



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
ENGENHARIA CIVIL
DEPARTAMENTO DE ENGENHARIA DE TRANSPORTES

JOSÉ LUCAS MESQUITA FROTA

ANÁLISE COMPARATIVA DE ALGORITMOS DE VISÃO COMPUTACIONAL
APLICADOS A CONTAGENS VOLUMÉTRICAS EM ÁREA URBANA

FORTALEZA

2017

JOSÉ LUCAS MESQUITA FROTA

ANÁLISE COMPARATIVA DE ALGORITMOS DE VISÃO COMPUTACIONAL
APLICADOS A CONTAGENS VOLUMÉTRICAS EM ÁREA URBANA

Monografia apresentada ao Curso de Engenharia Civil da Universidade Federal do Ceará como requisito parcial para obtenção do Título de Engenheiro Civil.

Orientador: Prof. Dr. Flávio José Craveiro Cunto

FORTALEZA

2017

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)

F961a Frota, José Lucas Mesquita.

Análise Comparativa de Algoritmos de Visão Computacional aplicados a Contagens Volumétricas em Área Urbana / José Lucas Mesquita Frota. – 2017.

65 f. : il. color.

Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Centro de Tecnologia, Curso de Engenharia Civil, Fortaleza, 2017.

Orientação: Prof. Dr. Flávio José Craveiro Cunto.

1. Estudos de Tráfego.. 2. Contagens Volumétricas.. 3. Visão Computacional. 4. Rastreamento Veicular. 5. Características. I. Título.

CDD 620

JOSÉ LUCAS MESQUITA FROTA

ANÁLISE COMPARATIVA DE ALGORITMOS DE VISÃO COMPUTACIONAL
APLICADOS A CONTAGENS VOLUMÉTRICAS EM ÁREA URBANA

Monografia apresentada ao Curso de Engenharia Civil da Universidade Federal do Ceará como requisito parcial para obtenção do Título de Engenheiro Civil.

Aprovado em: _____

BANCA EXAMINADORA

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

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

Prof. D. Sc. Rafael Perazzo Barbosa Mota
Universidade Federal do Cariri (UFCA)

À minha família: meus pais, avós, irmão e namorada, pelo apoio e confiança que sempre depositaram em mim ao longo dessa jornada.

AGRADECIMENTOS

Ao meu orientador Prof. Dr. Flávio José Craveiro Cunto, pela oportunidade que me deu, pela orientação e pelos ensinamentos.

Ao Johny e ao Matheus, que me ajudaram bastante com a concretização desse trabalho.

A todos os amigos que fiz ao longo dos meses no Grupo de Pesquisa em Transporte, Trânsito e Meio Ambiente (GTTEMA).

RESUMO

O acelerado crescimento urbano e o dinamismo dos sistemas de transportes tornam necessária a busca por novas ferramentas de gestão de tráfego, caracterizadas pela capacidade de processamento de informações em alta velocidade, auxiliando a tomada de decisão rápida e fundamentada. Dentre elas, cita-se a obtenção de parâmetros de tráfego a partir do processamento de imagens e do uso de algoritmos de Visão Computacional aplicados a vídeos de monitoramento das vias urbanas. O trabalho compara o desempenho em termos de contagens volumétricas de duas estratégias de detecção e rastreamento veicular aplicadas a um cenário urbano, caracterizado pelo fluxo interrompido. Através da análise de 45 vídeos agrupados em fluxo alto, médio e baixo, foi possível avaliar as duas estratégias. Os resultados indicaram um desempenho superior da estratégia baseada em características, com erro médio de 7,41 %, enquanto a estratégia baseada em regiões apresentou erro de 11,03 %, em média. Além disso, a taxa de detecção correta do método baseado em características foi de 74,1 %, ao passo que o método baseado em regiões teve taxa de 66,6 %. A estratégia baseada em características demonstrou maior capacidade em lidar com as peculiaridades do tráfego urbano, apresentando menor quantidade de erros de detecção, de agrupamento e de contagem.

Palavras-chave: estudos de tráfego, contagens volumétricas, visão computacional, rastreamento veicular, características, regiões.

ABSTRACT

The accelerated urban growth and the dynamism of transport systems make necessary the search for new traffic management tools, which are characterized by their capacity of processing information at a high speed, helping on the decision process. Among these tools is the use of image processing and computer vision algorithms applied to highway monitoring cameras, aiming at the obtainment of traffic parameters based on video images. The present work compares the performance of two different vehicle detection and tracking strategies applied to an urban scenario, characterized by interrupted flow. In order to do so, 45 videos were collected and analyzed and then grouped in high, medium and low flow. In terms of volumetric counts, the results indicated a superior performance of the feature based strategy, which had an average counting error of 7,41 %, while the region based strategy presented a counting error of 11,03 % on average. In addition, the feature based method reached a 74,1 % correct detection rate, whereas the correct detection rate of the region-based method was 66,6 %. The feature based strategy showed a greater capacity to handle the existing difficulties on the urban traffic, having fewer errors in terms of detection, grouping and counting.

Keywords: traffic studies, volumetric counts, computer vision, vehicle tracking, feature based, region based.

LISTA DE ILUSTRAÇÕES

Figura 1 - Estrutura típica de um laço indutivo	8
Figura 2 - Segmentação da imagem original (a), separando regiões móveis (b) e fundo fixo (c).....	10
Figura 3 - Utilização de um modelo geométrico para detecção veicular	11
Figura 4 - Detecção veicular e rastreamento de trajetórias a partir de modelos 3D predeterminados .	11
Figura 5 - Representação do método baseado em contornos ativos	12
Figura 6 - Rastreamento e detecção veicular baseados em regiões.....	13
Figura 7 - Detecção dos pontos (esq.), rastreamento (centro) e agrupamento (dir.).....	15
Figura 8 - Apresentação das etapas metodológicas	17
Figura 9 - Vista do cruzamento escolhido	18
Figura 10 - Ângulo de filmagem da câmera selecionada	19
Figura 11 - Imagens geradas para detecção de correspondência entre contagem e agrupamento	21
Figura 12 - Delimitação da região de interesse	22
Figura 13 - Ilustração do efeito da homografia.....	22
Figura 14 - Resultado final após a definição da região de interesse e aplicação da homografia	23
Figura 15 - Imagem original (esquerda) vs. fundo subtraído adaptativo (direita)	23
Figura 16 - Determinação de cantos com base no critério de Shi-Tomasi	24
Figura 17 - Exemplo de agrupamento e contagem de uma moto.....	25
Figura 18 - Ângulo de câmera utilizado pelo microssimulador VISSIM	44
Quadro 1 - Parâmetros de Detecção, Rastreamento e Agrupamento	28
Gráfico 1 - Distribuição dos erros percentuais: estratégia baseada em características	32
Gráfico 2 - Gráfico de dispersão – Estratégia baseada em características (Fluxo Alto).....	36
Gráfico 3 - Gráfico de dispersão – Estratégia baseada em regiões (Fluxo Alto).....	36
Gráfico 4 - Gráfico de dispersão – Estratégia baseada em características (Fluxo Médio)	37
Gráfico 5 - Gráfico de dispersão – Estratégia baseada em regiões (Fluxo Médio)	38
Gráfico 6 - Gráfico de dispersão – Estratégia baseada em características (Fluxo Baixo).....	39
Gráfico 7 - Gráfico de dispersão – Estratégia baseada em regiões (Fluxo Baixo)	39
Gráfico 8 - Erros Percentuais – Características x Regiões	40

LISTA DE TABELAS

Tabela 1 - Valores adotados na calibração	31
Tabela 2 - Contagens e erros percentuais: estratégia baseada em características	32
Tabela 3 - Composição do Tráfego – <i>Outliers</i> (Fluxo Alto)	33
Tabela 4 - Composição do Tráfego – <i>Outliers</i> (Fluxo Médio).....	34
Tabela 5 - Taxa de detecção de carros, veículos leves e veículos pesado por nível de fluxo	34
Tabela 6 - Comparação das contagens dos vídeos de fluxo alto	35
Tabela 7 - Comparação das contagens dos vídeos de fluxo médio	37
Tabela 8 - Comparação das contagens dos vídeos de fluxo baixo	38
Tabela 9 - Análise detalhada – Estratégia Baseada em Regiões.....	41
Tabela 10 - Análise detalhada – Estratégia Baseada em Características.....	42

SUMÁRIO

1	INTRODUÇÃO	1
1.1	Problema de Pesquisa e Questões Motivadoras	3
2	OBJETIVOS	4
2.1	Objetivo Geral	4
2.2	Objetivos Específicos	4
2.3	Estrutura da Monografia	5
3	REVISÃO BIBLIOGRÁFICA	6
3.1	Características do Fluxo de Tráfego Veicular Rodoviário	6
3.1.1	<i>Estudos Volumétricos</i>	7
3.2	Processamento de Imagens e Visão Computacional	9
3.3	Estratégias Automáticas de Detecção e Rastreamento Veicular	10
3.3.1	<i>Rastreamento Baseado em Modelos Tridimensionais</i>	10
3.3.2	<i>Rastreamento Baseado em Contornos Ativos</i>	12
3.3.3	<i>Rastreamento Baseado em Regiões</i>	13
3.3.4	<i>Rastreamento Baseado em Características</i>	14
4	METODOLOGIA	17
4.1	Consolidação da Base de Dados	18
4.2	Adaptações e Etapas do Algoritmo	20
4.2.1	<i>Definição da Região de Interesse</i>	21
4.2.2	<i>Homografia</i>	22
4.2.3	<i>Subtração de Fundo</i>	23
4.2.4	<i>Detecção e Rastreamento de Pontos</i>	24
4.2.5	<i>Agrupamento e Contagem</i>	25
4.3	Calibração	26
4.4	Processamento	27

4.5	Exportação e Comparação dos Resultados	27
5	RESULTADOS E DISCUSSÃO	28
5.1	Calibração.....	28
5.2	Resultados das Contagens	31
5.3	Comparação das estratégias.....	35
6	CONCLUSÕES	45
	REFERÊNCIAS BIBLIOGRÁFICAS	48
	APÊNDICE A – RESULTADOS DAS CONTAGENS DAS ESTRATÉGIAS BASEADAS EM REGIÕES (RB) E EM CARACTERÍSTICAS (FB)	51

1 INTRODUÇÃO

O desenvolvimento social e econômico observado no país ao longo das últimas décadas teve como uma de suas principais consequências o aumento expressivo da motorização individual (automóveis e motocicletas), haja vista as limitações das políticas públicas de transporte coletivo. (BRASIL. Ministério do Meio Ambiente, 2012). O consequente aumento da demanda torna necessária a adoção de medidas que mantenham um nível de serviço adequado para os usuários do sistema.

Diante do cenário apresentado, a utilização de novas tecnologias e aplicativos pelos operadores de sistemas de tráfego se apresenta como alternativa auxiliar para a tomada de decisões, visando à implementação de ajustes e melhorias necessários. O uso eficiente dessas ferramentas, entretanto, depende da prévia obtenção de informações a partir de estudos de tráfego.

O objetivo dos estudos de tráfego é obter, através de métodos sistemáticos de coleta, dados relativos aos cinco elementos fundamentais do tráfego (motorista, pedestre, veículo, via e meio ambiente). Constituem-se no instrumento de que se serve a engenharia de tráfego para atender às suas finalidades, tornando possível a obtenção do número de veículos que circula por uma via, suas velocidades, os locais de concentração de acidentes, entre outros aspectos. (DNIT, 2006)

Dentre os diversos parâmetros que podem ser obtidos, merece destaque o volume, definido como a taxa de fluxo de tráfego e expresso em veículos por unidade de tempo. A realização de contagens volumétricas torna possível determinar a quantidade, o sentido e a composição do fluxo de veículos que passam por um ou mais pontos do sistema viário numa determinada unidade de tempo. Essas informações são essenciais para a análise da capacidade de uma via e de suas condições de operação ao longo do dia. (DNIT, 2006)

As contagens volumétricas podem ser realizadas de forma manual ou automática. Quando manuais, são feitas por pesquisadores que se deslocam até o local de coleta e dispõem de fichas e contadores manuais para a execução da atividade. Esse tipo de contagem, entretanto, apresenta diversas limitações: o nível de atenção dos observadores diminui quando cansam, há o risco de julgamentos subjetivos e o custo é alto, levando-se em consideração a quantidade de

observadores. Há ainda o risco da presença do observador influenciar o comportamento do usuário da via. (LAURESHYN, 2010)

Contagens automáticas, por outro lado, são feitas por meio de sensores que detectam a passagem de veículos e então acumulam os dados registrados. São exemplos deste tipo de tecnologia os laços indutivos, tubos pneumáticos e sensores infravermelhos. Embora amplamente utilizados, ainda apresentam algumas desvantagens tais como o custo elevado e a exposição a vandalismos. (DNIT, 2006)

Nesse sentido, a utilização de técnicas de Visão Computacional aplicadas à contagem veicular surge como uma interessante alternativa. O avanço do processamento de imagens de vídeo decorrente da instalação de câmeras de monitoramento nas vias e da propagação de sistemas inteligentes de transportes associado ao desenvolvimento dos métodos de Visão Computacional torna possível a coleta de informações com base nas filmagens.

