando de faixa.

A perda de rastreamento mostrada na figura pode ter ocorrido por conta da falta de um melhor ajuste dos parâmetros do algoritmo. Salienta-se que a qualidade do ajuste é proporcional ao tempo de execução do mesmo e ao tempo de processamento. Apesar das perdas, considerou-se que o balanceamento entre qualidade de rastreamento e tempo de ajuste de parâmetros e execução do processamento foi adequado aos objetivos deste trabalho. Nota-se ainda que mesmo em meio a um trecho de desaceleração seguido por um de aceleração, a sobreposição dos diagramas espaço-tempo não se alterou.



A Tabela 3 mostra os resultados de contagem dos veículos que foram rastreados corretamente em todo o trecho nos 12 cenários propostos, além das médias de velocidade  $u_s$  e desvios-padrão de velocidade média dos veículos. Os veículos gerados durante a microsimulação foram subestimados pelo algoritmo de rastreamento em quase todos os cenários, se excetuando o cenário 11 de tráfego interrompido. As diferenças nos cenários de tráfego ininterrupto (1 a 9) se situam entre -3,37% e -1,08% aumentando de forma diretamente proporcional à altura da câmera e não variando significativamente com a mudança no regime de operação ou no fluxo veicular. Nos cenário de tráfego interrompido (10 a 12), os erros se situam entre -4,70% e 5,44% sendo levemente maiores que os de tráfego ininterrupto nos cenários de maior altura de câmera. A adaptação da etapa de agrupamento de *features* no algoritmo se mostrou crucial para a diminuição dos erros encontrados nos cenários de tráfego interrompido. Quanto às estimativas de  $u_s$ , o algoritmo gerou estimativas semelhantes ao VISSIM em todos os cenários.

Há veículos que não foram rastreados até o final do trecho, e por isso não foram contabilizados. Há também veículos que foram segmentados e foram contados como mais de um veículo. Estes casos podem estar relacionados a falhas nas etapas de detecção, rastreamento e/ou agrupamento de *features*.

Tabela 3 - Resultados obtidos para contagens e velocidades

Cenário (fluxo/trecho/regime)	Contagem			u <sub>s</sub> (km/h)	
	VISSIM	Algoritmo	E(%)	VISSIM	Algoritmo
1 (500vphpf/50m/ininterrupto)	372	368	-1,08%	51,2 (0,5)	52,1 (0,8)
2 (500vphpf/100m/ininterrupto)	370	364	-1,62%	51,8 (0,4)	52,5 (0,4)
3 (500vphpf/200m/ininterrupto)	369	362	-1,90%	51,9 (0,7)	52,2 (0,7)
4 (1000vphpf/50m/ininterrupto)	746	732	-1,87%	50,7 (1,0)	51,6 (1,0)
5(1000vphpf/100m/ininterrupto)	741	717	-3,24%	50,4 (2,8)	51,0 (2,8)
6 (1000vphpf/200m/ininterrupto)	741	716	-3,37%	49,5 (9,1)	50,1 (9,3)
7 (500vphpf/50m/ininterrupto*)	372	368	-1,08%	23,9 (2,1)	24,3 (2,3)
8 (500vphpf/100m/ininterrupto*)	367	360	-1,91%	22,6 (3,7)	23,3 (3,7)
9 (500vphpf/200m/ininterrupto*)	366	359	-1,91%	29,5 (9,5)	29,6 (9,8)
10 (500vphpf/50m/interrompido)	388	380	-2,06%	45,9 (21,5)	45,9 (21,9)
11 (500vphpf/100m/interrompido)	386	407	5,44%	31,1 (22,4)	31,5 (22,5)
12 (500vphpf/200m/interrompido)	383	365	-4,70%	34,9 (16,8)	35,2 (17,0)

Notas: ( ) desvio-padrão; \* regime ininterrupto com redução da velocidade

Fonte: Autor

Após a análise macroscópica da qualidade do algoritmo, foram gerados resultados de uma avaliação a nível microscópico. Para analisar a influência das alturas de câmera na qualidade do algoritmo, foram feitas duas comparações: a do tipo A, onde é avaliada a presença de fluxo veicular alto (1000vphpf) e baixo (500vphpf) e a do tipo B onde são avaliados 3 tipos de regime de fluxo veicular (ininterrupto, ininterrupto com redução da velocidade e interrompido).

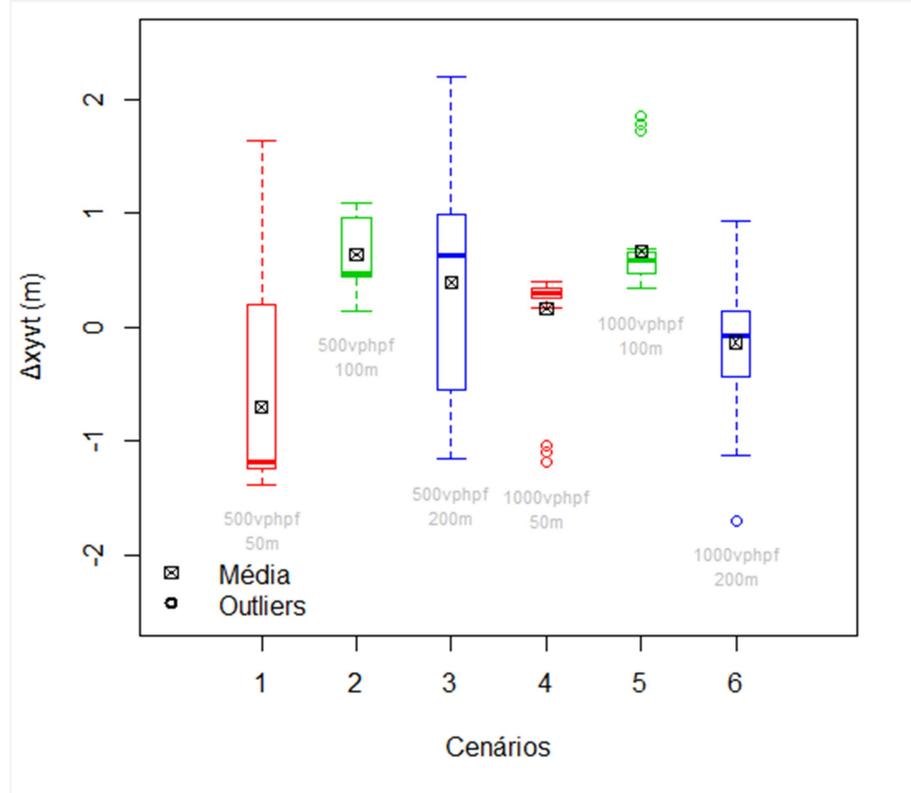
#### 4.1.1 Comparação tipo A

A seguir, estão dispostos os resultados da comparação tipo A, que incluem os cenários de 1 a 6. Nela são avaliados os impactos da mudança de fluxo veicular nos indicadores de coordenada, comprimento, contagem, velocidade média e instantânea, nas alturas de câmera correspondentes aos trechos de 50m, 100m e 200m filmados.

A seguir na Figura 21, dispõem-se as distribuições de  $\Delta xyvt$ . Cada boxplot expõe os resultados da amostra de 30 veículos. Observa-se que as diferenças médias das estimativas de coordenada ficaram entre -0,70m e 0,67m. Em relação à dispersão, os cenários 4, 5 e 6 (alto fluxo) apresentaram comportamento mais homogêneo quando comparados aos outros

cenários. Pode-se observar também que a influência do aumento de fluxo veicular na dispersão dos erros diminui conforme aumenta a altura de câmera.

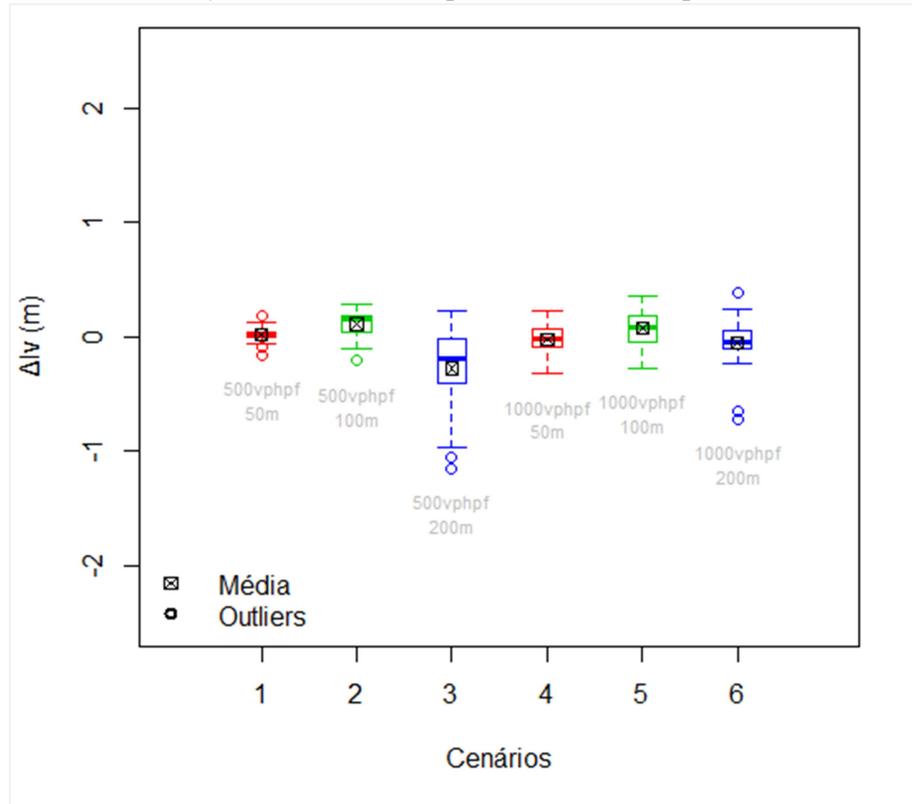
Figura 21 - Diferenças médias das coordenadas do VISSIM e rastreados ( $\Delta_{xyvt}$ )



Fonte: Autor

A Figura 22 apresenta as diferenças de comprimento veicular para cada cenário ( $\Delta_{lv}$ ). Quanto à estimativa de comprimento veicular os valores médios obtidos dos cenários situam entre -0,27m a 0,11m. Observa-se também que a dispersão das diferenças médias são aproximadamente as mesmas em todos os cenários.