Visão Computacional é o processo de utilizar um computador para extrair informações de alto nível de uma imagem digital. A partir de um vídeo, algoritmos de Visão Computacional realizam tarefas como detecção, rastreamento e classificação de veículos (BARCELLOS, 2014). Os métodos de rastreamento recorrentes na literatura existente são classificados como: rastreamento baseado em regiões (*region based*), em características (*feature based*), em modelos (*model based*) e em contornos (*active contour based*). (COIFMAN *et al.*, 1998)

Dentre os métodos listados acima, destacam-se os modelos baseados em regiões e características, extensamente explorados por conta dos acessíveis conceitos em que se baseiam. O rastreamento por regiões reúne pixels de iluminação semelhante próximos ou conectados entre si, agrupando-os em regiões denominadas “*blobs*” e rastreando-as (CÂMARA, 2014). O rastreamento com base em características, por sua vez, tem como princípio o rastreamento contínuo de pontos ou linhas que se destacam no veículo como para-choques ou faróis, conforme o momento de gravação. (COIFMAN *et al.*, 1998)

Embora tenham apresentado significativo progresso nos últimos anos, os algoritmos de rastreamento veicular ainda possuem grandes desafios a superar. No monitoramento de tráfego urbano, por exemplo, é preciso lidar com um ambiente externo, mudanças climáticas e de iluminação, câmeras com baixa resolução e uma

quantidade limitada de detalhes visuais. Além disso, há o fato de os veículos andarem muito próximos, o que, dependendo do posicionamento da câmera, pode favorecer a ocorrência de oclusões. (BUCH; VELASTIN; ORWELL, 2011)

1.1 Problema de Pesquisa e Questões Motivadoras

Problema de Pesquisa:

O problema que motiva a linha de pesquisa à qual esse trabalho pertence reside nas limitações dos atuais métodos de estudo de tráfego veicular que, por sua vez, restringem a qualidade e a quantidade de dados obtidos.

Os atuais métodos possuem altos custos envolvidos, além da dependência do fator humano, e são incapazes de obter grande quantidade de parâmetros simultaneamente.

Questões Motivadoras:

O presente trabalho baseia-se na análise técnica e avaliação de desempenho de algoritmos de rastreamento veicular, englobando em sua estrutura as seguintes questões:

- (a) Qual das estratégias avaliadas para contagem veicular em cenário urbano apresenta melhores resultados quando comparada com o cenário real (*ground truth*)?
- (b) Em um algoritmo de rastreamento baseado em características, quais os parâmetros mais relevantes para uma calibração eficiente?
- (c) A variação na intensidade do fluxo observado (alto, médio, baixo) apresenta efeito significativo na precisão dos algoritmos de contagem?

2 OBJETIVOS

2.1 Objetivo Geral

O trabalho tem como objetivo geral comparar o desempenho de duas diferentes estratégias de contagem veicular quando aplicados a uma mesma situação (interseção semaforizada em área urbana de Fortaleza).

2.2 Objetivos Específicos

Tendo em vista alcançar o objetivo principal deste trabalho, serão desenvolvidos os seguintes objetivos específicos:

- (a) Identificar as principais estratégias de Visão Computacional aplicadas a pesquisas volumétricas.
- (b) Identificar e calibrar os parâmetros de maior relevância para a utilização eficiente de um algoritmo baseado em características, tendo em vista sua utilização em um cenário urbano.
- (c) Determinar e comparar o nível de desempenho das duas estratégias em termos de contagens volumétricas, avaliando o desempenho para cada nível de fluxo e para os diferentes grupos de veículos.

2.3 Estrutura da Monografia

O trabalho está estruturado da seguinte forma:

O **capítulo 1** introduz o tema do trabalho, buscando situá-lo em um contexto maior e mostrando de forma breve os principais conceitos. Apresenta a justificativa da pesquisa através do problema e das questões motivadoras.

O **capítulo 2** apresenta o objetivo geral e os objetivos específicos do trabalho.

No **capítulo 3**, realiza-se uma revisão dos principais assuntos que permeiam o trabalho. O capítulo discorre sobre estudos de tráfego, uso da Visão Computacional e as principais estratégias de detecção e rastreamento veicular automatizado, apresentando as características de cada uma delas.

O **capítulo 4** apresenta a metodologia adotada para a execução do trabalho. Nesse capítulo, também são descritas as principais rotinas do algoritmo utilizado.

No **capítulo 5** são apresentados os resultados obtidos a partir das etapas metodológicas, procedendo-se à comparação das contagens das duas estratégias. Além dos resultados, discute-se as principais diferenças entre as duas estratégias, bem como as limitações existentes em cada uma delas.

O **capítulo 6** é o capítulo final, onde, de forma resumida, são apresentados os principais resultados e observações do trabalho, assim como sugestões futuras para que se faça progresso nas principais limitações constatadas.

3 REVISÃO BIBLIOGRÁFICA

3.1 Características do Fluxo de Tráfego Veicular Rodoviário

O tráfego veicular é composto por motoristas e veículos que interagem entre si e também com elementos da pista e com o ambiente em geral. Considerando-se a heterogeneidade dos usuários envolvidos, é possível perceber que as ações de operação de tráfego lidam com elementos de variabilidade e imprevisibilidade, impossibilitando um planejamento exato, uma vez que os cenários observados nunca serão exatamente iguais.

Nesse contexto, a implementação de melhorias e o controle das instalações de tráfego depende das características do tráfego e da análise de seus parâmetros. A intenção é assumir como referência as faixas de valores mais observadas para cada parâmetro. Os parâmetros tornam possível a avaliação qualitativa e quantitativa do sistema, auxiliando na compreensão e descrição do fluxo dos veículos. O fluxo de tráfego representa o número de veículos que cruzam uma determinada região dentro de um intervalo de tempo definido, sendo uma variável indicativa da demanda.

ROESS (2014) diferencia o fluxo de tráfego veicular em fluxo ininterrupto e fluxo interrompido. O fluxo ininterrupto é caracterizado pela ausência de interferências que interrompem o tráfego, como interseções de nível ou sinalização semaforica, por exemplo. Assim, as condições de tráfego dependem unicamente da interação entre os veículos, características das vias e condições climáticas do momento. No contexto brasileiro, as rodovias federais são exemplos de fluxo ininterrupto. O fluxo interrompido, por outro lado, é caracterizado pela incorporação planejada de componentes que interferem no tráfego. Como exemplo, sinais semaforicos organizam e controlam o progresso dos veículos ao longo das vias. As vias urbanas são exemplo de fluxo interrompido. As características do fluxo influenciam diretamente nos parâmetros de tráfego. Enquanto o fluxo ininterrupto é caracterizado por altas velocidades e grande espaçamento entre os veículos, o fluxo interrompido apresenta grande variabilidade de velocidade e no espaçamento entre veículos, conforme a evolução do ciclo semaforico e a presença de sinalização.

Os parâmetros que caracterizam a corrente de tráfego, por sua vez, podem ser classificados em duas grandes categorias: parâmetros macroscópicos, que visam

descrever o tráfego veicular como um todo, indicando características médias, e parâmetros microscópicos, que analisam o comportamento individual de um usuário (ou veículo) face aos demais. Dentre os parâmetros macroscópicos, estão o volume de tráfego, a densidade e a velocidade média. Com relação aos parâmetros microscópicos, são exemplos o *headway* e o espaçamento entre os veículos (ROESS, 2014).

O trabalho concentra-se nos estudos volumétricos, apresentando a finalidade desse tipo de estudo e identificando os principais métodos utilizados para a obtenção desse parâmetro.

3.1.1 Estudos Volumétricos

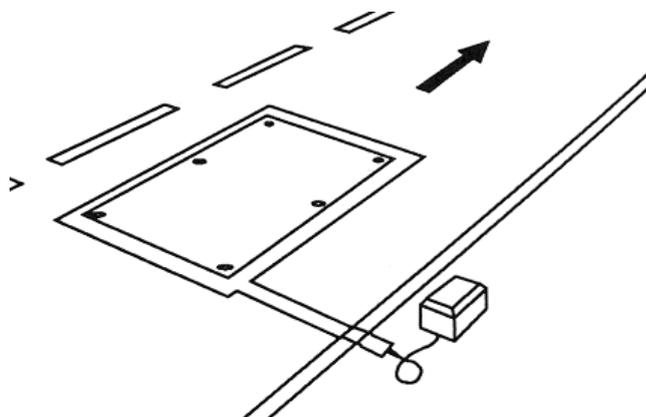
Dentre os tipos de estudos de tráfego, o estudo do volume é o mais básico e mais amplamente realizado, uma vez que quase todos os aspectos da engenharia de tráfego, desde o planejamento até o controle da operação, envolvem medidas de demanda, obtidas a partir dos estudos volumétricos. Com o auxílio das contagens volumétricas, é possível produzir estimativas do volume de veículos, da taxa de fluxo, da demanda e da capacidade (ROESS, 2014). Podem ainda auxiliar na determinação dos momentos de fluxo crítico, bem como das tendências de tráfego da via ou da influência de veículos pesados ou pedestres no fluxo de tráfego. (*Centre for Transportation Research and Education*, 2009).

O volume é definido como o número de veículos que passa por uma região durante um intervalo definido de tempo (normalmente de uma hora). A taxa de fluxo, por sua vez, é a taxa de veículos que passa por uma região em um intervalo de tempo menor que uma hora, expressa em um valor equivalente para o intervalo de uma hora. A demanda consiste na quantidade de veículos que desejam passar em uma determinada região durante um intervalo definido de tempo. Por fim, a capacidade representa a taxa máxima de veículos que pode cruzar uma região em um intervalo determinado de tempo, sendo uma característica da via. Quando há congestionamento, isso indica que a demanda é maior do que a capacidade.

As contagens são tipicamente realizadas de forma manual ou automatizada. Quando manuais, são realizadas por operadores que se localizam próximo ao ponto de interesse e dispõem de pranchetas que auxiliam a contagem. A principal limitação desse tipo de contagem é a dependência do fator humano. Além de terem uma capacidade de observação limitada por sentido de fluxo ou faixa, a atenção dos observadores diminui conforme cansam. (LAURESHYN, 2010)

Por outro lado, as contagens automáticas se baseiam na utilização de sensores instalados no pavimento ou próximo a ele. Dentre os principais métodos, estão: o laço indutivo, que registra a passagem de um veículo através de indução magnética (Figura 1), o tubo pneumático, que reconhece o eixo de um veículo com base na pressão sobre o tubo de borracha disposto sobre a faixa de rolamento, e os radares, instalados ao lado da pista.

Figura 1 - Estrutura típica de um laço indutivo



Fonte: Federal Highway Administration Research and Technology (FHWA), 2016

As contagens podem ainda ser realizadas com a utilização de câmeras, sendo possível a extração de informações de forma manual ou automática. Além de não existir interferência no fluxo de veículos, a presença de câmeras de monitoramento em diversas vias e a possibilidade de cobrir uma grande área com uma única câmera favorecem a utilização de imagens de vídeo.

Considerando o custo e o tempo empregados em contagens volumétricas manuais a partir da análise de vídeos, pesquisas foram iniciadas na década de 90 com o intuito de automatizar o processo de extração de informações. Dentre os

principais desafios, estão a detecção correta de veículos mesmo diante de condições climáticas adversas ou câmeras de baixa resolução e o tempo de processamento das informações, uma vez que a contagem veicular é feita ao longo de grandes intervalos de tempo ou continuamente. (LESSARD *et al.*, 2016)

3.2 Processamento de Imagens e Visão Computacional

A multiplicação das câmeras de monitoramento e o grande desenvolvimento tecnológico observado nas últimas décadas tornaram possível a análise e extração de informações a partir de imagens e vídeos. Nesse contexto, destacam-se dois conceitos: processamento de imagens e Visão Computacional.

Em geral, o processamento de imagens é visto, em uma interpretação mais restrita, como a realização de operações e/ou transformações na imagem, com o intuito de melhorar a qualidade da imagem e prepará-la para a análise. A redução de ruídos e o realce de contraste são exemplos de processamento de imagens. Há também uma interpretação mais ampla do significado do processamento de imagens, onde se considera que áudios, imagens e vídeos são compostos por números que são então processados e organizados. Nesse cenário, o conjunto de imagens é o ponto de entrada do sistema e os valores numéricos processados, que podem ou não compor outra imagem, são o ponto de saída.

A Visão Computacional, por sua vez, consiste na interpretação das informações fornecidas. Nela, a máquina é “ensinada”, por exemplo, a reconhecer objetos ou movimentação em sequência de quadros e então tomar decisões sem a interferência do ser humano. No contexto das contagens volumétricas automatizadas, é a responsável pela detecção e pelo rastreamento de veículos, assim como pela decisão de contabilizar ou não um conjunto de pontos como veículo.

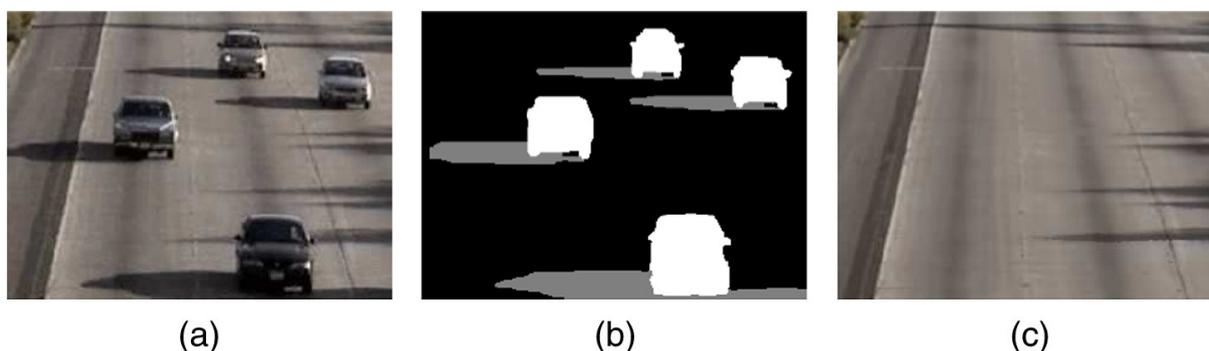
As principais estratégias de detecção e rastreamento de veículos utilizadas em sistemas inteligentes de tráfego são apresentadas a seguir.

3.3 Estratégias Automáticas de Detecção e Rastreamento Veicular

O processo de detecção e rastreamento tem início com a obtenção das imagens da via pela câmera estacionária, podendo ser realizado algum tratamento com o intuito de melhorar a estabilização da sequência de imagens ou melhorar a resolução destas.

A etapa seguinte consiste na segmentação, onde as regiões da imagem são classificadas como fixas (*background*) ou móveis (*foreground*) conforme a existência ou não de movimentação ao longo do vídeo (Figura 2). A segmentação envolve procedimentos como a subtração de fundo. (HUANG *et al.*, 2012)

Figura 2 - Segmentação da imagem original (a), separando regiões móveis (b) e fundo fixo (c)



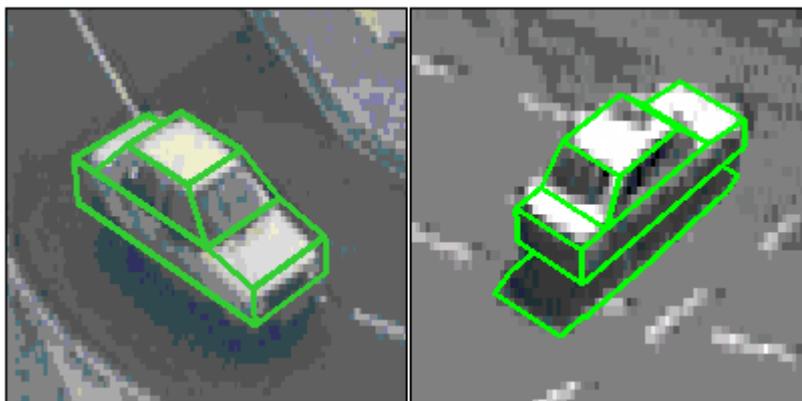
Fonte: Barcellos *et al.* (2016)

Após a separação entre o que é estático e o que se move, acontece a detecção e o rastreamento dos objetos de interesse. Nessa etapa cada método apresenta princípios diferenciados. Com base na diferença entre frames, os objetos em movimento são rastreados e classificados. Dentre as principais estratégias de detecção e rastreamento veicular, destacam-se a baseada em modelos tridimensionais (*3D Model-based*), em contornos ativos (*Active Contour based*), em regiões (*Region based*) e em características (*Feature based*).

3.3.1 Rastreamento Baseado em Modelos Tridimensionais

A estratégia baseada em modelos tridimensionais busca localizar e reconhecer veículos com base na correspondência geométrica entre eles e modelos rígidos previamente informados à base de dados do algoritmo, possibilitando a observação da trajetória do veículo (Figura 3).

Figura 3 - Utilização de um modelo geométrico para detecção veicular



Fonte: Koller (1996)

BUCH *et al.* (2009) avaliaram a eficiência do rastreamento de um algoritmo baseado em modelos 3D, onde a detecção e classificação dos veículos se deu a partir da analogia entre os veículos e o conjunto de esqueletos básicos (*wire frames*) registrados. Feita a correlação, os veículos tiveram suas trajetórias rastreadas (Figura 4). Partindo de uma análise de 100 trajetórias, o sistema detectou um total de 144 trajetórias, das quais 94 foram corretas. As principais falhas observadas foram a não-detecção de trajetórias (6 vezes), a detecção de falsas trajetórias (27 vezes) e a mudança de ID do veículo observado (10 vezes).

Figura 4 - Detecção veicular e rastreamento de trajetórias a partir de modelos 3D predeterminados



Fonte: Buch *et al.* (2009)

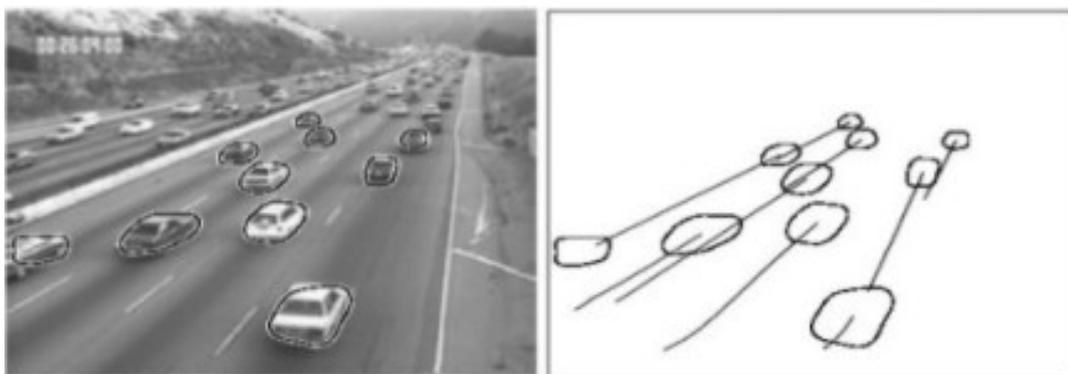
A estratégia de modelos 3D possibilita o rastreamento eficaz de uma pequena quantidade de modelos, tendo-se em vista a dependência desse método com relação aos modelos registrados pelo usuário e a grande diversidade de veículos existentes no tráfego (SAUNIER e SAYED, 2006). Há ainda limitações relacionadas

com a oclusão, que acontece quando parte do veículo rastreado ou mesmo todo o veículo é sobreposto por um outro objeto, impedindo o rastreamento correto. Nessa estratégia a sobreposição, ainda que parcial, dificulta o encaixe do veículo observado dentro das categorias de modelos pré-determinadas.

3.3.2 Rastreamento Baseado em Contornos Ativos

Essa estratégia baseia-se na obtenção do contorno do veículo, tomando-o como referência para as atualizações dos instantes seguintes (Figura 5). O método assemelha-se à estratégia baseada em regiões, apresentando uma menor complexidade computacional e gerando uma descrição mais detalhada dos objetos rastreados. É utilizado, por exemplo, para o rastreamento de pedestres com base no contorno da cabeça humana (SAUNIER e SAYED, 2006).

Figura 5 - Representação do método baseado em contornos ativos



Fonte: Indupalli (2011)

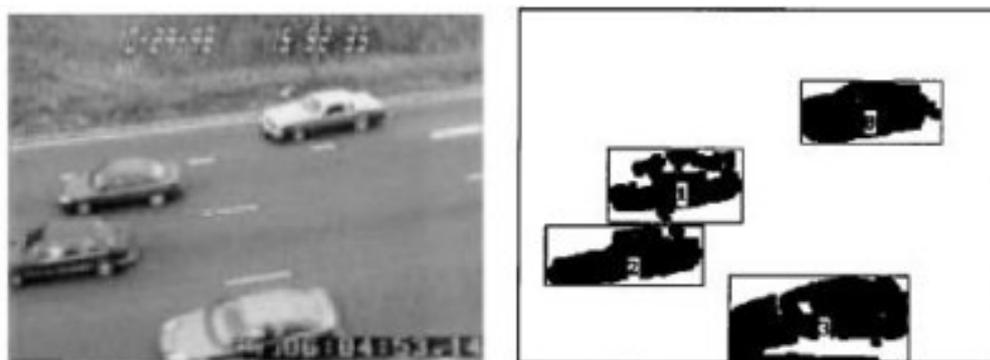
Resultados experimentais obtidos por FAN *et al.* (2002) indicam que o método apresenta desempenho satisfatório no rastreamento de veículos que estão bem separados. O estudo, no entanto, não lidou com a existência de oclusões veiculares, sendo essa considerada a principal limitação do método baseado em contornos ativos. Esse problema ocorre especialmente em situações de inicialização, onde o veículo é detectado pela primeira vez já com alguma oclusão, resultando no agrupamento de dois veículos como um só e causando erros significativos em termos de dimensões e padronização. (COIFMAN *et al.*, 1998)

3.3.3 Rastreamento Baseado em Regiões

A estratégia baseada no reconhecimento de regiões identifica regiões de pixels com intensidade semelhante, agrupando-as em “blobs” que são associados a veículos. Essas regiões são obtidas a partir da subtração de fundo, e então rastreadas com base em suas informações, dentre as quais estão o movimento, tamanho, formato e a posição do centroide (Figura 6).

O rastreamento baseado em regiões é considerado eficiente do ponto de vista computacional, exigindo menos em termos de capacidade e tempo de processamento. A estratégia funciona bem em situações de fluxo livre ou tráfego leve. Entretanto, diante de congestionamentos, os veículos se sobrepõem, gerando oclusões que dificultam a segmentação individual. Como resultado, esses veículos são agrupados como um único *blob* e considerados um único veículo, resultando na subestimação do fluxo. (SAUNIER e SAYED, 2006)

Figura 6 - Rastreamento e detecção veicular baseados em regiões



Fonte: Gupte *et al.* (2002)

Em seu trabalho, 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. O trabalho desenvolvido por CÂMARA (2014) foi o ponto de partida da comparação das duas estratégias, tendo sido utilizado o mesmo conjunto de vídeos obtidos em sua metodologia, a partir de uma coleta realizada em 2013 junto ao Controle de Tráfego em Área de Fortaleza (CTAFOR). Além disso, os resultados

obtidos para as contagens volumétricas foram utilizados para a comparação do desempenho das duas estratégias.

O erro médio obtido na análise dos vídeos foi de 11,0% quando os parâmetros de calibração variaram em função do tipo de fluxo e de 18,4% quando foram utilizados os mesmo valores de calibração para todos os vídeos. Uma análise mais detalhada revelou que a taxa média de detecção correta (verdadeiro positivo, quando há correspondência entre o *blob* detectado e o veículo analisado) foi de 66,6% para a calibração variável e de 63,8% para a calibração fixa.

Dentre as principais limitações observadas, estão: a segmentação de veículos de maior porte, sendo esses contabilizados 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).

3.3.4 Rastreamento Baseado em Características

A estratégia baseada em características abandona a ideia de rastrear objetos como um todo, selecionando apenas características que se destacam no objeto, como pontos ou linhas (COIFMAN *et al.*, 1998). No caso de veículos, por exemplo, cantos e janelas se destacam durante o dia, enquanto faróis e lanternas são destaque durante filmagens noturnas. Isso permite que um algoritmo detecte e rastreie veículos em diferentes momentos do dia, dada a adaptabilidade do método.