Figura 22 - Diferenças médias de comprimento veicular para cada cenário ( $\Delta l_v$ )

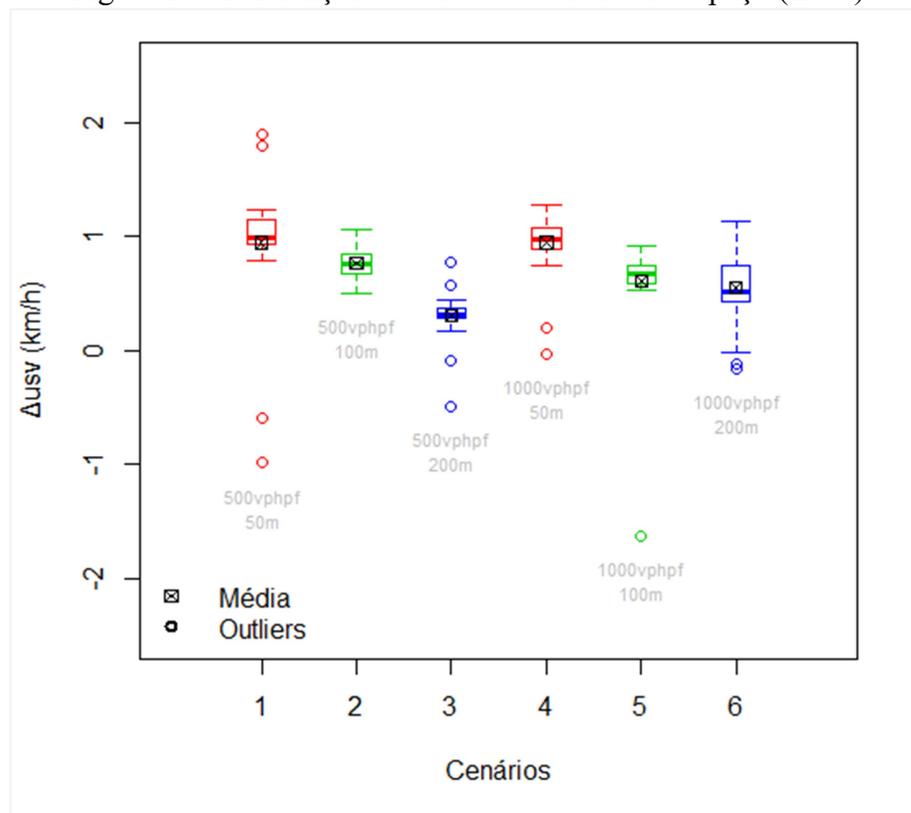


Fonte: Autor

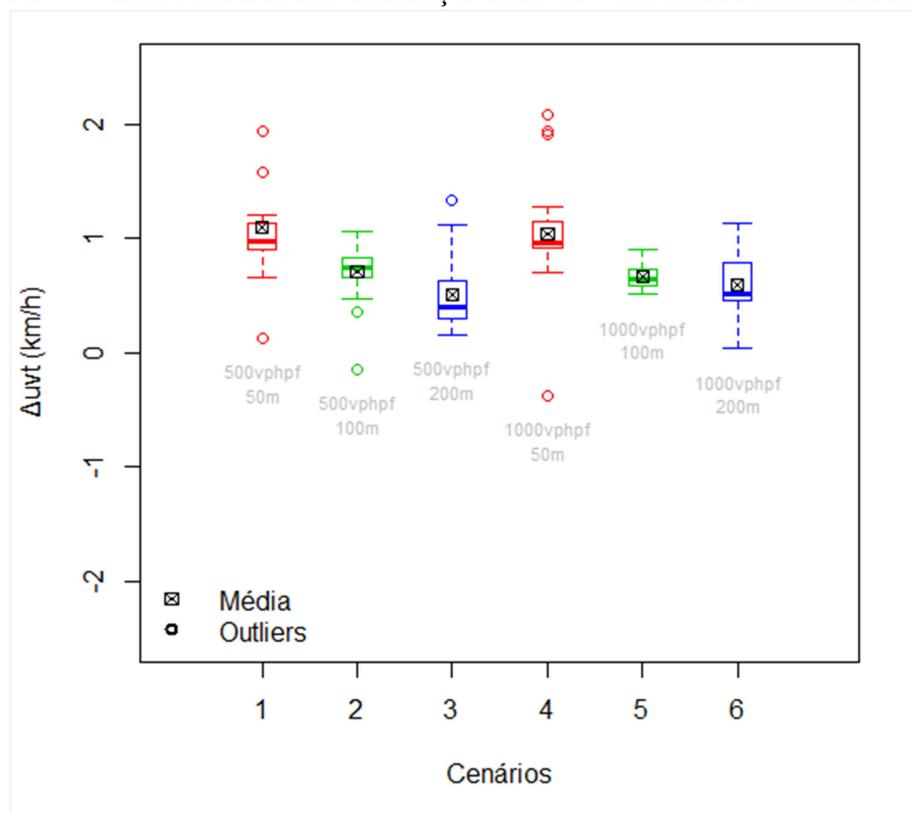
Acredita-se que um dos motivos que justifica as diferenças encontradas na coordenada e no comprimento veicular possa estar nos modelos presentes nas etapas de identificação, rastreamento e agrupamento de *features*.

A Figura 23 e a Figura 24 mostram as diferenças entre as velocidades médias e instantâneas dos veículos em cada cenário. Em relação às diferenças de velocidade (Figura 23 e Figura 24) é possível afirmar que as médias de  $u_s$  obtidas pelo algoritmo de rastreamento estiveram, em geral, acima das médias fornecidas pelo VISSIM independente dos cenários, entre 0,31 e 0,95 km/h.

Em se avaliando cenários de mesmo fluxo, existe uma tendência de redução de  $\Delta_{usv}$  significativa ( $\alpha = 0,05$ ) com o aumento da altura de filmagem. No que diz respeito às velocidades instantâneas, as médias de  $\Delta_{uvt}$  (Figura 24) se situam entre 0,51 e 1,10km/h. Pode-se observar que as médias das diferenças de velocidades média e instantânea não têm grande alteração em função do aumento de fluxo veicular. A dispersão das diferenças médias são aproximadamente as mesmas em todos os cenários.

Figura 23 - Diferenças de velocidade média no espaço ( $\Delta u_{sv}$ )

Fonte: Autor

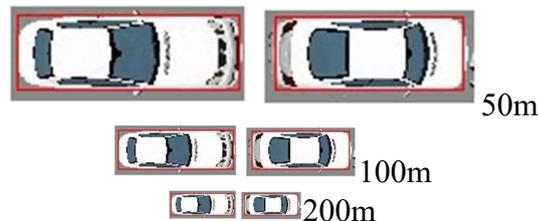
Figura 24 - Valores médios das diferenças entre as velocidades instantâneas ( $\Delta u_{vt}$ )

Fonte: Autor

Quanto à variação da altura da câmera, acredita-se que um dos motivos que justifica as diferenças encontradas na velocidade possa estar em possíveis distorções na representação da imagem 3D dos veículos gerada pelo VISSIM ao longo do percurso. Na Figura 25 são expostas imagens de um mesmo veículo em locais diferentes nos trechos de 50m, 100m e 200m.

Pode-se observar que a imagem dos veículos muda conforme sua localização do segmento de via, e conforme maior for a altura de câmera, a distorção tem tamanho menor, seguindo o tamanho do veículo. Desse modo, o tamanho das distorções podem explicar os erros são maiores conforme diminui a altura de câmera. Os limites do retângulo vermelho desenhado pelo algoritmo ilustram a região identificada como um veículo.

Figura 25 - Entrada e saída de um veículo no *link* em diferentes alturas de câmera



Fonte: Autor

Salienta-se que embora o algoritmo tenha como base os pixels para o estabelecimento das coordenadas, estas são exportadas com valores que variam dentro dos reais. Embora a estimativa de velocidade dependa da estimativa de posição dada dentro dos reais, as diferenças em suas estimativas podem ser independentes. Em dois quadros consecutivos as diferenças entre as coordenadas do VISSIM e algoritmo podem ser iguais e então a velocidade é estimada. Percebeu-se também que embora o fluxo não interfira tanto nas estimativas de velocidade, o tempo de processamento aumenta quando este também aumenta.

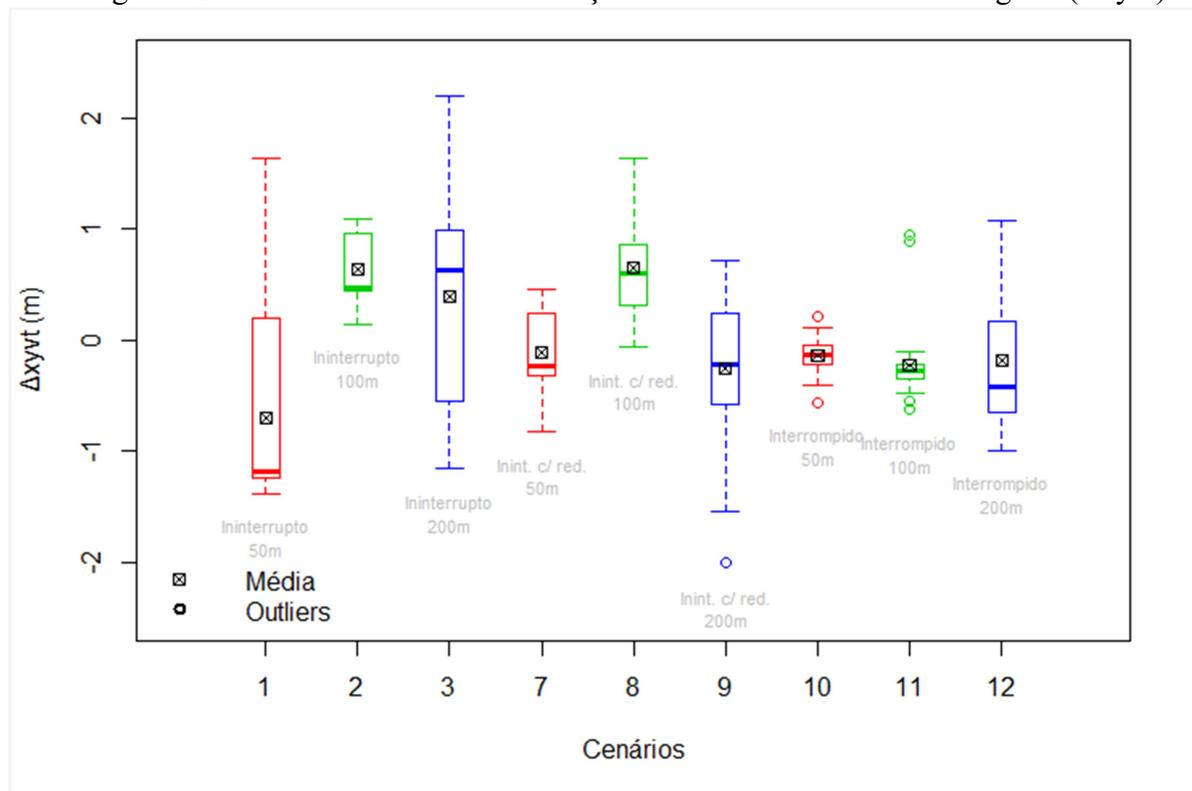
#### 4.1.2 Comparação tipo B

A seguir, estão dispostos os resultados da comparação tipo B, que incluem os cenários de 1 a 3 e 7 a 12, cujos fluxos veiculares são de 500vphpf. Nela são avaliados os impactos da mudança de regime de fluxo veicular nos indicadores de coordenada, comprimento, velocidade média e instantânea, para cada altura de câmera correspondente aos trechos de 50m, 100m e 200m filmados.