A abordagem baseada em características (*features*) é robusta com relação à existência de oclusões parciais, uma vez que detecta diversos pontos de um veículo e os mantém agrupados com base na proximidade entre eles e no padrão de movimentação. Assim, ainda que alguns pontos não possam ser vistos por conta da interferência dos demais veículos, os demais pontos do agrupamento formado continuarão unidos entre si, permitindo a detecção, o agrupamento e o rastreamento adequado (Figura 7).

Figura 7 - Detecção dos pontos (esq.), rastreamento (centro) e agrupamento (dir.)



Fonte: Coifman et al. (1998)

Como resultado, algoritmos baseados em detecção por características conseguem se adaptar rapidamente a situações de tráfego denso, rastreando múltiplos objetos ao mesmo tempo e apresentando resultados superiores aos das demais estratégias em termos de detecção, rastreamento e contagem correta.

SAUNIER E SAYED (2006) utilizaram essa estratégia em três diferentes grupos de vídeos: o primeiro consistiu num conjunto de vídeos utilizados para análise de conflitos de tráfego, enquanto as demais filmagens foram obtidas através das universidades de Karlsruhe e Cambridge.

Os vídeos foram analisados após a calibração do algoritmo, sendo encontrado um percentual de correspondência verdadeira entre agrupamentos e veículos de 86% nos vídeos de conflitos de tráfego, 84,7% nos vídeos de Karlsruhe e 94,4% nos vídeos de Cambridge. As principais falhas observadas se deram por conta da detecção de pontos distantes das câmeras, além das trepidações destas.

LESSARD *et al.* (2016) propuseram um método semiautomatizado para a contagem de veículos a partir do rastreamento de imagens de vídeo, o qual envolveu a análise de cerca de 500 horas de vídeos. O sistema de rastreamento baseado em características é totalmente automatizado, sendo as trajetórias veiculares geradas e informadas aos usuários. A partir dessas trajetórias, filtrando-se as áreas de interesse em cada vídeo, o usuário tem acesso aos resultados das contagens.

Os resultados da contagem foram avaliados em termos percentuais de erro médio absoluto, sendo obtidos erros médios de apenas 14%, resultado considerado pelos autores como promissor, tendo em vista as condições e qualidades dos vídeos,

os quais não foram produzidos com o intuito de serem utilizados para futuras pesquisas, e a grande variação entre os cenários utilizados na avaliação do método.

A principal limitação observada consistiu na fragmentação das trajetórias, causada principalmente pelas oclusões e também pelas paradas dos veículos nas faixas de retenção, impactando diretamente nas contagens. Isso se deveu ao fato de que as câmeras foram instaladas sem qualquer intenção de utilização para esse fim, apresentando ângulos e posições desfavoráveis.

Utilizando uma estratégia baseada na detecção de características, MORSE *et al.* (2015) analisaram diferentes cenários com variações nas condições climáticas e também nas condições de câmera (ângulo e resolução da gravação), buscando com isso avaliar o impacto da calibração de parâmetros de rastreamento e agrupamento nos dados de tráfego. Para isso, criou-se um algoritmo genético que, com base na comparação entre os valores obtidos pelo algoritmo e os valores reais (obtidos por observação direta), gerava para cada tentativa um novo conjunto de dados com diferentes valores de calibração.

Dentre as principais conclusões, MORSE *et al.* (2015) observaram uma forte correlação entre os resultados das contagens de tráfego e o ajuste de parâmetros de rastreamento e agrupamento feito pelo algoritmo genético. Por outro lado, as velocidades médias observadas apresentaram menor sensibilidade ao processo de calibração, não sendo observadas mudanças significativas a partir de ajustes no rastreamento e agrupamento.

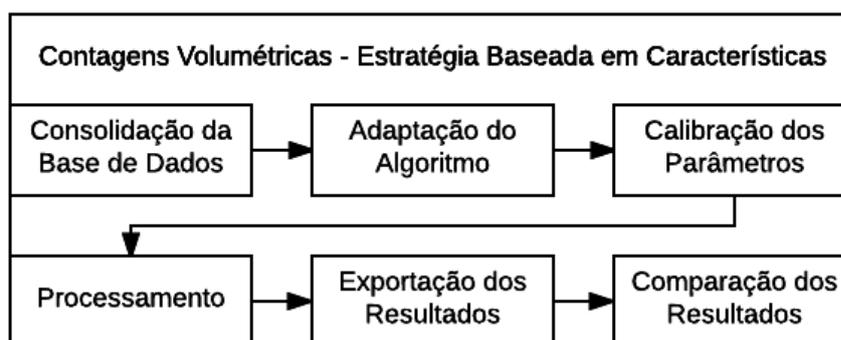
Os resultados também indicaram que câmeras de alta resolução apresentam uma baixa sensibilidade ao processo de otimização, gerando resultados satisfatórios para a maioria das combinações testadas, enquanto vídeos gravados com câmeras de menor resolução ou durante o inverno apresentaram grande dependência do processo de calibração, sendo a variação mais significativa observada com a diminuição do parâmetro *feature-quality* (parâmetro que define um limite a partir do qual as *features* serão levadas em consideração).

Para a análise dos vídeos, o trabalho desenvolvido utilizou a estratégia baseada na detecção de características (*features*), a partir de um algoritmo desenvolvido pelo grupo de Visão Computacional da Universidade Federal do Ceará, que utiliza a linguagem *Python*.

4 METODOLOGIA

A metodologia apresentada na Figura 8 sistematiza as etapas realizadas durante o trabalho, tendo em vista a avaliação do desempenho de um algoritmo de contagem veicular baseado em características aplicado em uma área urbana. Os resultados obtidos são então comparados com aqueles obtidos por CÂMARA (2014), que, em seu trabalho, avaliou o desempenho de um algoritmo de contagem baseado em regiões sujeito ao mesmo cenário.

Figura 8 - Apresentação das etapas metodológicas



Fonte: Autor (2017)

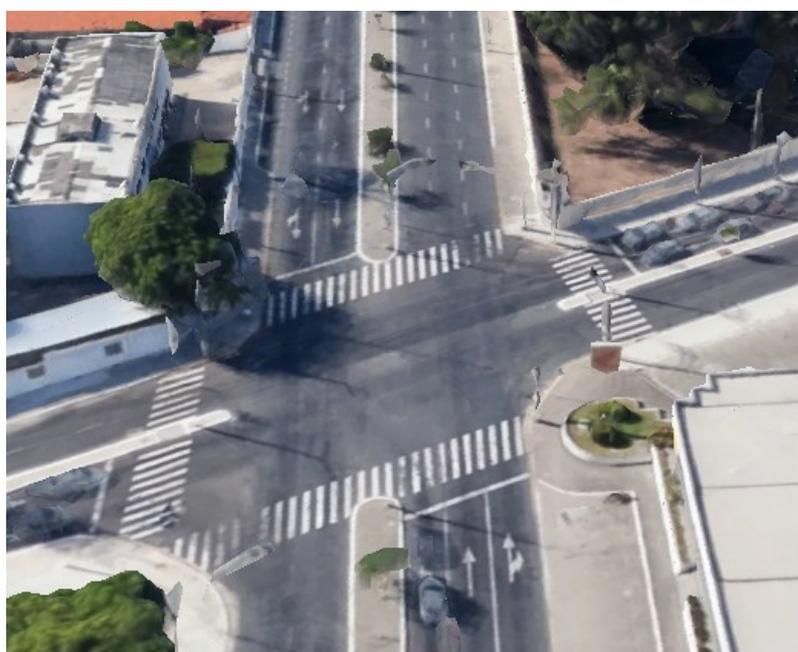
Conforme apresentado no fluxograma, inicialmente são obtidas as filmagens que serão utilizadas e os valores reais das contagens volumétricas (consolidação da base de dados); em seguida, são feitas adaptações na estrutura original do algoritmo com o intuito de viabilizar e otimizar as contagens volumétricas; a etapa seguinte consiste no ajuste dos parâmetros de detecção, rastreamento e agrupamento (calibração); definidos os valores das variáveis, é realizado o processamento dos vídeos; por fim, realizadas as contagens volumétricas, é feita a exportação dos resultados da estratégia baseada em características. De posse dos resultados, é feita a comparação do desempenho dos dois métodos diante de um cenário urbano.

4.1 Consolidação da Base de Dados

Nesta etapa, foram obtidos e organizados os vídeos utilizados para a análise da estratégia baseada em características e os resultados reais das contagens volumétricas (determinados por observação direta). Como o trabalho propõe a comparação de dois métodos, os vídeos utilizados são os mesmos selecionados que foram obtidos e editados por CÂMARA (2014), que avaliou o desempenho de um algoritmo de contagem volumétrica baseado em regiões em uma área urbana.

Os vídeos foram obtidos no ano de 2013 a partir de uma câmera do Controle de Tráfego em Área de Fortaleza (CTAFOR). A câmera selecionada apresenta resolução de 320x240 pixels, taxa de 30 frames por segundo e está instalada em um poste, a 15 metros de altura. O local escolhido foi o cruzamento entre as avenidas Borges de Melo e Luciano Carneiro, no Bairro de Fátima (Figura 9).

Figura 9 - Vista do cruzamento escolhido



Fonte: Google Earth (2017)

As filmagens foram capturadas ao longo de uma semana, de segunda-feira a sexta-feira, em dois diferentes intervalos: de 07h20min até 08h40min e depois de 09h20min até 10h40min. Objetivou-se, com isso, ter material para uma análise adequada em cenários de fluxo pesado, médio e leve.

Os vídeos obtidos apresentavam formato MPEG2 e tamanho de aproximadamente 650 megabytes cada. Tendo em vista a necessidade de otimização do tempo de processamento dos vídeos pelo algoritmo, CÂMARA (2014) optou pela divisão dos vídeos em intervalos de 15 minutos. Além disso, converteu cada um deles para o formato AVI. Com isso, diminuiu-se o tamanho do arquivo e também o tempo de processamento necessário.

Um total de 45 vídeos dentre os vídeos gerados foi considerado adequado por CÂMARA (2014), que realizou a contagem manual destes para a comparação entre os resultados obtidos por observação direta e os obtidos pelo algoritmo. Esses valores também foram utilizados como valores de referência para a calibração e determinação do erro na estratégia baseada em características. É importante destacar que alguns vídeos foram descartados por conta de anomalias nas filmagens, como a forte movimentação da câmera e a presença de insetos obstruindo a visão da mesma.

Os vídeos selecionados foram listados em ordem decrescente da quantidade de veículos contabilizados, sendo agrupados em três categorias com 15 vídeos cada: vídeos de fluxo alto, vídeos de fluxo médio e vídeos de fluxo baixo. Cada uma das três categorias foi analisada separadamente, inclusive no que diz respeito à calibração do algoritmo.

A câmera selecionada permite a visualização apenas da Avenida Borges de Melo (Figura 10). Embora seu alcance englobe as quatro faixas da avenida (duas em cada sentido), restringiu-se a contagem de veículos apenas às duas faixas de chegada (sentido de aproximação da câmera).

Figura 10 - Ângulo de filmagem da câmera selecionada



4.2 Adaptações e Etapas do Algoritmo

Uma vez que o trabalho objetiva a obtenção de contagens volumétricas para comparação, foram realizadas adaptações na estrutura original do código com o intuito de viabilizar a realização das contagens de forma adequada e otimizar o tempo de processamento necessário. Esta seção descreve as principais modificações realizadas e, em seguida, apresenta as etapas do algoritmo, desde a definição da região analisada até a contagem dos veículos.

A primeira adaptação se deu por conta da necessidade de inicialização do algoritmo com frames que apresentem a pista limpa, sem qualquer veículo. Isso ocorre por conta do método utilizado para a detecção de veículos, que se baseia na comparação entre frames consecutivos. Assim, ao se iniciar o algoritmo com veículos em tela nos primeiros frames, estes serão assumidos como parte do fundo e prejudicarão toda a contagem posterior. Como os vídeos são gravações reais de uma importante via em horário de fluxo intenso, poucos vídeos apresentaram inicialização adequada. Diante disso, foi necessário, com o auxílio de um software de edição de vídeo, adicionar frames com a pista vazia ao início dos vídeos. Com o intuito de uniformizar o procedimento, adicionou-se a cada um dos 45 vídeos uma imagem fixa da pista vazia por um intervalo de 5 segundos, garantindo assim a inicialização adequada do algoritmo.

Considerando-se a grande quantidade de vídeos e a duração destes (27.150 frames cada), decidiu-se pela retirada das planilhas geradas pelo algoritmo e alimentadas a cada frame executado. As planilhas geradas informam valores como a posição e a velocidade de cada ID (agrupamento) rastreado a cada instante. Como tais planilhas não são essenciais para as contagens volumétricas e aumentam significativamente o tempo de processamento de cada vídeo, esses trechos do algoritmo foram desconsiderados.