A seguir na Figura 26, dispõem-se as distribuições de  $\Delta_{xyvt}$ . Cada *boxplot* expõe os resultados da amostra de 30 veículos. Observa-se que as diferenças médias das estimativas de coordenada ficaram entre -0,70m e 0,65m. Em relação à dispersão, os cenários 10, 11 e 12 (regime interrompido) apresentaram comportamento mais homogêneo quando comparados aos outros cenários, principalmente em baixas alturas de câmera. Isso pode ser por conta da parada dos veículos que, presente nesses cenários, fazem as diferenças se estabilizarem.

Pode-se observar também que as alturas de câmera correspondentes aos trechos de 200m apresentaram, em geral, maior dispersão das diferenças, quando comparado às outras alturas de câmera em cada regime de fluxo.

Figura 26 - Valores médios das diferenças das coordenadas em cada regime ( $\Delta_{xyvt}$ )

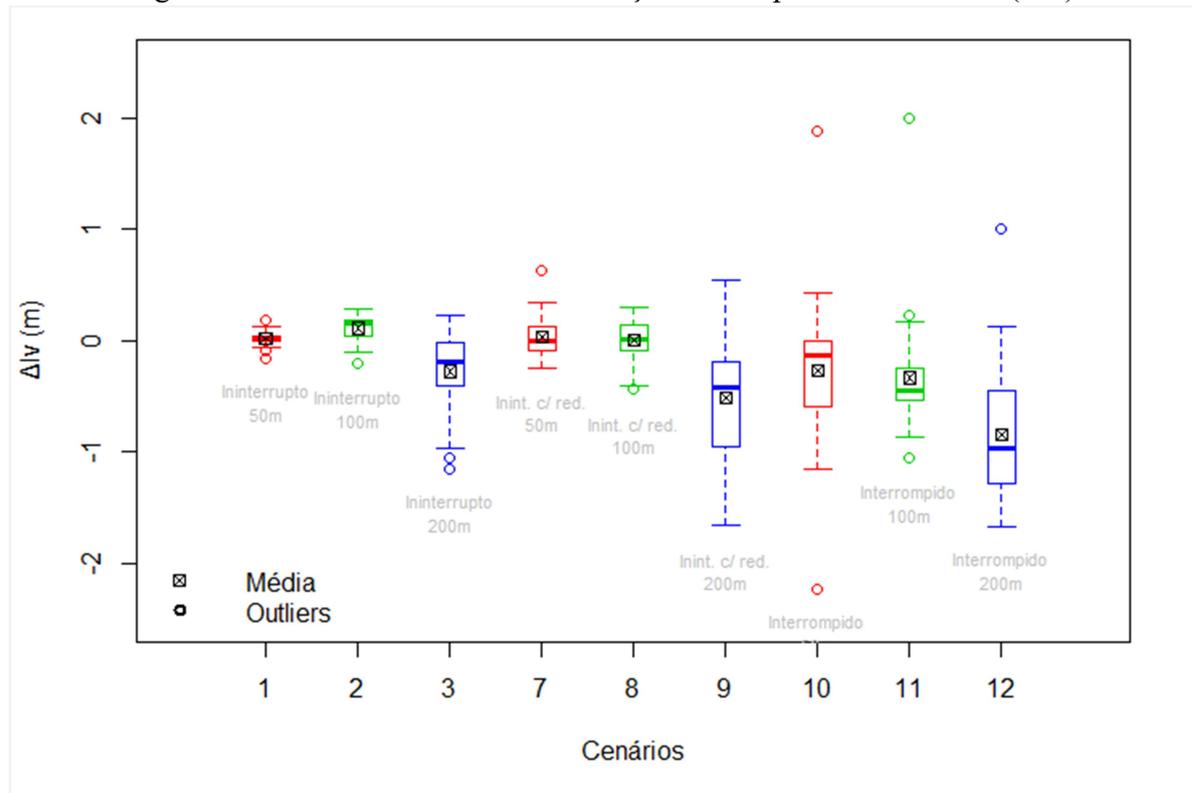


Fonte: Autor

A Figura 27 apresenta as diferenças de comprimento veicular para cada cenário ( $\Delta_{lv}$ ). Quanto à estimativa de comprimento veicular os valores médios obtidos dos cenários situam entre -0,85m a 0,11m. Nos 3 regimes de fluxo, os cenários com maior altura de câmera apresentaram maiores diferenças médias dos cenários (mais afastado de 0). O regime de fluxo ininterrupto (cenários 1, 2 e 3) apresentou menor dispersão das diferenças do que os outros regimes com redução da velocidade e interrompido.

Acredita-se que um dos principais motivos que justifica as diferenças encontradas na coordenada e no comprimento veicular possa estar em possíveis distorções na representação da imagem 3D dos veículos gerada pelo VISSIM ao longo do percurso, também apresentadas na comparação do tipo A.

Figura 27 - Valores médios das diferenças de comprimento veicular ( $\Delta l_v$ )



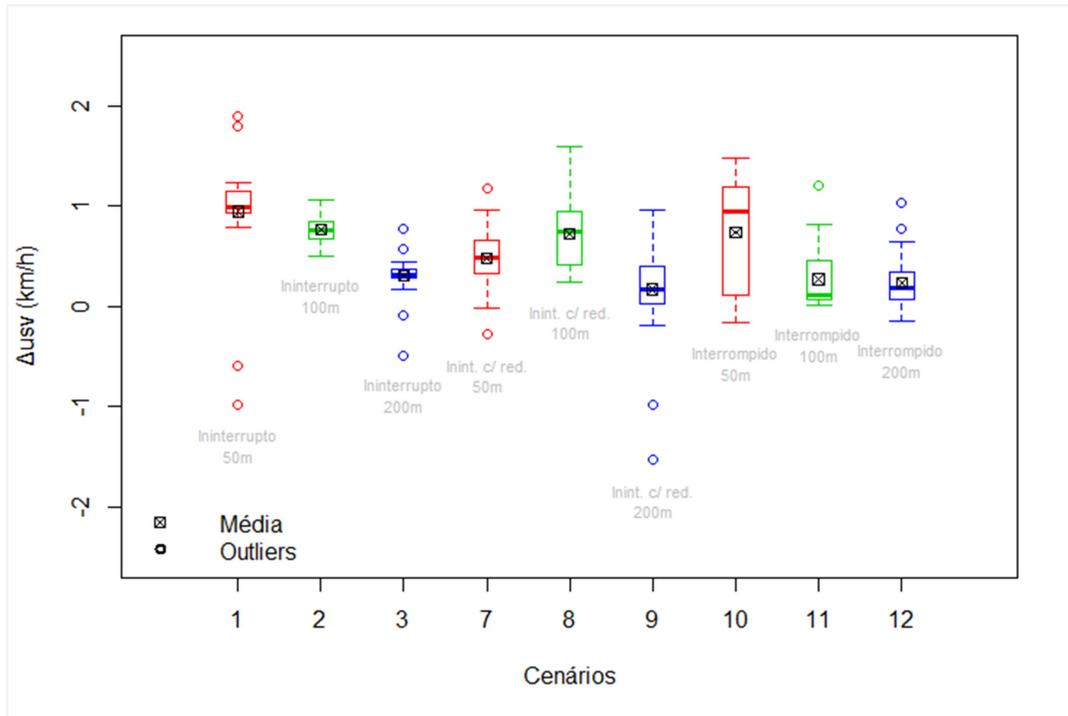
Fonte: Autor

A Figura 28 e a

Figura 29 mostram as diferenças entre as velocidades médias e instantâneas de cada veículo. Em relação às diferenças de velocidade (Figura 28 e a

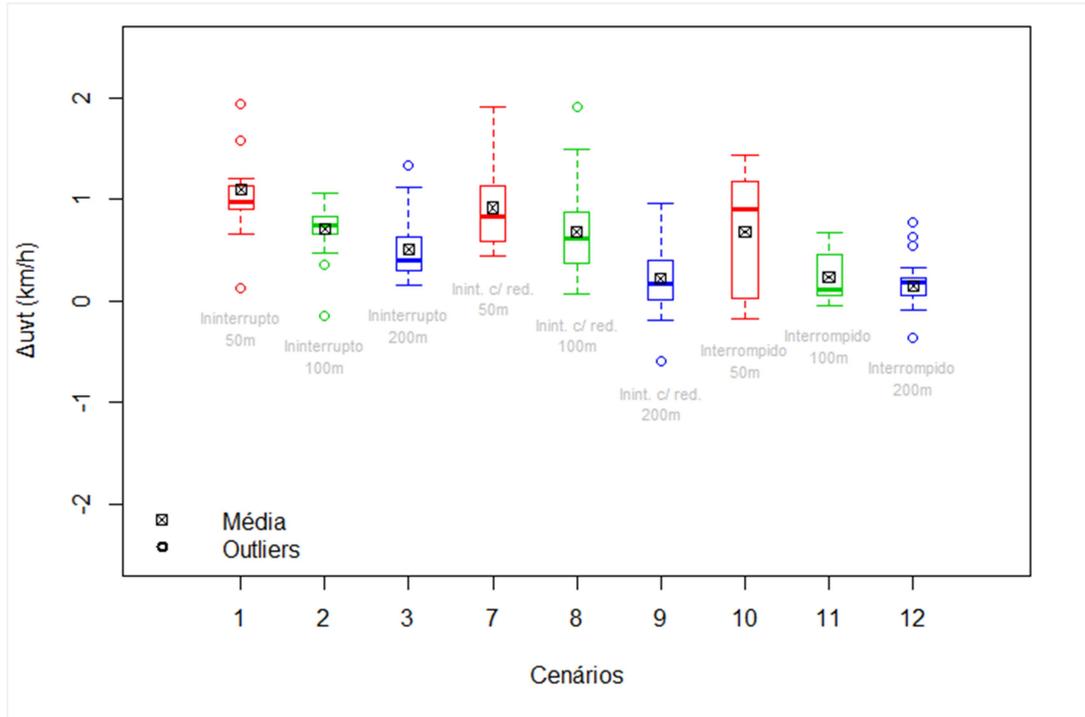
Figura 29) é possível afirmar que as médias de  $u_s$  obtidas pelo algoritmo de rastreamento (python) estiveram, em geral, acima das médias fornecidas pelo VISSIM independente dos cenários, entre 0,17 e 0,95 km/h. Avaliando os regimes de fluxo, parece haver uma tendência de redução de  $\Delta_{usv}$  com o aumento da altura de filmagem, excetuando-se o que ocorre entre os cenários 7 e 8 da Figura 28.

No que diz respeito às velocidades instantâneas, as médias de  $\Delta_{uvt}$  (Figura 24) se situam entre 0,15 e 1,10km/h. Pode-se observar que os resultados oriundos das velocidades média e instantânea não têm grande alteração em função do regime de fluxo veicular, entretanto, os cenários variação de velocidade (cenários 7, 8, e 9) apresentaram distribuição mais larga nos valores de  $\Delta_{uvt}$  em comparação com os cenários 1, 2 e 3, podendo ser devido à maior variação das acelerações dos veículos ao longo do percurso. Quanto aos cenários de tráfego interrompido, a velocidade é estimada corretamente quando os veículos param, sendo igual a 0. Isto pode ter contribuído para não aumentar tanto a dispersão dos erros nos cenários 11 e 12.