Por fim, para garantir a obtenção dos valores de contagens e permitir a análise detalhada do desempenho do algoritmo, duas novas estruturas foram adicionadas ao código: a primeira delas gera uma imagem da tela observada em cada frame executado, armazenando o conjunto de imagens na mesma pasta onde está o código referente ao vídeo analisado. A segunda estrutura funciona de forma semelhante, gerando imagens todas as vezes que um veículo é contabilizado na

contagem. A diferença se dá pelo fato de que essas imagens apresentam todos os agrupamentos formados no ato da contabilização de um veículo. Para cada imagem gerada são informados o frame e a contagem de veículos naquele instante. Assim, se trabalhadas em conjunto, as duas estruturas permitem acompanhar detalhadamente as contagens, tornando possível verificar para cada contagem se existiu ou não correspondência com o agrupamento correto de um veículo (Figura 11).

Figura 11 - Imagens geradas para detecção de correspondência entre contagem e agrupamento



Fonte: Autor (2017)

Descritas as modificações necessárias, as etapas do algoritmo são brevemente apresentadas a seguir.

4.2.1 Definição da Região de Interesse

A definição de uma região de interesse (do inglês *Region of Interest*, ou *ROI*) consiste na restrição e aplicação das etapas subsequentes a uma porção menor dos vídeos analisados. Essa etapa se justifica por conta das limitações de processamento dos algoritmos de Visão Computacional. Busca-se condicionar o algoritmo de forma que obtenha estritamente as informações desejadas, reduzindo assim o tempo de processamento.

A região de interesse delimitada nos vídeos é apresentada na Figura 12.

Figura 12 - Delimitação da região de interesse

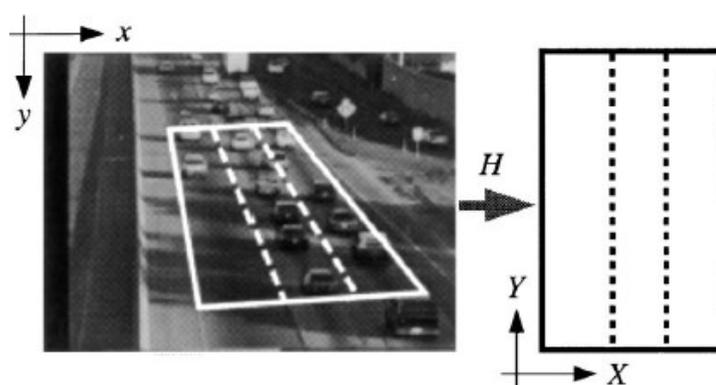


Fonte: Autor (2017)

4.2.2 Homografia

A homografia consiste em uma transformação projetiva de planos, mapeando pontos de um plano para outro plano (Figura 13). No âmbito da Visão Computacional, permite a retificação de imagens, sendo utilizada para corrigir deformações geradas pelo ângulo de câmera, que influencia na variação do tamanho dos veículos conforme se movimentam. Uma escala real deve ser informada para que seja possível criar uma imagem proporcional ao objeto real e calcular as coordenadas reais de posição.

Figura 13 - Ilustração do efeito da homografia



Fonte: Coifman *et al.* (1998)

Embora a homografia vise corrigir distorções de posição para auxiliar a obtenção correta de parâmetros de posição e velocidade, optou-se por realizar essa etapa por acreditar-se que a transformação de eixos pode facilitar o agrupamento dos pontos e a posterior contagem, uma vez que existem parâmetros de agrupamento que levam em consideração a distância horizontal e vertical entre os pontos, além do ângulo formado entre eles. O resultado final é apresentado na Figura 14.

Figura 14 - Resultado final após a definição da região de interesse e aplicação da homografia



Fonte: Autor (2017)

4.2.3 Subtração de Fundo

Nesta etapa, ocorre a segmentação da imagem, onde se diferencia o que está se movendo do que se mantém estático (Figura 15). Para que seja eficiente, é necessário que o algoritmo seja capaz de utilizar um *background* adaptativo conforme a evolução das imagens, uma vez que mudanças de iluminação ou mesmo veículos parados por longos períodos podem afetar negativamente a detecção de pontos caso não sejam incorporadas à imagem de fundo.

Figura 15 - Imagem original (esquerda) vs. fundo adaptativo subtraído (direita)



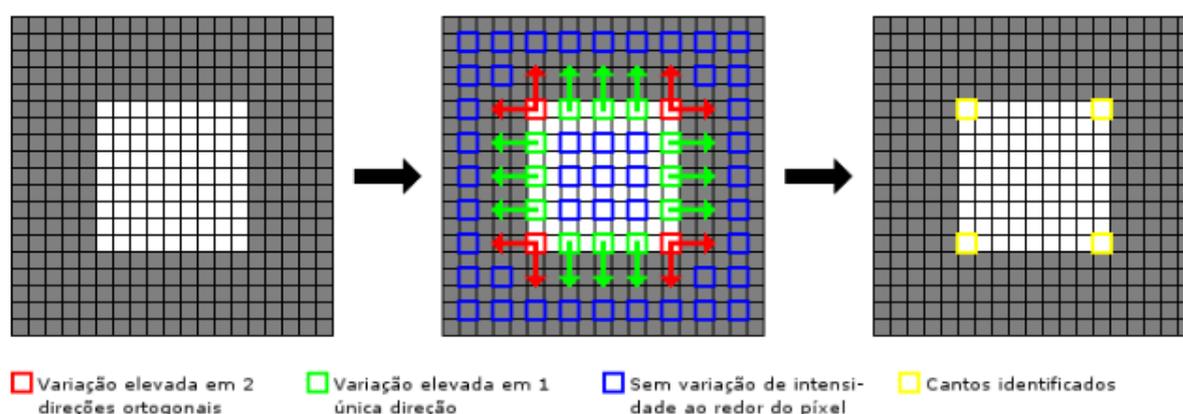
Fonte: Autor (2017)

Dentre os métodos de subtração de fundo disponíveis no OpenCV, utilizou-se o método *BackgroundSubtractorMOG2*, representado pela função `cv2.createBackgroundSubtractorMOG2()`. O método, tal como seu antecessor (*BackgroundSubtractorMOG*), modela o fundo adaptativo com base em misturas de distribuições Gaussianas. Cada mistura mantém relação com a proporção de tempo que determinadas cores se mantêm nos quadros, sendo consideradas integrantes do fundo aquelas que se mantêm por mais tempo e mais estáticas. A utilização do MOG2 se deve à sua maior capacidade adaptativa diante de variações de iluminação.

4.2.4 Detecção e Rastreamento de Pontos

Dentre as funções disponíveis no OpenCV para detecção de pontos, utilizou-se no algoritmo o método de detecção de cantos desenvolvido por J. Shi e C. Tomasi em 1994 (*Shi-Tomasi Corner Detector*, em inglês). Com base na diferença de intensidade entre os pixels da vizinhança e através da função `cv2.goodFeaturesToTrack()` são obtidos os N cantos mais fortes na imagem (sendo N definido pelo usuário) após a conversão da imagem para escala de cinza. Cabe também ao usuário definir a qualidade mínima do canto para que este seja acumulado ou rejeitado (sendo o valor definido entre 0 e 1), além da distância euclidiana mínima entre os cantos detectados. A Figura 16 ilustra o procedimento para a determinação de cantos em um objeto.

Figura 16 - Determinação de cantos com base no critério de Shi-Tomasi



Fonte: Britto (2011)

Para o rastreamento dos pontos, utilizou-se o método de Lukas-Kanade para determinação do Fluxo Óptico, representado no OpenCV pela função `cv2.calcOpticalFlowPyrLK()`. Esta técnica permite que determinados pontos de um quadro do vídeo sejam localizados num quadro anterior. Este é o passo inicial para se determinar o deslocamento de um veículo entre dois quadros consecutivos do vídeo. Antes, no entanto, é necessário detectar os cantos da imagem com base na variação de cor (intensidade) significativa nas direções ortogonais. (Britto, 2011).

Com base na intensidade e na variação de posição do ponto observado (comparando a posição do ponto no frame atual e no frame anterior), o algoritmo decide se aquele é ou não o mesmo ponto observado.

4.2.5 Agrupamento e Contagem

Para o agrupamento dos pontos detectados anteriormente são definidos critérios de agrupamento no algoritmo. Dentre eles, estão limitações que levam em consideração a distância horizontal e vertical entre os pontos observados, a velocidade de movimentação dos pontos, além da inclinação e do ângulo formado entre esses pontos. Após a definição de quais pontos se ligarão uns aos outros, é formada uma matriz de relacionamento entre eles, atribuindo-se um ID a cada conjunto de pontos reconhecido como um agrupamento. O algoritmo representa os cantos extremos de um agrupamento, interligando-os por uma linha vermelha.

Delimitou-se na região de interesse dos vídeos uma área onde são feitos os testes, decidindo-se se os cantos detectados são ou não agrupados. Após a região definida, apenas os agrupamentos formados serão mantidos, sem risco de novas ligações entre os pontos.

Finalmente, a contagem de um agrupamento acontece quando este ultrapassa a linha de contagem. Se o agrupamento atender às características mínimas (quantidade de *features* e dimensões em X e Y, por exemplo), será contabilizado como um veículo. A Figura 17 demonstra o agrupamento e a contagem de uma motocicleta.

Figura 17 - Exemplo de agrupamento e contagem de uma moto



Fonte: Autor (2017)

4.3 Calibração

Por calibração, entende-se o ajuste dos parâmetros modificáveis no algoritmo com o intuito de otimizar o processamento e obter melhores resultados em termos de contagem. No trabalho executado, a calibração se deu por tentativa e erro, de forma contínua, assistindo-se à execução do código e em seguida realizando os ajustes necessários, com base nas falhas observadas e no tempo de processamento.

Para cada nível de fluxo (alto, médio e baixo) foram selecionados três vídeos que foram ajustados diversas vezes até um resultado considerado satisfatório (erros menores que 7% para os três vídeos). Assim, atingido um nível aceitável, os parâmetros de calibração foram replicados para os demais vídeos, adotando-se para cada categoria de intensidade de fluxo uma calibração única.

Os parâmetros são agrupados no algoritmo em três categorias: parâmetros de detecção, de rastreamento e de agrupamento.

Dentre os parâmetros de detecção, destacam-se o “*detect_interval*” e o “*NMaxFeaturesAtScreen*” que indicam, respectivamente, o intervalo entre frames para detecção de novos pontos e a quantidade máxima de pontos em tela, possuindo relação direta com o tempo de processamento e o desempenho do algoritmo. Existem ainda parâmetros que delimitam o nível de qualidade das *features* para que sejam levadas em consideração (*qualityLevel*) e a distância mínima que devem existir entre dois pontos, em pixels (*minDistance*).

Com relação aos parâmetros de rastreamento e agrupamento, é permitido ao usuário, por exemplo, determinar o maior deslocamento (em pixels) entre dois quadros consecutivos para que um ponto seja considerado o mesmo (*TrackAssignmentLimitX* e *TrackAssignmentLimitY*). Além disso, são ajustáveis os valores que dizem respeito às dimensões máximas permitidas para um agrupamento (*DeltaXLimit_Group* e *DeltaYLimit_Group*), assim como os limites de diferença de velocidade entre os pontos (*Sup/Inf LimiteAbsoluteVel*) e a quantidade mínima de pontos para que um agrupamento seja contabilizado como veículo (*MaxNPointsRejectLikeGroup*).

4.4 Processamento

Definidos os valores finais dos parâmetros de calibração, os vídeos foram executados sequencialmente. A ordem da obtenção dos resultados se deu com base na intensidade do fluxo, sendo obtidos primeiramente os resultados para os vídeos de fluxo alto, depois, para os de fluxo médio e, por último, para os de fluxo baixo.

Considerando-se o tempo de processamento dos vídeos (o qual variou entre cerca de 6 horas para vídeos de fluxo alto e 3 horas para vídeos de fluxo baixo) e a grande quantidade de filmagens, decidiu-se executar o algoritmo de forma simultânea em quatro máquinas, com o intuito de obter os resultados mais rapidamente.

4.5 Exportação e Comparação dos Resultados

Após a execução com a calibração final, foram geradas, para cada vídeo analisado, as imagens referentes aos frames executados, apresentando o número do frame executado e a contagem até o momento. Nesse sentido, a imagem final (último frame executado) foi utilizada como dado de referência para a contagem final do algoritmo em cada vídeo. Os dados obtidos foram organizados em uma planilha e separados conforme o nível de fluxo dos vídeos originais.