Fonte: Autor

Figura 29 - Valores médios das diferenças entre as velocidades instantâneas ( $\Delta v_{uv}$ )



Fonte: Autor

Quanto às comparações do tipo B, observou-se que não houve mudança significativa na qualidade dos indicadores, quando comparados os cenários de fluxo livre com os cenários de fluxo interrompido. Acredita-se que grande parte disso se deve às adaptações realizadas no algoritmo para a etapa de agrupamento de pontos, a qual contou com um sistema de memorização das associações de *features* quando estas estavam, outrora, em movimento. Assim, quando os veículos paravam, havia uma identificação dos mesmos separadamente, ainda que estes estivessem com velocidades médias muito semelhantes.

## 5 CONSIDERAÇÕES FINAIS E RECOMENDAÇÕES

A construção de diagramas espaço-tempo com maior precisão e em tempo real permite o desenvolvimento de técnicas mais avançadas de gestão do tráfego, a calibração de modelos de microssimulação de tráfego e a avaliação da segurança viária a partir de conflitos veiculares e perfil de condução dos motoristas. Este trabalho apresentou uma avaliação da qualidade do rastreamento veicular baseado em características considerando diferentes níveis de demanda veicular, regime de fluxo e alturas de filmagem.

O método proposto se baseou em filmagens realizadas em um ambiente de simulação microscópica (VISSIM) o qual permitiu informações precisas a respeito do ambiente de circulação, além de permitir a avaliação de forma controlada de fatores de influência na qualidade. Utilizando as informações de saída do VISSIM (*ground truth*), foram avaliadas as diferenças entre o diagrama espaço-tempo, coordenadas e fluxos veiculares, velocidade média no espaço, velocidades instantâneas e comprimento dos veículos em diferentes cenários.

Numa análise mais abrangente dos 12 cenários, foi constatada uma boa sobreposição de diagramas espaço-tempo gerados a partir do algoritmo e do VISSIM. Foi observado também que o algoritmo não detecta bem a largura dos veículos quando estes estão em direção diagonal e assim, pelos diagramas não é possível avaliar bem o rastreamento quando veículos estão mudando de faixa.

Em relação à contagem volumétrica o algoritmo de rastreamento subestimou a quantidade de veículos gerada pelo microssimulador em quase todos os cenários, se excetuando apenas o cenário 11 de tráfego interrompido.

As diferenças de contagem para o tráfego ininterrupto ficaram entre -3,37% e -1,08% aumentando de forma diretamente proporcional à altura da câmera e não variando significativamente com a mudança no regime de operação ou no fluxo veicular. Quanto ao tráfego interrompido, os erros se situam entre -4,70% e 5,44% sendo maiores que os de tráfego ininterrupto nos cenários de maior altura de câmera. A adaptação da etapa de agrupamento de *features* no algoritmo se mostrou eficiente nos cenários de tráfego interrompido. Quanto às estimativas de  $u_s$  da Tabela 3, o algoritmo gerou estimativas semelhantes ao VISSIM em todos os cenários. As causas em tais diferenças podem estar relacionadas a possíveis distorções na representação da imagem 3D ao longo do percurso e/ou a falhas nas etapas de detecção, rastreamento e/ou agrupamento das características rastreadas (*features*).

Numa análise microscópica da qualidade de rastreamento foram utilizados dois tipos de comparação, tipo A, para verificar a influência do aumento de fluxo nas estimativas dos indicadores e do tipo B, para verificar a influência da mudança de regime de fluxo veicular nas estimativas dos indicadores.

Na comparação tipo A, as diferenças médias dos cenários obtidas pelas diferenças nas estimativas de coordenada dos veículos exportadas pelo algoritmo e pelo VISSIM se situam entre -0,70m e 0,67m. As diferenças médias nas estimativas de comprimento veicular se situam entre -0,27m a 0,11m. Em relação às diferenças entre as velocidades médias no espaço, os resultados indicam valores entre 0,31 e 0,95 km/h, tendo o algoritmo de rastreamento superestimado levemente esse indicador. As diferenças dos erros médios relacionados à velocidade instantânea ficaram entre 0,51 e 1,10km/h, na mesma tendência de leve superestimação pelo algoritmo de rastreamento.

Em relação à dispersão das diferenças de coordenada, os cenários 4, 5 e 6 (alto fluxo) apresentaram comportamento mais homogêneo quando comparados aos outros cenários e a influência do aumento de fluxo veicular diminui conforme aumenta a altura de câmera. A dispersão das diferenças de comprimento veicular, velocidade média e instantânea são aproximadamente as mesmas em todos os cenários.

Observou-se também que as diferenças médias das velocidades média e instantânea não têm grande alteração em função do fluxo. Quanto à variação da altura da câmera, acredita-se que um dos motivos que justifica as diferenças encontradas na velocidade possa estar em possíveis distorções na representação da imagem 3D dos veículos gerada pelo VISSIM ao longo do percurso.

Na comparação tipo B, as diferenças médias dos cenários obtidas pelas diferenças nas estimativas de coordenada dos veículos exportadas pelo algoritmo e pelo VISSIM se situam entre -0,70m e 0,65m. As diferenças médias nas estimativas de comprimento veicular se situam entre -0,85m a 0,11m.

Em relação às diferenças entre as velocidades médias no espaço, os resultados indicam valores entre 0,17 e 0,95 km/h, tendo o algoritmo de rastreamento superestimado levemente esse indicador. Vale ressaltar, entretanto, que em algumas observações  $u_x$  foi subestimada pelo algoritmo. As diferenças dos erros médios relacionados à velocidade instantânea ficaram entre 0,15 e 1,10km/h, na mesma tendência de leve superestimação pelo algoritmo de rastreamento. Pode-se observar que os resultados oriundos das velocidades média e instantânea não têm grande alteração em função do regime de fluxo veicular.

Avaliando os regimes de fluxo, parece haver uma tendência de redução de  $\Delta_{usv}$  com o aumento da altura de filmagem, excetuando-se o que ocorre entre os cenários 7 e 8.

Em relação à dispersão das diferenças de coordenada, os cenários 10, 11 e 12 (regime interrompido) apresentaram comportamento mais homogêneo quando comparados aos outros cenários, principalmente em baixas alturas de câmera. A parada dos veículos presente nesses cenários podem ter feito as diferenças se estabilizarem. Pode-se observar também que as alturas de câmera correspondentes aos trechos de 200m apresentaram, em geral, maior dispersão das diferenças, quando comparado às outras alturas de câmera em cada regime de fluxo.

Em relação à dispersão das diferenças de comprimento, nos três regimes de fluxo, os cenários com maior altura de câmera apresentaram diferenças médias mais afastadas de 0. O regime de fluxo ininterrupto (cenários 1, 2 e 3) apresentou menor dispersão das diferenças do que os outros regimes com redução da velocidade e interrompido.

Em relação à dispersão das diferenças de velocidade média e instantânea, entretanto, os cenários variação de velocidade (cenários 7, 8, e 9) apresentaram distribuição mais larga nos valores de  $\Delta_{uvt}$  em comparação com os cenários 1, 2 e 3, podendo ser devido à maior variação das acelerações dos veículos ao longo do percurso. Quanto aos cenários de tráfego interrompido, a velocidade é estimada corretamente quando os veículos param, sendo igual a 0, podendo ter contribuído para não aumentar tanto a dispersão dos erros nos cenários 11 e 12.

Quanto às comparações do tipo B, observou-se que não houve mudança significativa na qualidade dos indicadores, quando comparados os cenários de fluxo livre com os cenários de fluxo interrompido. É possível que parte disso seja por conta das adaptações realizadas no algoritmo para a etapa de agrupamento de pontos, gerando melhores resultados para os cenários de tráfego interrompido.

Acredita-se que um dos motivos que justifica as diferenças encontradas na coordenada, comprimento veicular e velocidades médias e instantâneas possam estar em possíveis distorções na representação da imagem 3D dos veículos gerada pelo VISSIM ao longo do percurso, também apresentadas na comparação do tipo A. A imagem dos veículos distorce conforme sua localização do segmento de via, e conforme maior for a altura de câmera, a distorção tem tamanho menor, seguindo o tamanho do veículo. Assim, o tamanho das distorções pode explicar o crescimento das diferenças a partir da diminuição na altura de câmera. As diferenças encontradas também podem estar nos modelos matemáticos presentes nas etapas de identificação, rastreamento e/ou agrupamento de *features*.

O VISSIM se mostrou um microssimulador flexível para a criação de cenários tridimensionais. Há ainda outras possibilidades a serem exploradas como a luminosidade em si ou a sua variação com o tempo, a presença de obstáculos, variedade do perfil de cores e tamanhos de veículos, condições de tráfego com a presença de névoa, pedestres, interferência do ângulo de câmera na qualidade de extração de trajetórias veiculares e a compensação do ganho de extensão do trecho a ser capturado mediante a variação do ângulo de câmera, entre outras condições.

Os erros dos trabalhos apresentados na literatura, em geral, não usam os mesmos vídeos, podendo incluir viés de comparação e dificultando a correta avaliação. Além disso, a qualidade da coleta automática de dados microscópicos de tráfego veicular, realizada a partir de vídeos, pode se diferenciar entre cenários de tráfego. Assim, o VISSIM pode se tornar útil para diminuir o viés de comparação de qualidade entre algoritmos para tal finalidade, por permitir a padronização dos métodos de avaliação da qualidade, permitir o controle dos fatores de influência na qualidade e permitir testes em diversos cenários de tráfego.

O uso de imagens do VISSIM contribuiu como uma boa alternativa para ajuste e avaliação do algoritmo, com a possibilidade de análise de dados em larga escala e com uma resolução temporal mais satisfatória que em outros métodos existentes na literatura como os que utilizam dados coletados em campo.

O método de rastreamento utilizado pode ser considerado adequado para a confecção de diagramas espaço-tempo e há um grande potencial para a sua utilização em diferentes mecanismos de controle do fluxo de veículos e diferentes modos de transporte, além de ser uma ferramenta promissora na avaliação do desempenho da segurança viária.

Mais estudos são necessários para aprofundar aspectos inerentes à visão computacional aplicada ao rastreamento veicular, como a verificação da influência da variação do ângulo de câmera, da amplitude de filmagem do trecho ou ainda a influência da heterogeneidade e peculiaridades do tráfego urbano brasileiro na qualidade do rastreamento.

Em relação aos trabalhos futuros, recomenda-se:

- Analisar a influência da variação de luminosidade ambiente na qualidade de rastreamento veicular;
- Analisar a influência da variação do ângulo de câmera na qualidade de rastreamento veicular. A variação do ângulo de câmera é inversamente proporcional à amplitude do trecho filmado. Para uma dada altura fixa de câmera, quanto mais a câmera for ortogonal ao plano do solo, menor é a extensão do trecho filmado e maior a qualidade de extração das trajetórias veiculares, visto que

os veículos não se mostram sobrepostos na imagem. Nem sempre é possível obter um tamanho de trecho razoavelmente bom quando a câmera é ortogonal ao plano do solo, pois para isso seria necessário um posicionamento de câmera bastante alto. Uma leve mudança de ângulo na câmera pode proporcionar uma extensão de trecho maior e com uma qualidade que ainda pode ser considerada boa;

- Propor um método melhor de agrupamento de *features*, que possa considerar suas trajetórias, mecanismos de memorização de agrupamento, mecanismos relacionados ao padrão de movimento dos pontos, tais como a variação do ângulo entre os deslocamentos de *features* ao longo do trecho, e até cor veicular para melhorar os erros falsos positivos. Tais erros ocorrem em veículos que têm as mesmas trajetórias e se encontram próximos uns aos outros no tráfego urbano;
- Investigar a relação entre o ajuste dos parâmetros dos modelos matemáticos e a qualidade do rastreamento veicular;
- Analisar a qualidade de rastreamento de ciclomotores em tráfego urbano;
- Avaliar a qualidade com cenários reais e comparar com os cenários simulados.

## REFERÊNCIAS

- ABDEL-ATY, M.; CUNNINGHAM, R.; GAYAH, V.; HSIA, L. Dynamic Variable Speed Limit Strategies for Real-Time Crash Risk Reduction on Freeways. **Transportation Research Record**, Journal of the Transportation Research Board, Washington, v. 2078, p. 108-116, mai. 2008.
- ARCHER, J. **Indicators for traffic safety assessment and prediction and their application in micro-simulation modelling: A study of urban and suburban intersections**. 2005. Tese de Doutorado, Department of Infrastructure, Royal Institute of Technology, Sweden, 2005.
- ASTARITA, *et al.* **Motorway traffic parameter estimation from mobile phone counts**. *Eur. J. Oper. Res.*, Washington, v. 175, n. 3, p. 1435-1446, 2006.
- AUTEY, J.; S, T.; Z, M. H. Safety evaluation of right-turn smart channels using automated traffic conflict analysis. **Accident Analysis and Prevention**, Canada, v. 45, p. 120–130. 2012. doi:10.1016/j.aap.2011.11.015.
- BAKER, K.; S, G. Performance assessment of model-based tracking. **Proceedings of the IEEE Workshop on Applications of Computer Vision**, Palm Springs, v. 45, p. 28–35, 1992.
- BALLARD, D. H.; BROWN, C. M. **“Computer Vision”**. Prentice Hall. ISBN 0131653164. Ontario: Computational Vision Institute, 1982.
- BEAUCHEMIN, S.; BARRON, J. **The computation of optical flow**. USA. New York: ACM, 1995.
- BOUGUET, J. Y. Pyramidal implementation of the affine lucas kanade feature tracker description of the algorithm. **Intel Corporation**, v. 5, 2001.
- BRADSKI, G.; KAEHLER, A. **Learning Computer Vision with the OpenCV Library**. Sebastopol, California: O'Reilly Media. 2008.
- BROWN, C. M. *Advances in Computer Vision*. Lawrence Erlbaum Associates. 1987. ISBN 0-89859-648-3.
- BURTON, A.; RADFORD, J. **Thinking in Perspective: Critical Essays in the Study of Thought Processes**. Routledge. ISBN 0-416-85840-6. 1978.
- CHEN, B. J.; MEDIONI, G. Motion propagation detection association for multi-target tracking in wide area aerial surveillance. **Advanced Video and Signal Based Surveillance (AVSS)**, 12th IEEE International Conference on, p. 1–6. 2015.
- CHOI, K., Chung, Y. Travel time estimation algorithm using GPS probe and loop detectors data fusion. **Proceeding of the Transportation Research Board**. 80th Annual Meeting, Washington D.C., 2001.

COIFMAN, B.; BEYMER, D.; MCLAUCHLAN, P.; MALIK, J. A Real-time Computer Vision System for Vehicle Tracking and Traffic Surveillance. **Transportation Research. Part C: Emerging Technologies**, v. 6, n. 4, p. 271-288, California, 1998.

COIFMAN, B.; Dhoorjaty, S. Z. H. Lee. Estimating median velocity instead of mean velocity at single loop detectors. **Transp. Res. Part C**, v. 11, n. 3, p. 211-222, 2003.

CUNHA, A. L. **Sistema automático para obtenção de parâmetros do tráfego veicular a partir de imagens de vídeo usando OpenCV**. 2013. Tese de Doutorado, Universidade de São Paulo, 2013.

DAVID, J.; YAIR, W. Optical Flow Estimation. **Paragios**, Handbook of Mathematical Models in Computer Vision, Springer, 2006. ISBN 0-387-26371-3.

FEDERAL HIGHWAY ADMINISTRATION. **A new look at sensors**. Public Roads, US Department of Transportation, v. 71, n. 3, p. 32-3, 2007.

GIBSON, J. **The Perception of the Visual World**. Houghton Mifflin. 1950.

GONZALEZ, R. ; WOODS, R. **Processamento de Imagens Digitais**. Editora Blucher: São Paulo, 509 fl, 2007. ISBN: 85-212-0264-44.

GRABNER, H. *et al.* On-line boosting-based car detection from aerial images. **ISPRS J. Photogramm. Remote Sens.**, v. 63, p. 382-396, 2008.

GUIDO, G. *et al.* Evaluating the accuracy of vehicle tracking data obtained from Unmanned Aerial Vehicles. **International Journal of Transportation Science and Technology**, v. 5, p. 136-151. 2016. doi:10.1016/j.ijtst.2016.12.001.

GUPTE, S. *et al.* Detection and classification of vehicles, **IEEE Transactions on Intelligent Transportation Systems**, vol. 3, n. 1, p. 37-47, Mar. 2002.

HADI, R.; SULONG, G.; GEORGE, L. Vehicle detection and tracking techniques: a concise review. **Signal & Image Processing: An International Journal (SIPIJ)**. v. 5, n. 1, p. 34-42, 2014.

HAOUI, A.; KAVALER R.; VARAIYA P. Wireless magnetic sensors for traffic surveillance. **Transp. Res. Part C**, v. 16, n. 3, p. 294-306, 2008.

HAUER, E.; HAKKERT, A. 1989. **The extent and implications of incomplete accident reporting**. Transportation Research Record: Journal of the Transportation Research Board, 1185:1-10, 9.

HINZA, S. ;U. Stilla. **Car detection in aerial thermal images by local and global evidence accumulation**. Pattern Recognit. Lett., 27 (4) (2006), pp. 308-315

HO, T.J. ; M.J. Chung. **Information-aided smart schemes for vehicle flow detection enhancements of traffic microwave radar detectors** Appl. Sci., 6 (7) (2016), p. 196

HODLMOSER, M.; MICUSIK, B.; POLLEFEYS, M.; LIU, M.; KAMPEL, M. 2013. **Model-Based Vehicle Pose Estimation and Tracking in Videos Using Random Forests**. International Conference on 3D Vision. DOI: 10.1109/3DV.2013.63

HOOSE, N. **Impacts: an image analysis tool for motorway surveillance**. Traffic Engineering and Control, v. 33, n. 3, 1992, p. 140–147.

INTEL (2010). **Open Source Computer Vision Library**. <http://opencv.org/>

ISMAIL, K., SAYED, T., SAUNIER, N., and LIM, C. 2009. **Automated analysis of pedestrian-vehicle conflicts using video data**. Transportation Research Record: Journal of the Transportation Research Board, 2140: 44–54. doi:10.3141/2140-05.

ISMAIL, K.; SAYED, T.; SAUNIER, N. 2010. **Automated analysis of pedestrian vehicle conflicts: Context for before-and-after Studies**. Transportation Research Record: Journal of the Transportation Research Board, 2198: 52–64. doi:10.3141/2198-07.

ISMAIL, K.; SAYED, T.; SAUNIER, N. 2010. **Automated safety analysis using videosensors: technology and case studies**. In: Canadian Multidisciplinary Road Safety Conference, Ontario, Canada.

JUNG, Y. 2001. **Feature-Based Vehicle Tracking Using Trajectory Matching**. IFAC Proceedings, Elsevier Volume 34, Issue 4 Page 263-268.

KANHERE, N.; BIRCHFIELD, S. 2008. **Real-Time Incremental Segmentation and Tracking of Vehicles at Low Camera Angles Using Stable Features**. Intelligent Transportation Systems, IEEE Transactions on, vol. 9, pp. 148-160.

KELSON, R.; AIRES, A.; ADELARDO, A. (2008). **Optical Flow Using Color Information** (PDF). ACM New York, NY, USA. ISBN 978-1-59593-753-7.

KIM, S.W.E., 1998. **Performance comparison of loop/piezo and ultrasonic sensor-based traffic detection systems for collecting individual vehicle information**. In: Proceedings of the 5th World Congress on Intelligent Transport Systems, 4083.

KIM, Zu Whan; Malik, J. **High-quality vehicle trajectory generation from video data based on vehicle detection and description**. Proceedings of the 2003 IEEE International Conference on Intelligent Transportation Systems. 2003. DOI: 10.1109/ITSC.2003.1251944.

KOLLER, D. ;K. Daniilidis, H.H. Nagel. **Model-based object tracking in monocular image sequences of road traffic scenes**. Int. J. Comput. Vis., 10 (3) (1993), pp. 257-281

KOLLER, D. ;J. Weber, J. Malik. **Robust Multiple Car Tracking With Occlusion Reasoning**. ECCV, Stockholm Sweden (1994), pp. 189-196.

KWONG, K. ; R. Kavalier, R. Rajagopal, P. Varaiya. **Arterial travel time estimation based on vehicle re-identification using wireless magnetic sensors.** *Transp. Res. Part C*, 17 (6) (2009), pp. 586-606.

LAURESHYN, A.; GOEDE, M.d.; SAUNIER, N.; FYHRI, A. 2016. **Cross-comparison of three surrogate safety methods to diagnose cyclist safety problems at intersections in Norway.** *Accid. Anal. Prevent.* (in press).

LESSARD, A.; BELISLE, F.; SAUNIER, N. 2016. **The CountingApp, or How to Count Vehicles in 500 Hours of Video.** In *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR) Workshops*, June 2016.

LI, Z. ;X. Yang. **Application of cement-based piezoelectric sensors for monitoring traffic flows.** *J. Transp. Eng.*, 132 (7) (2006), pp. 565-573.

LUCAS, B.; KANADE, T. (1981), **An iterative image registration technique with an application to stereo vision.** *Proceedings of Imaging Understanding Workshop*, pages 121—130

MCGROWEN, P. M. Sanderson. **Accuracy of pneumatic road tube counters.** 2011. *Western District Annual Meeting, Institute of Transportation Engineers* (2011).

MAHMUD, S.; FERREIRA, L.; HOQUE, Md.; TAVASSOLI, A. 2016. **Application of proximal surrogate indicators for safety evaluation: A review of recent developments and research needs.** *IATSS Research*, <https://doi.org/10.1016/j.iatssr.2017.02.001>.

MONDAL, A.; GHOSH, S.; GHOSH, A. (2014) **Efficient silhouette-based contour tracking using local information.** *Soft Computing*, v.20, Issue 2, p. 785-805.