Uma vez determinados os valores da estratégia baseada em características, os resultados dos dois métodos foram comparados. A análise principal foi feita com base na taxa de erro percentual dos vídeos, sendo avaliada também a dispersão dos resultados.

5 RESULTADOS E DISCUSSÃO

Nesta seção são apresentados os resultados obtidos após os ajustes e a execução dos vídeos no algoritmo. São discutidos também os efeitos práticos resultantes das diferenças entre as duas estratégias em questão, bem como as principais limitações observadas.

Inicia-se com uma discussão acerca da calibração realizada e seus parâmetros. Em seguida, os resultados obtidos para a estratégia baseada em características (*feature based*) são apresentados e posteriormente comparados com aqueles da estratégia baseada em regiões (*region based*). Por fim, são discutidos aspectos observados durante a execução dos vídeos e que apresentam influência direta nos resultados das contagens.

5.1 Calibração

A calibração tratou de ajustes nos parâmetros responsáveis pela detecção, rastreamento e agrupamento de pontos, objetivando a obtenção de menores erros de contagem. Podem ser listados 20 parâmetros para os quais foram testados diversos valores ao longo do processo de calibração. Os ajustes foram feitos com base na observação direta do desempenho do algoritmo ao longo de sua execução.

Considerando a grande quantidade de parâmetros envolvidos, torna-se impraticável uma descrição minuciosa de cada um. Os parâmetros principais são apresentados no Quadro 1, com breves resumos de seus significados.

Quadro 1 - Parâmetros de Detecção, Rastreamento e Agrupamento

Etapa	Nome Parâmetro	Descrição
	<i>NFramesNoExecuted</i>	Quantidade de frames não executada a cada frame executado
Detecção	<i>MaxCorners</i>	Número máximo de cantos detectáveis
	<i>detect_interval</i>	Intervalo entre frames p/ detecção de novos pontos
	<i>NMaxFeaturesAtScreen</i>	Número máximo de pontos detectados em tela
	<i>Maskball</i>	Raio do círculo que surge ao redor de um ponto detectado, evitando pontos próximos

	<i>Qualitylevel</i>	Percentual de pontos que será rejeitado com base na qualidade conferida a cada ponto
	<i>minDistance</i>	Mínima distância admitida entre duas features
	<i>ShadowDetect</i>	Habilita/Desabilita a detecção de sombras
	<i>GoodFeaturesLimit</i>	Valor limite que define se um ponto é bom ou não para ser rastreado nos frames seguintes
	<i>useHarrisDetector</i>	Habilita/Desabilita a detecção de cantos de Harris
Rastreamento	<i>TrackAssignmentLimitX</i>	Máxima variação de posição em X para que um ponto rastreado seja considerado o mesmo
	<i>TrackAssignmentLimitY</i>	Máxima variação de posição em Y para que um ponto rastreado seja considerado o mesmo
Agrupamento	<i>DeltaXLimit_Group</i>	Distância máxima permitida em X entre dois pontos para que façam parte de um mesmo agrupamento
	<i>DeltaYLimit_Group</i>	Distância máxima permitida em Y entre dois pontos para que façam parte de um mesmo agrupamento
	<i>Sup / Inf LimitRelativeVel</i>	Limites de diferença % de velocidade relativa entre pontos para que façam parte do mesmo agrupamento
	<i>Sup / Inf LimiteAbsoluteVel</i>	Limites de diferença % de velocidade absoluta entre pontos para que façam parte do mesmo agrupamento
	<i>InclinationDist</i>	Inclinação máxima permitida para que dois pontos façam parte do mesmo agrupamento
	<i>MaxNPointsRejectLikeGroup</i>	Número máximo de pontos em um agrupamento que resultará na não-contagem como veículo

Fonte: Autor (2017)

A partir do quadro observado, é possível ter uma ideia da grande quantidade de fatores de que depende a calibração. Existem ainda outros parâmetros, não mencionados, não totalmente compreendidos ou cuja variação não apresentou um padrão bem definido em termos de agrupamento e rastreamento dos pontos, etapas que precedem a contagem. Como exemplo, têm-se os parâmetros do método de Lukas-Kanade (*winsize*, *maxLevel*, *criteria_count* e *criteria_eps*), um método diferencial para a estimação do fluxo óptico. Embora tenha sido feito progresso na compreensão dessas variáveis ao longo do trabalho, há ainda grande margem para otimização dos valores, o que certamente resultará em uma melhor calibração.

Considerando-se a situação apresentada, a calibração dos cenários foi feita com base na observação da execução do algoritmo. Modificando-se os parâmetros separadamente, foi possível observar o efeito da variação de cada um na contagem veicular. Para cada nível de fluxo foram selecionados aleatoriamente três dos quinze vídeos, sendo a calibração para o respectivo fluxo dada como finalizada quando todos os vídeos selecionados apresentaram erro de contagem menor ou igual a 7%.

Foi necessário levar em consideração as peculiaridades de cada tipo de fluxo. Para os vídeos de fluxo alto, por exemplo, que possuem uma média de 360 veículos por vídeo e apresentam longas filas, diminuiu-se a quantidade de frames executados (*NFramesNoExecuted*), aumentando-se também o intervalo entre frames para a detecção de novos pontos (*detect_interval*) por conta das limitações de processamento do algoritmo. Já para os vídeos de fluxo baixo (com média de 226 veículos por vídeo) o cenário foi o oposto. Por conta da maior velocidade desenvolvida pelos veículos, foi necessário executar todos os frames e detectar novos pontos em cada um deles com o intuito de rastrear corretamente a maior quantidade possível de veículos, em especial as motocicletas e bicicletas, de pequenas dimensões e com difícil reconhecimento por conta da baixa resolução da câmera (320x240).

Os valores adotados para os parâmetros em cada um dos três cenários são apresentados na Tabela 1.

Tabela 1 - Valores adotados na calibração

Parâmetro	Fluxo Alto	Fluxo Médio	Fluxo Baixo
<i>NFramesNoExecuted</i>	2	1	0
<i>MaxCorners</i>	2000	2000	1500
<i>detect_interval</i>	3	2	1
<i>NMaxFeaturesAtScreen</i>	150	120	120
<i>Maskball</i>	9	12	13
<i>Qualitylevel</i>	0.0001	0.01	0.01
<i>minDistance</i>	10	13	13
<i>ShadowDetect</i>	1	1	1
<i>GoodFeaturesLimit</i>	15	10	7
<i>useHarrisDetector</i>	1	1	1
<i>TrackAssignmentLimitX</i>	30	30	30
<i>TrackAssignmentLimitY</i>	20	20	20
<i>DeltaXLimit_Group</i>	30	40	25
<i>DeltaYLimit_Group</i>	18	18	14
<i>Sup/Inf LimitRelativeVel</i>	0.03	0.07	0.05
<i>Sup/Inf LimiteAbsoluteVel</i>	0.03	0.07	0.05
<i>InclinationDist</i>	0.7	1	0.6
<i>MaxNPointsRejectLikeGroup</i>	2	4	5

Fonte: Autor (2017)

5.2 Resultados das Contagens

Definidos os valores definitivos dos parâmetros de calibração, os vídeos foram executados e seus resultados processados. Os valores das contagens da estratégia baseada em características (*feature based* – FB) são apresentados de forma resumida na Tabela 2, assim como seus respectivos erros percentuais. A tabela completa, com os valores de contagem real, composição do tráfego e contagem obtida em cada uma das duas estratégias é apresentada no final do trabalho (Apêndice A).

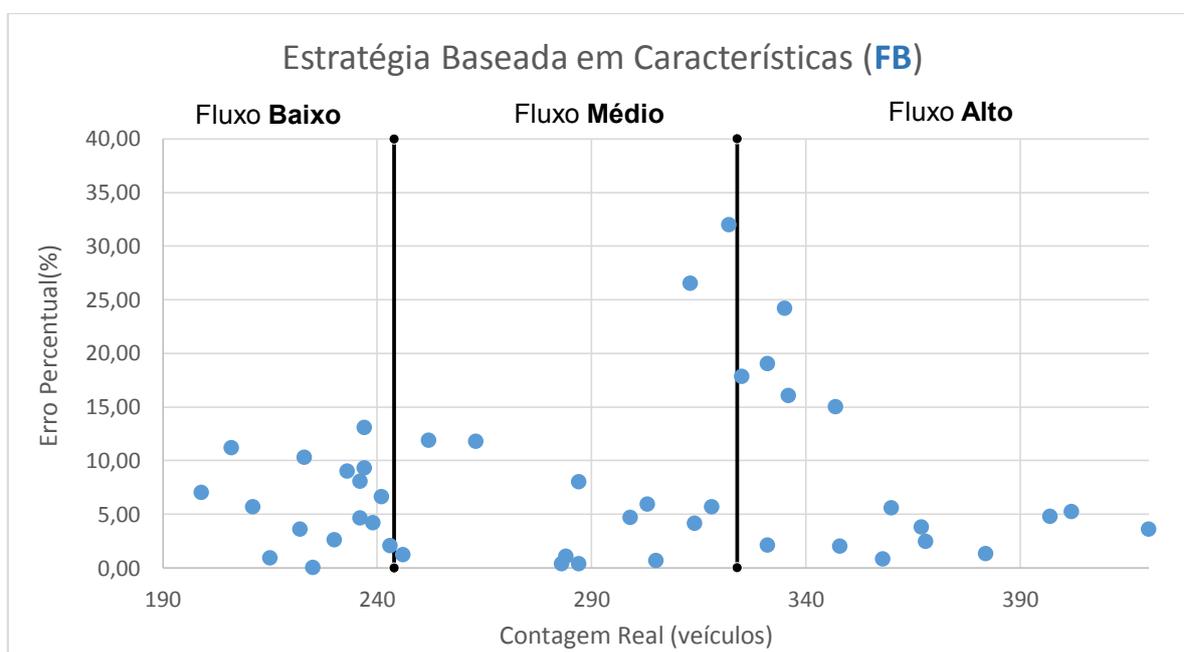
Tabela 2 - Contagens e erros percentuais: estratégia baseada em características

Fluxo Alto				Fluxo Médio				Fluxo Baixo			
# Vídeo	Real	FB	E (%)	# Vídeo	Real	FB	E (%)	# Vídeo	Real	FB	E (%)
V1	420	435	+ 3.57	V16	322	219	- 31.99	V31	241	225	- 6.64
V2	402	381	- 5.22	V17	318	300	- 5.66	V32	239	229	- 4.18
V3	397	378	- 4.79	V18	314	327	+ 4.14	V33	237	215	- 9.28
V4	382	387	+ 1.31	V19	313	230	- 26.52	V34	237	268	+ 13.08
V5	368	359	- 2.45	V20	305	303	- 0.66	V35	236	255	+ 8.05
V6	367	381	+ 3.81	V21	303	321	+ 5.94	V36	236	247	+ 4.66
V7	360	340	- 5.56	V22	299	285	- 4.68	V37	233	254	+ 9.01
V8	358	361	+ 0.84	V23	287	264	- 8.01	V38	230	236	+ 2.61
V9	348	341	- 2.01	V24	287	288	+ 0.35	V39	225	225	0.00
V10	347	399	+ 14.99	V25	284	281	- 1.06	V40	223	246	+ 10.31
V11	336	390	+ 16.07	V26	283	284	+ 0.35	V41	222	230	+ 3.60
V12	335	416	+ 24.18	V27	263	232	- 11.79	V42	215	213	- 0.93
V13	331	394	+ 19.03	V28	252	222	- 11.90	V43	211	223	+ 5.69
V14	331	324	- 2.11	V29	246	249	+ 1.22	V44	206	229	+ 11.17
V15	325	383	+ 17.85	V30	243	248	+ 2.06	V45	199	213	+ 7.04
Erro Médio (Módulo)			8.25	Erro Médio (Módulo)			7.76	Erro Médio (Módulo)			6.42
Desvio Padrão			7.54	Desvio Padrão			9.24	Desvio Padrão			3.67

Fonte: Autor (2017)

Os resultados são apresentados no Gráfico 1.

Gráfico 1 - Distribuição dos erros percentuais: estratégia baseada em características



Fonte: Autor (2017)

Observa-se que os resultados obtidos na categoria de fluxo baixo apresentaram menor variação do que os demais, com todos os valores de erro entre 0 e 15 %. Embora os fluxos médio e alto tenham indicado uma tendência de redução do erro percentual com o aumento da quantidade de veículos, a presença de *outliers* (valores com erros entre 15 e 35%) prejudica os valores médios, resultando em maior erro médio e maior desvio padrão nos cenários de fluxo alto e fluxo médio.