NOORALAHYAN, A.Y. ; H.R. Kirby, D. McKeown **Vehicle classification by acoustic signature**  
*Math. Comput. Modell.*, 27 (9–11) (1998), pp. 205-214

OH, J., Min, J., Kim, M., Cho, H., 2009. **Development of an automatic traffic conflict detection system based on image tracking technology.** In: *Proceedings of the Transportation Research Board 88th Annual Meeting*, Washington D.C.

OSKARBSKI, J.; KASZUBOWSKI, D. (2016). **Implementation of Weigh-in-Motion System in Freight Traffic Management in Urban Areas.** *Transportation Research Procedia* 16. p. 449-463.

PERKINS, S.; HARRIS, J.(1968) **Traffic Conflict Characteristics –Accident Potential at Intersections.** *Highway. Research Record*, No. 225, p 35-43.

POLK, A.E. ;M.C. Pietrzyk. **The Miami method: using automatic vehicle location (AVL) for measurement of roadway level-of-service.** *Proceedings of the Annual Meeting of ITS America*, vol. 1, *Intelligent Transportation Society of America*, Washington D.C. (1995)

ROESS, R.P., Prassas, E.S., McShane, W.R., Traffic Engineering. Fourth Edition. Pearson 2011.

ROYDEN, C.; MOORE, K. (2012). "**Use of speed cues in the detection of moving objects by moving observers**". *Vision Research*.59: 17–24. doi:10.1016/j.visres.2012.02.006.

SAUNIER, N., MOURJI, N., AGARD, B. 2011. **Mining microscopic data of vehicle conflicts and collisions to investigate collision factors**. *Transportation Research Record: Journal of the Transportation Research Board*, 0117: 41–50.

SAUNIER, Nicolas; Sayed, Tarek; Ismail, Karim. 2010. **Large-Scale Automated Analysis of Vehicle Interactions and Collisions**. *Transportation Research Record: Journal of the Transportation Research Board*. List of Issues, Volume 2147. DOI: 10.3141/2147-06.

SAUNIER, N.; SAYED, T. 2007. **Automated analysis of road safety with video data**. *Transportation Research Record: Journal of the Transportation Research Board*, 2019: 57–64. DOI:10.3141/2019-08.

SAYED, T., ZAKI, M., AUTEY, J. 2013. **Automated safety diagnosis of vehicle bicycle interactions using computer vision analysis**. *Safety Science*, 59: 163–172. doi:10.1016/j.ssci.2013.05.009

SCHLOSSER, C., Reitberger, J., Hinz, S., 2003. **Automatic car detection in high resolution urban scenes based on an adaptive 3D-model**. In: *EEE/ISPRS Joint Workshop on Remote Sensing and Data Fusion over Urban Areas*, Berlin, pp. 98–107.

SHI, J.; TOMASI, C. "**Good features to track**", *Proc. IEEE Comput. Soc. Conf. Computational Vision and Pattern Recogn.*, pages 593–600, 1994.

SMALLEY, D.O. ; D.R. Hickman, W.R. McCasland. **Design and Implementation of Automatic Vehicle Identification Technologies for Traffic Monitoring in Houston, Texas, Draft Report TX-97-1958-2F**. Texas Transportation Institute, College Station, Texas (1996)

SONG, K.T.; CHEN, C. H.; HUANG, C. H. C. Design and experimental study of an ultrasonic sensor system for lateral collision avoidance at low speeds. **IEEE Intelligent Vehicles Symposium**, p. 647-652, 2004.

SUBIRATS, P; GOYATB, Y.; JACOBC, B.; VIOLETTA, E. A New Road Safety Indicator Based on Vehicle Trajectory Analysis. **Transportation Research Procedia**, v. 14, p. 4267-4276. 2016.

SUMMER, R.; Smith, R.; Kennedy, J.; Robinson, J. Cellular based traffic surveillance. the Washington, D.C. Area operational test. **Proceeding of the IVHS America Annual Meeting**, Washington D.C, v. 2, 1994.

TAGELDIN, A.; MOHAMED, H.; SAYED, T. Examining pedestrian evasive actions as a potential indicator for traffic conflicts. **IET Intelligent transport systems**, v. 11 n. 5, p. 282–289, 2017. doi:10.1049/iet-its.2016.0066.

TYAGI, V.; KALYANARAMAN, S.; KRISHNAPURAM, R. Vehicular traffic density state estimation based on cumulative road acoustics. **IEEE Trans. Intell. Transp. Syst.**, v. 13, n. 3, p. 1156-1166, 2012.

VAIDYA, N.; HIGGINS, L. L., TURNBULL, K. F. An evaluation of the accuracy of a radio trilateration automatic vehicle location system. **Proceedings of the Annual Meeting of ITS America**, Intelligent Transportation Society of America, Washington D.C, 1996.

WOOTTON, J. R.; GARCÍA-ORTIZ, A.; AMIN, S. M. Intelligent Transportation Systems: a global perspective. **Math Computing Modelling**, v. 22, n. 4, p. 259-268, 1995.

WORRAL, A. D.; SULLIVAN, G. D.; BAKER, K. D; A simple intuitive camera calibration tool for natural images. **Proceedings of Conference British Machine Vision**. Canada, v. 2. p. 781-790, 1994.

XU, Hao; LIU, H.; GONG, H. Modeling the asymmetry in traffic flow: Microscopic approach. **Applied Mathematical Modelling**. v. 37, n. 22, 15 p. 9431-9440, nov. 2013, <https://doi.org/10.1016/j.apm.2013.04.037>.

YAGHOUBI, E. N. Improving vehicle tracking rate and speed estimation in dusty and snowy weather conditions with a vibrating camera. **PLoS ONE**, v. 12, n. 12, p. 12-13, 2017. <https://doi.org/10.1371/journal.pone.0189145>.

YIM, Y. B.; CAYFORD, R. Investigation of Vehicles as Probes Using Global Positioning system and Cellular Phone Tracking: Field Operational Test. **California PATH Working Paper**, University of Berkeley, Berkley California, v. 1, n. 12, p. 12-19, 2001.

ZWAHLEN, H. T. *et al.* Evaluation of microwave radar trailers for nonintrusive traffic measurements. **Transp. Res. Rec.**, v. 1917, n. 1, p. 127-140, 2005.

ZHANG, G.; AVERY R. P.; WANG, Y. Video-based vehicle detection and classification system for real-time traffic data collection using uncalibrated video cameras. **Transp. Res. Rec.**, v. 19, n. 1, p. 135-154, 2017.

ZHAO, D.; DAI, Y.; ZHANG, Z. Computational intelligence in urban traffic signal control: A survey. **IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)**. v. 42, n. 4, p. 485-494, 2012.

## ANEXO A - QUADRO DE INDICADORES BASEADOS NO TEMPO

Indicador	Limitações	Vantagens	Tipos de conflitos adequados
TTC - Tempo para colisão - O tempo até uma colisão entre os veículos ocorrer se eles continuassem em seu curso atual em suas velocidades atuais.	Supõe que veículos consecutivos manterão velocidades constantes; Ignora muitos conflitos potenciais devido a discrepâncias de aceleração ou desaceleração; Pode fornecer a proximidade dos acidentes, mas não a sua gravidade; O curso de colisão deve existir, o índice TTC não pode ser estimado em um número finito onde o veículo principal é mais rápido do que o seguidor.	TTC é muito mais utilizado na prática do que PET ou TA devido a problemas teóricos; TTC foi mais informativo do que o PET; Muitos sistemas de prevenção de colisão de automóveis ou sistemas de assistência ao motorista usaram o TTC como um critério de alerta importante; Aplicável para a análise de segurança da Zona de Trabalho, aplicável em pós-processador, como o SSAM	Traseira, em conversão, em veículo estacionado, transversais e colisões com pedestres
TET - Tempo exposto ao TTC - Soma de todos os momentos (durante o período de tempo considerado) que um motorista se aproxima de um veículo dianteiro com um valor TTC abaixo do valor limite.	Não fornece os níveis de variação de severidade de diferentes valores TTC abaixo do valor limiar; Se o valor TTC for inferior ao limite, não afetará o valor do indicador TET; Altamente intensivo no uso de dados.	Pode ser calculado separadamente por classe de usuário, pode ser aplicado na comparação de um caso de “ <i>do-nothing</i> ” com uma situação adaptada; Adequado para aplicação em estudos de simulação ou coleta semiautomática; Fácil de incluir pequeno valor TTC devido à inclusão de valores TTC dependentes do tempo.	Mesmos que o TTC
TIT - Tempo de TTC integrado - Soma dos TTCs durante o tempo que está abaixo do limite estipulado	Não é preferível utilizar em estudos comparativos nos quais ferramentas são aplicadas para gerar trajetórias; Os benefícios são pequenos devido às incertezas no comportamento do motorista.	O nível de segurança da colisão pode ser derivado; Pode ser aplicado na comparação de um caso de “ <i>do-nothing</i> ” com uma situação adaptada; adequado para estudos de coleta semiautomática; Fácil de incluir pequeno valor TTC devido à inclusão de valores TTC dependentes do tempo.	Mesmos que o TTC
MTTC - Tempo de colisão modificado - Modelos modificados que consideraram todos os possíveis cenários longitudinais de conflito devido a discrepâncias de aceleração ou desaceleração	Não é adequado para mudança de faixa ou colisão frontal; Não reflete a gravidade da colisão.	Mais avançado do que o TTC; Considera discrepâncias de condução; A gravidade da colisão pode ser ponderada usando indicadores de CI.	Acidentes veículo a veículo; Mesmos que o TTC

Indicador	Limitações	Vantagens	Tipos de conflitos adequados
CI - Índice de acidente - Influência da velocidade na energia cinética envolvida em colisões.	Descreve apenas as informações de segurança sobre dois veículos em determinado momento e local. Não é adequado para mudança de faixa ou colisão frontal.	Reflete a gravidade de um potencial acidente; descreve a influência da velocidade na energia cinética envolvida em colisões; Considera o tempo decorrido antes da ocorrência do conflito; A gravidade e a probabilidade de um conflito potencial podem ser interpretadas.	Mesmos que o MTTC
<i>Hedway</i> (H) - O tempo decorrido entre a frente do veículo principal que passa um ponto na estrada e a frente do veículo seguinte que passa pelo mesmo ponto	Aplicável principalmente em conflitos para colisões longitudinais no ambiente de tráfego; Não leva em consideração conflitos devido a movimentos laterais, especialmente durante a mudança ou ultrapassagem da faixa.	Fácil de medir; O nível de segurança pode ser distinguido.	Parte traseira principalmente, em conversão e colisão com veículo estacionado.
<i>Time to Accident</i> (TA) - Tempo para acidente (TA) é o tempo que resta para um acidente desde o momento em que um dos usuários da estrada começa uma ação evasiva se eles tivessem continuado com velocidade e direções inalteradas	Muitas vezes criticado por confiar fortemente no julgamento subjetivo de velocidade e distância. Dependem principalmente da ação evasiva. O mesmo que o TTC	Amplamente utilizado; Fácil de medir; Pode ser feito manualmente ou por análise de vídeo. Manuais foram desenvolvidos em diferentes países.	Mesmos que o TTC
Tempo pós-invasão (PET) - O tempo entre o momento em que um usuário da estrada (veículo) deixa a área de colisão potencial e o outro usuário da estrada chega à área de colisão.	Único útil no caso de trajetórias transversais (isto é, cruzamento) (colisão de ângulo à direita); Não é possível refletir as mudanças com a dinâmica de eventos críticos de segurança em uma área maior; Os níveis de gravidade, bem como o impacto de um conflito não são levados em consideração;	PET é mais apropriado do que o TTC para trajetórias que se cruzam; O PET pode ser facilmente extraído; Os PETs podem ser facilmente estimados usando análise fotométrica em vídeo ou ambiente simulado; PET representa os comportamentos do motorista.	Principalmente para conflitos transversais ou em ângulo, conflitos com pedestres.

## ANEXO B - QUADRO DE INDICADORES BASEADOS EM DISTÂNCIA

Indicador	Limitações	Vantagens	Tipos de conflitos adequados
Índice Potencial de Colisão com Desaceleração Urgente (PICUD) - Distância entre dois veículos considerada apenas quando estes param completamente	Aplicável principalmente em condição de mudança de faixa quando o veículo principal aplica uma frenagem de emergência; Valor limiar ainda não definido; Não toma em consideração conflitos laterais.	PICUD é mais adequado do que TTC para avaliar o perigo de colisão dos veículos consecutivos com velocidades semelhantes. A PICUD pode detectar a mudança nas condições de trânsito e os conflitos de forma mais sensível que o TTC.	Mesmos que o TTC
Proporção de Distância de Parada (PSD) - Relação entre a distância restante ao ponto potencial de colisão e a distância de parada mínima aceitável	Com base em ações evasivas; O PSD fornece maior porcentagem de interação de veículos e exposição ao tempo em conflito do que TTC e DRAC, portanto, menos foco em problemas de segurança específicos.	O conflito de veículo único com objetos fixos ou não fixos pode ser avaliado; Fácil de observar e calcular.	Acertar objeto (no lado da estrada ou da estrada), derrubando-o.
Margem para colisão (MTC) - Relação do somatório da distância entre veículos e a distância de parada do veículo anterior dividida pela distância de parada do veículo a seguir.	Igual à distância de parada. Além disso, não considera um atraso de resposta do veículo à frente. Um parâmetro não dimensional.	Igual à distância de parada. Ele também oferece a possibilidade de conflito quando precedendo e seguindo um veículo, ao mesmo tempo, desacelera-se abruptamente.	Igual à distância de parada.
Nível de densidade insegura (DU) - Nível de "insegurança" na relação entre dois veículos consecutivos na estrada por unidade de tempo.	O valor deste parâmetro realmente não tem um sentido em si mesmo e deve ser usado apenas para fins de comparação; adequado apenas para a análise de colisão traseira (trajetória idêntica).	Dá informações precisas; Estudo comparativo entre link pode ser feito.	Traseira, mudança de faixa.
Diferença de distância de parada e espaçamento (DSS) - DSS é definido pelo espaçamento e distância de parada.	Fornecer informações sobre o número de veículos inseguros, mas não considera o grau de perigo, bem como a duração.	A fórmula de cálculo e o valor do limiar perigoso são simples e claros.	Traseira, acertar objetos
DSS integrado ao tempo (TIDSS) - Valor total do intervalo de valores integrados de tempo entre DSS e o valor limiar perigoso.	Principalmente adequado para conflitos traseiros.	Considera o grau e a duração do perigo.	Mesmos que o DSS

### ANEXO C - QUADRO DE INDICADORES BASEADOS EM DESACELERAÇÃO

Indicador	Limitações	Vantagens	Tipos de conflitos adequados
Taxa de desaceleração para evitar o acidente (DRAC) - Velocidade diferencial entre o veículo seguinte / resposta e o respectivo veículo sujeito / principal (SV) dividido pelo tempo	Não consegue identificar com precisão a situação potencial de conflito de trânsito; Não é adequado para movimento lateral.	Considera explicitamente o papel das velocidades diferenciais e das desacelerações no fluxo de tráfego.	Traseira, veículo estacionado, colisão com pedestre e manobras divergentes.
Índice de Potencial de Crash (CPI) - Probabilidade de que um dado DRAC do veículo exceda a sua taxa de desaceleração máxima disponível (MADR) durante um determinado intervalo de tempo.	Não é adequado para movimentos laterais; aplicável principalmente na interseção.	Abordar algumas das questões encontradas na DRAC como a capacidade de frenagem do veículo para as condições vigentes da estrada e do tráfego.	O mesmo que a DRAC.
Criticality Index Function (CIF) - Multiplicação da velocidade do veículo com a desaceleração requerida	Como TTC, considera a velocidade constante do veículo consecutivo; Uma avaliação adicional é necessária usando dados de campo para validação.	A possibilidade de ocorrência e gravidade pode ser medida.	Conversões, em ângulo à direita.
<i>Extended</i> Delta-V - Diferença entre a velocidade inicial no momento da manobra evasiva e a velocidade no momento da possível colisão.	Presença de subjetividade ao assumir uma desaceleração com que os veículos se aproximam	Consegue integrar proximidade temporal ao acidente com a sua severidade	Mesmos que o TTC

## ANEXO D - QUADRO DE RESULTADOS EXPORTADOS PELO ALGORITMO

ID	Velocidade média	Velocidade Instantânea	Quadro	X frente	Y frente	X Traseira	Y Traseira	Faixa	Líder	Seguidor	Espacamento
0	50.59435113	50.78424922	308	8.045791656	9.469031548	2.967823938	7.859378637	3	X	X	X
0	50.52540801	50.71858237	311	9.469994833	9.488541211	4.251861203	7.864206891	3	X	X	X
0	50.63017912	50.82419749	314	10.85785267	9.496433051	5.705430157	7.86938926	3	X	X	X
0	50.591878	50.58933901	317	12.28714507	9.614920062	7.124086868	7.873858962	3	X	X	X
0	50.67285937	50.96776212	320	13.67956649	9.784147721	8.550526375	7.872345651	3	X	X	X
0	50.76216409	51.07072179	323	15.11452845	9.790064198	9.985052153	7.884193391	3	X	X	X
0	50.68869883	50.94702783	326	16.49418321	9.796629765	11.42949319	7.872687199	3	X	X	X
0	50.79718745	51.17033038	329	17.93389431	9.801860188	12.88303257	7.871623372	3	X	X	X
0	50.87552284	51.25338808	332	19.37723825	9.802135201	14.33663036	7.874413424	3	X	X	X
0	50.79999651	51.20817705	335	20.7490167	9.799979454	15.77972885	7.870609816	3	X	X	X
0	50.88052084	51.21385448	338	22.19532368	9.797975999	17.20805057	7.867667472	3	X	X	X
0	50.94025745	51.22078065	341	23.6401728	9.781342883	18.65320575	7.886516216	3	X	X	X
0	50.91467673	51.44996693	344	25.05078279	9.794764556	20.09309133	7.874714312	3	X	X	X
0	50.95680296	51.33830636	347	26.47734058	9.78418986	21.54661223	7.883178356	3	X	X	X
0	51.02530285	51.47924598	350	27.92088708	9.787378385	22.99664224	7.890389317	3	X	X	X
0	51.06312774	51.90446173	353	29.36316793	9.784802725	24.45015722	7.916576918	3	X	X	X
0	51.09074488	51.89444729	356	30.80213384	9.785236684	25.90363673	7.868346872	3	X	X	X
0	51.07903188	51.42037954	359	32.2018202	9.784769457	27.37261454	7.869751509	3	X	X	X
0	51.12322739	51.52393714	362	33.6549064	9.783043233	28.83421432	7.867717004	3	X	X	X
0	51.16856597	51.71331658	365	35.1077442	9.783060976	30.32264118	7.877169469	3	X	X	X

## ANEXO E – PARÂMETROS DE SEGMENTAÇÃO E DETECÇÃO DE PONTOS

Nº	Parâmetro	Amplitude	Default	Origem do parâmetro	Relevância	Significado
1	threshold	0 - 255	40	OpenCV	baixa	variável limite de tolerância das diferenças de intensidade do pixel para segmentação
2	detect_interval	$\geq 1$	2	Algoritmo	alta	determina a periodicidade da detecção de novos pontos
3	NMaxFeaturesAScreen	$\geq 4$	1000	Algoritmo	alta	Número máximo de features presentes na tela
4	maskball	$\geq 1$	10	Algoritmo	alta	tamanho da região próxima a um ponto onde não será permitida a detecção de novos pontos
5	maxCorners	$\geq 4$	2000	OpenCV	alta	Número máximo de cantos para retornar. Se houver mais cantos do que os encontrados, os mais fortes deles são retornados. maxCorners $\leq 0$ implica que nenhum limite no máximo é definido e todos os cantos detectados são retornados. Proveniente da função cv2.goodfeaturesToTrack
6	qualityLevel	$0 < Q \leq 1$	0.0001	OpenCV	alta	Parâmetro que caracteriza a qualidade mínima aceita dos cantos da imagem. O valor do parâmetro é multiplicado pela melhor medida de qualidade de canto, que é o autorvalor mínimo ou a resposta da função Harris. Os cantos com a medida de qualidade inferior ao produto são rejeitados. Por exemplo, se o melhor canto tiver a medida de qualidade = 1500 e o QualityLevel = 0.01, todos os cantos com a medida de qualidade inferior a 15 são rejeitados.
7	minDistance	$\geq 1$	20	OpenCV	alta	distância mínima entre as features, em pixels
8	blockSize	$\geq 1$	3	OpenCV	alta	tamanho do bloco de pesquisa
9	useHarrisDetector	0 ou 1	0	OpenCV	baixa	booleana 0 - desativado e 1 - ativado
10	k	$\geq 0$	0,04	OpenCV	baixa	parâmetro de ajuste