É importante discutir as razões que ocasionaram a existência de valores com erros percentuais maiores, entre 15% e 35%. Dos sete valores a partir da faixa de 15% de erro, cinco pertencem ao cenário de fluxo alto (**V10, V11, V12, V13 e V15**), enquanto os outros dois pertencem ao fluxo médio (**V16, V19**). Todos esses vídeos possuem uma característica em comum: apresentam uma composição de tráfego que destoa da dos demais vídeos da mesma categoria. Os cinco vídeos de fluxo alto (V10, V11, V12, V13 e V15) apresentam uma quantidade de veículos leves (motos e bicicletas) muito abaixo da média dos demais vídeos (respectivamente 102, 113, 81, 90 e 94 contra uma média de 148). Além disso, também apresentaram uma quantidade de veículos pesados acima da média dos demais vídeos. Como resultado, o erro “para menos” na contagem (a não detecção de veículos leves) acontece em menor proporção, não compensando completamente o erro “para mais” (a múltipla contagem de veículos de grande porte), resultando num erro maior que os demais. Os cinco resultados superestimaram a contagem real. A Tabela 3 exhibe a composição dos vídeos de alto fluxo mencionados.

Tabela 3 - Composição do Tráfego – *Outliers* (Fluxo Alto)

Vídeo	Total	Carros	Veículos Leves	Veículos Pesados	% Leves	% Pesados	Relação Leves/Pesados	Erro (%)
V10	347	220	102	25	29.39	7.20	4.08	14.99
V11	336	196	113	27	33.63	8.04	4.19	16.07
V12	335	218	81	36	24.18	10.75	2.25	24.18
V13	331	216	90	25	27.19	7.55	3.60	19.03
V15	325	206	94	25	28.92	7.69	3.76	17.85
Demais Vídeos (Média)	373	204	148	21	39.68	5.63	7.05	3.17

Fonte: Autor (2017)

Com relação aos dois vídeos de fluxo médio, ocorre o oposto. V16 e V19 apresentam uma quantidade de veículos leves bem maior que a média dos demais vídeos (149 e 129 contra uma média de 73). Assim, o erro “para menos” se torna mais

evidente, não sendo possível compensá-lo suficientemente com o erro “para mais”. Os dois vídeos apresentam ainda outro agravante: possuem quantidade de veículos pesados inferior à média dos demais vídeos de fluxo médio (19 e 17, enquanto a média dos demais é de 23). Como resultado, V16 e V19 subestimam a contagem de veículos, sendo responsáveis pelos maiores erros em seu nível de fluxo. A Tabela 4 compara a composição dos vídeos com a média dos demais vídeos de fluxo médio.

Tabela 4 - Composição do Tráfego – *Outliers* (Fluxo Médio)

Vídeo	Total	Carros	Veículos Leves	Veículos Pesados	% Leves	% Pesados	Relação Leves/Pesados	Erro (%)
V16	322	154	149	19	46.27	5.90	7.84	31.99
V19	313	167	129	17	41.21	5.43	7.59	26.52
Demais Vídeos (Média)	283	187	73	23	25.80	8.13	3.17	4.45

Fonte: Autor (2017)

Com a intenção de quantificar o impacto das duas principais fontes de erro (não detecção de veículos leves e múltipla detecção de veículos pesados), decidiu-se analisar separadamente a contagem de carros, veículos leves e veículos pesados. Para isso, selecionou-se um vídeo referente a cada nível de fluxo. Os vídeos selecionados foram V1 (maior fluxo), V24 (valor médio) e V45 (menor fluxo). A análise classificou o total de veículos, a quantidade de veículos contados corretamente, os veículos não contados e as contagens em excesso. A partir da soma de todas as contagens do algoritmo (contagens corretas e em excesso), determinou-se um fator de contagem para cada categoria de veículo. Os resultados obtidos são apresentados na Tabela 5.

Tabela 5 - Taxa de detecção de carros, veículos leves e veículos pesado por nível de fluxo

Vídeo	Categ.	Total	Contagem Correta	Contagem Correta (%)	Não Contado	Não Contado (%)	Contagem Extra	Total Contado	Fator de Contagem
V1	Carros	246	225	91.46	21	8.54	60	285	1.16
	Leves	153	69	45.10	84	54.90	3	72	0.47
	Pesados	21	19	90.48	2	9.52	59	78	3.71
V24	Carros	190	161	84.73	29	15.26	35	196	1.03
	Leves	75	35	46.66	40	53.33	2	37	0.49
	Pesados	23	22	95.65	1	4.34	33	55	2.39
V45	Carros	148	135	91.21	13	8.78	24	159	1.07
	Leves	35	14	40.00	21	60.00	1	15	0.43
	Pesados	16	16	100	0	0.00	23	39	2.43

Fonte: Autor (2017)

Os resultados indicam a eficiência da contagem de carros (taxa média de 89,1 % de contagem correta), mesmo diante da formação de filas e de longos períodos parados. Isso se deve à capacidade do método de rastrear pontos localizados em diferentes cantos do veículo e mantê-los unidos, estando em movimento ou não, permitindo o agrupamento correto e a diferenciação entre veículos.

Em contrapartida, o percentual de contagem correta de veículos leves manteve-se entre 40% e 50%, indicando a dificuldade do algoritmo de lidar com veículos de menores proporções, com menos pontos de destaque e maiores velocidades (o que implica em menor tempo de rastreamento). Com relação aos veículos pesados, observa-se que a contagem destes resulta em muitas contagens extras. Os fatores de contagem indicam que, na prática, para cada veículo pesado existente, foram contados entre 2,39 a 3,71 veículos, conforme o nível de fluxo.

5.3 Comparação das estratégias

Nesta seção, são comparados os resultados das contagens obtidas através das estratégias baseadas em características (*feature based* – FB) e em regiões (*region based* – RB). Os resultados desta última foram obtidos por CÂMARA (2014). Após a apresentação dos resultados, são analisados gráficos de dispersão dos dois métodos para cada nível de fluxo e também para todos os valores. Por fim, são comparados dados referentes a uma análise detalhada da contagem para os dois métodos.

Os resultados referentes aos vídeos de fluxo alto são apresentados abaixo.

Tabela 6 - Comparação das contagens dos vídeos de fluxo alto

# Vídeo	Contagem Real	Contagem RB	Contagem FB	E% RB	E% FB	FB supera RB?
V1	420	381	418	-9.29	+3.57	Sim
V2	402	411	381	+2.24	-5.22	Não
V3	397	426	378	+7.30	-4.79	Sim
V4	382	339	387	-11.26	+1.31	Sim
V5	368	418	359	+13.59	-2.45	Sim
V6	367	394	381	+7.36	+3.81	Sim
V7	360	361	340	+0.28	-5.56	Não
V8	358	391	361	+9.22	+0.84	Sim

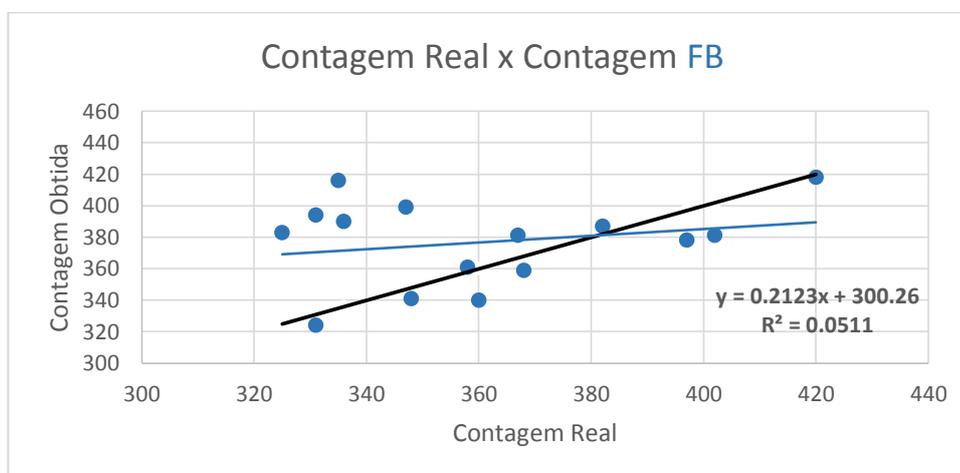
(Continua)

# Vídeo	Contagem Real	Contagem RB	Contagem FB	E% RB	E% FB	FB supera RB?
V9	348	411	341	+18.10	-2.01	Sim
V10	347	442	399	+27.38	+14.99	Sim
V11	336	407	390	+21.13	+16.07	Sim
V12	335	375	416	+11.94	+24.18	Não
V13	331	442	394	+33.53	+19.03	Sim
V14	331	326	324	-1.51	-2.11	Não
V15	325	412	383	+26.77	+17.85	Sim

Erro Médio (Módulo) **13.39** **8.25**
Desvio Padrão - σ **9.71** **7.54**

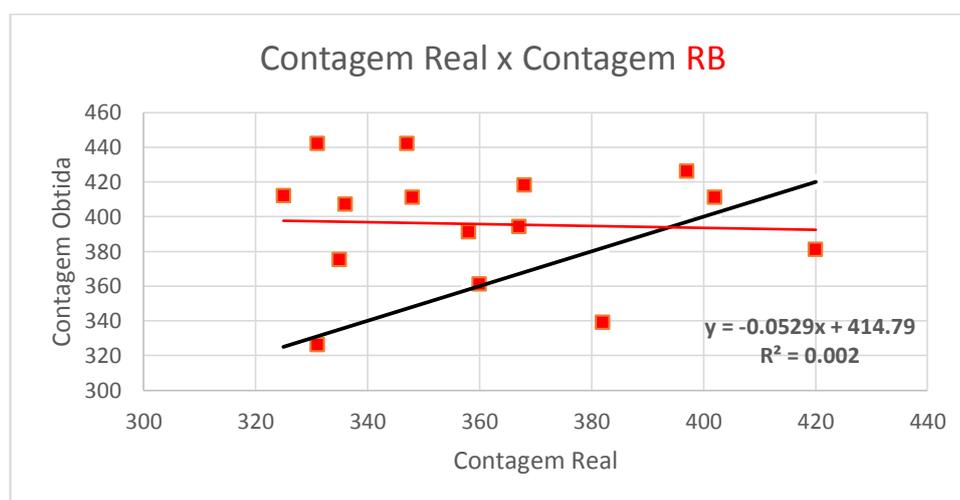
Fonte: Autor (2017)

Gráfico 2 - Gráfico de dispersão – Estratégia baseada em características (Fluxo Alto)



Fonte: Autor (2017)

Gráfico 3 - Gráfico de dispersão – Estratégia baseada em regiões (Fluxo Alto)



Fonte: Autor (2017)

A partir dos resultados, observa-se que a estratégia baseada em características obteve resultados superiores em 11 dos 15 vídeos analisados. O erro percentual médio foi menor, assim como o desvio padrão. Além disso, a reta de tendência apresenta o comportamento esperado, enquanto a linha de tendência da estratégia baseada em regiões caminha em sentido contrário ao esperado.

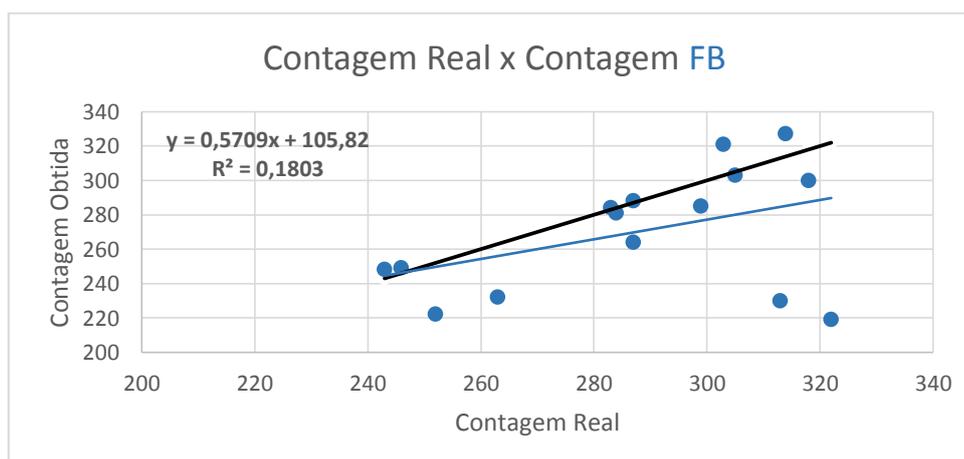
São apresentados os resultados obtidos para o cenário de fluxo médio.