### TIPOS DE PARÂMETROS

#### Parâmetros de Segmentação - Background

Parâmetros de Detecção de Features

## ANEXO F – PARÂMETROS DE RASTREAMENTO E AGRUPAMENTO

Nº	Parâmetro	Amplitude	Default	Origem do parâmetro	Relevância	Significado
11	<i>winSizeY</i>	≥=3	21	<i>OpenCV</i>	alta	Parâmetros do Lucas-Kanade - Algoritmo de Rastreamento das features - Optical flow
12	<i>winSizeY</i>	≥=3	21	<i>OpenCV</i>	alta	y da janela
13	<i>maxLevel</i>	≥=1	3	<i>OpenCV</i>	alta	número de subdivisões da região de interesse (para features vazias)
14	<i>criteria3</i>	≥=1	30	<i>OpenCV</i>	média	(c2,TERM _CRITERIA_COUNT   c2,TERM _CRITERIA_EPS, 100, 0.03)
15	<i>criteria4</i>	0<C<=1	0.01	<i>OpenCV</i>	média	parâmetro limite para loop de verificação de features
16	<i>GoodFeaturesLimit</i>	0<G<=1	10	Algoritmo	média	parâmetro limite de identificação do rastro das features
17	<i>track_len</i>	≥=2		Algoritmo	baixa	Neste caso utiliza os últimos 100 frames para estimar a velocidade média das features para agrup (média móvel)
18	<i>DeltaXILimit_Group</i>	≥=1	100	Algoritmo	média	limite máximo de agrupamento de duas features em x
19	<i>DeltaYLimit_Group</i>	≥=1	40	Algoritmo	média	limite máximo de agrupamento de duas features em y
20	<i>SuplLimitRelativeVel</i>	≥=0	0.05	Algoritmo	média	critério de similaridade de velocidade entre features 5%
21	<i>InfLimitRelativeVel</i>	≤=0	-0.05	Algoritmo	média	critério de similaridade de velocidade entre features 5%
22	<i>SuplLimitAbsoluteVel</i>	≥=0	0.2	Algoritmo	média	critério de similaridade de velocidade absoluta
23	<i>InfLimitAbsoluteVel</i>	≤=0	-0.2	Algoritmo	média	critério de similaridade de velocidade absoluta
24	<i>InclinationLimit</i>	>0	0.12	Algoritmo	média	critério (angular) para não agrupar veículos em faixas diferentes
25	<i>InclinationDist</i>	>0	0.5	Algoritmo	alta	critério para não agrupar veículos em faixas diferentes
26	<i>MaxPointsRectedInGroup</i>	≥=0	5	Algoritmo	alta	número mínimo de pontos para formar um agrupamento. Pode ser importante em função da altura da câmera

### TIPOS DE PARÂMETROS

*Parâmetros de Rastreamento de Features*

*Parâmetros de Agrupamento de Features*

**ANEXO G – VALORES DOS PARÂMETROS PARA OS CENÁRIOS PROPOSTOS**

Nº do Parâmetro	Cenário 1	Cenário 2	Cenário 3	Cenário 4	Cenário 5	Cenário 6	Cenário 7	Cenário 8	Cenário 9	Cenário 10	Cenário 11	Cenário 12
	500vph/ft/recho de 50m	500vph/ft/recho de 100m	500vph/ft/recho de 200m	1000vph/ft/recho de 50m	1000vph/ft/recho de 100m	1000vph/ft/recho de 200m	RV/500vph/ft/recho de 50m	RV/500vph/ft/recho de 100m	RV/500vph/ft/recho de 200m	INT/500vph/ft/recho de 50m	INT/500vph/ft/recho de 100m	INT/500vph/ft/recho de 200m
1	40	40	40	40	40	40	40	40	40	40	40	40
2	1	1	1	1	1	1	1	1	1	1	1	1
3	200	3500	3000	200	350	500	200	280	500	200	280	500
4	10	10	10	10	10	5	19	10	9	19	10	5
5	200	380	200	3000	3000	3000	3000	3000	3000	3000	3000	3000
6	0,0001	0,0001	0,0001	0,0001	0,0001	0,0001	0,0001	0,0001	0,0001	0,0001	0,0001	0,0001
7	20	15	20	20	20	20	20	20	10	20	15	10
8	2	4	2	2	2	2	8	2	10	8	9	10
9	1	1	1	1	1	1	1	1	1	1	1	1
10	0,04	0,04	0,04	0,04	0,04	0,04	0,04	0,04	0,04	0,04	0,04	0,04
11	10	10	10	10	10	10	10	10	10	10	10	10
12	10	10	10	10	10	10	10	10	10	10	10	10
13	10	5	10	10	5	5	10	5	5	10	5	5
14	200	250	200	200	200	200	200	200	200	200	200	200
15	0,0001	0,0001	0,0001	0,0001	0,0001	0,0001	0,0001	0,0001	0,0001	0,0001	0,0001	0,0001
16	10	15	10	15	15	15	10	10	20	10	10	20
17	50	50	50	50	50	50	50	50	50	50	50	50
18	120	180	36	120	180	100	120	100	40	120	100	40
19	20	20	12	20	20	15	20	20	20	20	20	20
20	0,07	0,05	0,05	0,07	0,05	0,03	0,07	0,05	0,05	0,05	0,05	0,05
21	-0,07	-0,05	-0,05	-0,07	-0,05	-0,03	-0,07	-0,05	-0,05	-0,05	-0,05	-0,05
22	0,5	0,1	0,1	0,5	0,1	0,1	0,05	0,1	0,5	0,05	0,1	0,5
23	-0,5	-0,1	-0,1	-0,5	-0,1	-0,1	-0,05	-0,1	-0,5	-0,05	-0,1	-0,5
24	0,2	0,12	0,3	0,2	0,2	0,07	0,2	0,1	0,2	0,2	0,2	0,2
25	0,5	0,7	0,2	0,5	0,7	0,1	0,5	0,7	0,4	0,5	0,5	0,5
26	7	3	5	7	3	5	7	3	4	7	3	2

## ANEXO H – VALORES DE TESTE ADOTADOS EM CADA PARÂMETRO

N°	Parâmetro	Origem do parâmetro	Valores de Teste		
			Limite Inf.	Default	Limite Sup.
2	<i>detect_interval</i>	Adaptado	1	2	4
3	<i>NMaxFeaturesAtScreen</i>	Adaptado	500	1000	2000
4	<i>maskball</i>	Adaptado	5	10	20
5	<i>maxCorners</i>	OpenCV	500	1000	2000
6	<i>qualityLevel</i>	OpenCV	0.00005	0.0001	0.0002
7	<i>minDistance</i>	OpenCV	10	20	40
8	<i>blockSize</i>	OpenCV	2	3	6
11	<i>winSizeX</i>	OpenCV	11	21	41
12	<i>winSizeY</i>	OpenCV	11	21	41
13	<i>maxLevel</i>	OpenCV	2	3	6
14	<i>criteria3</i>	OpenCV	15	30	60
15	<i>criteria4</i>	OpenCV	0.005	0.01	0.02
16	<i>GoodFeaturesLimit</i>	Adaptado	5	10	20
18	<b>DeltaXLimit_Group</b>	Adaptado	<b>50</b>	<b>100</b>	<b>200</b>
19	<b>DeltaYLimit_Group</b>	Adaptado	<b>20</b>	<b>40</b>	<b>80</b>
20	<b>SupLimitRelativeVel</b>	Adaptado	<b>0.025</b>	<b>0.05</b>	<b>0.1</b>
21	<b>InfLimitRelativeVel</b>	Adaptado	<b>-0.025</b>	<b>-0.05</b>	<b>-0.1</b>
22	<b>SupLimitAbsoluteVel</b>	Adaptado	<b>0.1</b>	<b>0.2</b>	<b>0.4</b>
23	<b>InfLimitAbsoluteVel</b>	Adaptado	<b>-0.1</b>	<b>-0.2</b>	<b>-0.4</b>
24	<b>InclinationLimit</b>	Adaptado	<b>0.06</b>	<b>0.12</b>	<b>0.24</b>
25	<b>InclinationDist</b>	Adaptado	<b>0.25</b>	<b>0.5</b>	<b>1</b>
26	<b>MaxNpointsRejectLikeGroup</b>	Adaptado	<b>3</b>	<b>5</b>	<b>10</b>

## ANEXO I – ANÁLISE DOS ERROS OBTIDOS PELA ALTERAÇÃO DOS VALORES

ERROS PERCENTUAIS CORRESPONDENTES AOS RESPECTIVOS VALORES DE TESTE									
Cenário	Cenário 10 - 50 METROS - contagem			Cenário 11 - 100 METROS - contagem			Cenário 12 - 200 METROS - contagem		
	Limite Inf.	Default	Limite Sup.	Limite Inf.	Default	Limite Sup.	Limite Inf.	Default	Limite Sup.
2	-14%	-17%	-27%	-48%	-49%	-62%	-83%	-72%	-83%
3	-17%	-17%	-17%	-51%	-49%	-49%	-80%	-72%	-72%
4	-16%	-17%	-37%	-43%	-49%	-58%	-70%	-72%	-75%
5	-17%	-17%	-17%	-49%	-49%	-49%	-72%	-72%	-72%
6	-18%	-17%	-17%	-51%	-49%	-49%	-86%	-72%	-72%
7	-14%	-17%	-34%	-42%	-49%	-53%	-63%	-72%	-79%
8	-18%	-17%	-20%	-49%	-49%	-66%	-73%	-72%	-72%
11	-34%	-17%	-10%	-64%	-49%	-34%	-86%	-72%	-61%
12	-21%	-17%	-67%	-29%	-49%	-86%	-48%	-72%	-85%
13	-66%	-17%	-17%	-49%	-49%	-49%	-72%	-72%	-72%
14	-24%	-17%	-14%	-50%	-49%	-50%	-67%	-72%	-73%
15	-18%	-17%	-19%	-50%	-49%	-50%	-71%	-72%	-73%
16	-19%	-17%	-17%	-51%	-49%	-41%	-85%	-72%	-69%
18	-17%	-17%	-11%	-52%	-49%	-45%	-77%	-72%	-65%
19	-17%	-17%	-32%	-33%	-49%	-49%	-73%	-72%	-72%
20	-18%	-17%	-18%	-49%	-49%	-49%	-73%	-72%	-70%
21	-16%	-17%	-17%	-50%	-49%	-49%	-73%	-72%	-72%
22	-18%	-17%	-17%	-49%	-49%	-49%	-72%	-72%	-71%
23	-18%	-17%	-17%	-50%	-49%	-49%	-73%	-72%	-72%
24	-17%	-17%	-17%	-53%	-49%	-48%	-73%	-72%	-68%
25	-17%	-17%	-20%	-49%	-49%	-55%	-72%	-72%	-74%
26	-12%	-17%	-26%	-42%	-49%	-63%	-69%	-72%	-77%
Média das diferenças absolutas entre o erro default e cada limite (Inferior e superior) por cenário									
	50m	100m	200m	50m	100m	200m	50m	100m	200m
	6,3%	7,3%	11,0%	0,3%	0,9%	4,0%	10,5%	7,6%	2,5%
	0,3%	0,3%	0,0%	0,3%	0,3%	0,0%	0,6%	0,9%	6,7%
	10,1%	5,6%	7,7%	1,7%	8,6%	0,4%	11,9%	15,4%	12,3%
	27,0%	28,3%	18,4%	24,8%	0,3%	0,0%	4,9%	0,8%	2,7%
	1,3%	0,8%	0,7%	1,2%	5,2%	7,7%	1,2%	5,2%	7,7%
	3,2%	3,3%	5,6%	7,6%	8,5%	0,4%	0,9%	0,3%	1,3%
	0,9%	0,3%	0,8%	0,8%	0,7%	0,8%	0,3%	0,0%	0,7%
	0,3%	0,0%	0,7%	0,5%	0,4%	0,1%	0,1%	2,3%	2,5%
	1,6%	3,1%	1,0%	6,8%	10,3%	4,2%			
Gráficos das variações dos erros em cada cenário									
	50m	100m	200m	50m	100m	200m	50m	100m	200m