Tabela 7 - Comparação das contagens dos vídeos de fluxo médio

# Vídeo	Contagem Real	Contagem RB	Contagem FB	E% RB	E% FB	FB supera RB?
V16	322	191	219	-40.68	-31.99	Sim
V17	318	287	300	-9.75	-5.66	Sim
V18	314	277	327	-11.78	+4.14	Sim
V19	313	215	230	-31.31	-26.52	Sim
V20	305	281	303	-7.87	-0.66	Sim
V21	303	303	321	0.00	+5.94	Não
V22	299	286	285	-4.35	-4.68	Não
V23	287	277	264	-3.48	-8.01	Não
V24	287	294	288	+2.44	+0.35	Sim
V25	284	275	281	-3.17	-1.06	Sim
V26	283	315	284	+11.31	+0.35	Sim
V27	263	310	232	+17.87	-11.79	Sim
V28	252	297	222	+17.86	-11.90	Sim
V29	246	207	249	-15.85	+1.22	Sim
V30	243	229	248	-5.76	+2.06	Sim
				Erro Médio (Módulo)	12.23	7.76
				Desvio Padrão - σ	10.90	9.24

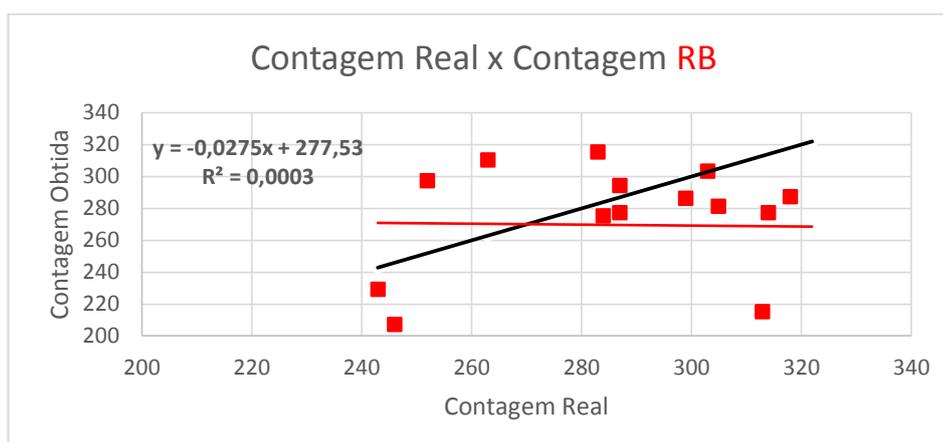
Fonte: Autor (2017)

Gráfico 4 - Gráfico de dispersão – Estratégia baseada em características (Fluxo Médio)



Fonte: Autor (2017)

Gráfico 5 - Gráfico de dispersão – Estratégia baseada em regiões (Fluxo Médio)



Fonte: Autor (2017)

No cenário de fluxo médio, observa-se que a estratégia baseada em características apresentou desempenho superior em 12 dos 15 vídeos analisados, apresentando menores erro percentual médio e desvio padrão. Além disso, apresentou coeficiente de determinação (R^2) superior e uma linha de tendência com o padrão esperado, diferente do observado na estratégia baseada em regiões.

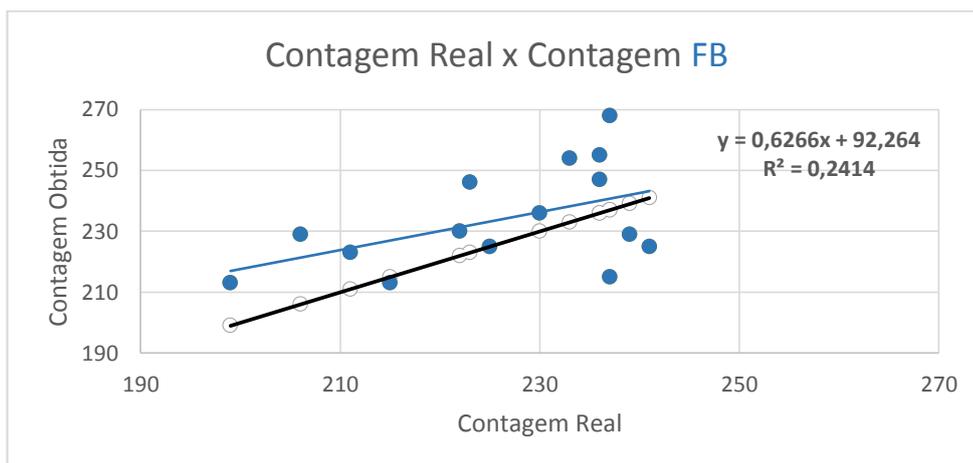
Por último, são apresentados os resultados do cenário de fluxo baixo.

Tabela 8 - Comparação das contagens dos vídeos de fluxo baixo

# Vídeo	Contagem Real	Contagem RB	Contagem FB	E% RB	E% FB	FB supera RB?
V31	241	218	225	-9.54	-6.64	Sim
V32	239	240	229	+0.42	-4.18	Não
V33	237	218	215	-8.02	-9.28	Não
V34	237	194	268	-18.14	+13.08	Sim
V35	236	212	255	-10.17	+8.05	Sim
V36	236	211	247	-10.59	+4.66	Sim
V37	233	209	254	-10.30	+9.01	Sim
V38	230	242	236	+5.22	+2.61	Sim
V39	225	226	225	+0.44	0.00	Sim
V40	223	212	246	-4.93	+10.31	Não
V41	222	188	230	-15.32	+3.60	Sim
V42	215	213	213	-0.93	-0.93	Igual
V43	211	200	223	-5.21	+5.69	Não
V44	206	197	229	-4.37	+11.17	Não
V45	199	216	213	+8.54	+7.04	Sim
			Erro Médio (Módulo)	7.48	6.42	
			Desvio Padrão - σ	5.00	3.67	

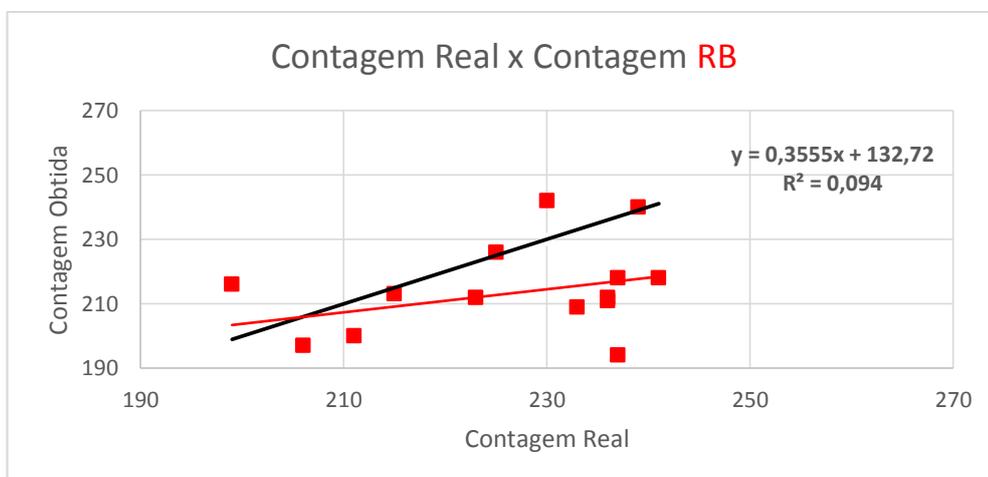
Fonte: Autor (2017)

Gráfico 6 - Gráfico de dispersão – Estratégia baseada em características (Fluxo Baixo)



Fonte: Autor (2017)

Gráfico 7 - Gráfico de dispersão – Estratégia baseada em regiões (Fluxo Baixo)

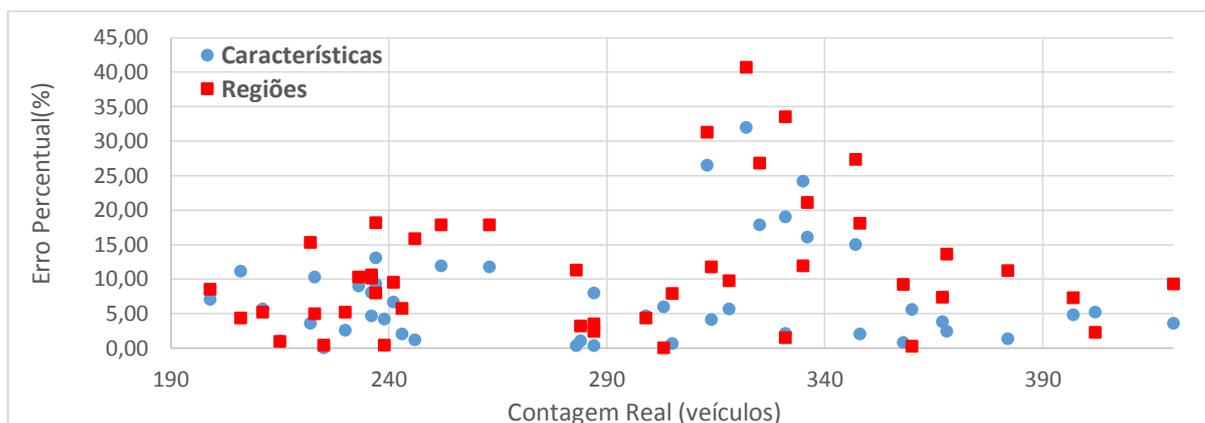


Fonte: Autor (2017)

Mesmo diante de um bom desempenho da estratégia baseada em regiões, a estratégia baseada em características apresentou resultados superiores em 9 dos 15 vídeos analisados. Apresentou, mais uma vez, menores erro médio percentual e desvio padrão, além de um coeficiente de determinação superior.

Por fim, um resumo das duas estratégias em termos de erro percentual é apresentado no Gráfico 8.

Gráfico 8 - Erros Percentuais – Características x Regiões



Fonte: Autor (2017)

A partir do gráfico, é possível observar que os erros da estratégia baseada em regiões são, em regra, maiores, apresentando também uma maior dispersão. Enquanto a maioria dos valores da estratégia de características encontram-se entre 0 e 15%, os valores baseados em regiões se distribuem, em sua maioria, entre as faixas de 0 e 20% de erro.

Outro aspecto importante evidenciado pelo gráfico diz respeito aos “*outliers*” mencionados anteriormente. Os vídeos que apresentaram a maior taxa de erro na estratégia baseada em características são também, na maioria dos casos, os responsáveis pelos maiores erros na estratégia baseada em regiões, sendo estes últimos ainda maiores do que os primeiros. Como são os mesmos vídeos (sujeitos à mesma composição de tráfego), isso sugere a dificuldade das duas estratégias em lidar com a presença de veículos de porte diferenciado (menor e maior porte), sendo a maior ou menor presença destes na composição de tráfego a principal razão para o desequilíbrio na compensação de erros e, por consequência, para o surgimento de erros maiores. Nesse aspecto, embora ainda apresente erros significativos, o desempenho da estratégia baseada em características também se mostrou superior.

Em seu trabalho, CÂMARA (2014) decidiu realizar uma análise detalhada da estratégia baseada em regiões, avaliando o nível de desempenho real do algoritmo e classificando cada detecção dentro de uma determinada categoria (detecção correta, segmentação, agrupamento, dupla contagem, falso positivo e falso negativo). Para tanto, selecionou um vídeo de cada nível de fluxo e realizou a análise manual das imagens.

Com o intuito de comparar a taxa de detecção correta das duas estratégias, o procedimento de CÂMARA (2014) foi replicado para a estratégia baseada em características. Feitas as devidas adaptações, os mesmos vídeos foram utilizados e tiveram suas contagens analisadas veículo por veículo. Cada alteração na contagem foi agrupada em uma das seguintes categorias:

- Detecção correta, quando a detecção é referente a um único veículo adequadamente agrupado;
- Segmentação, quando o agrupamento de um veículo é segmentado em agrupamentos menores, sendo detectado mais de uma vez;
- Agrupamento, quando dois ou mais veículos são agrupados conjuntamente e detectados como apenas um veículo;
- Dupla Contagem, quando um veículo é detectado e contabilizado mais de uma vez, mesmo apresentando pouca ou nenhuma variação em seu agrupamento;
- Falso Positivo, quando é detectado e contabilizado um agrupamento que não se refere a nenhum veículo existente;
- Falso Negativo, quando veículos ultrapassam a região de contagem sem que sejam detectados.

Os resultados das duas estratégias são apresentados nas Tabelas 9 e 10.

Tabela 9 - Análise detalhada – Estratégia Baseada em Regiões

Video	Cont. Real	Cont. Estimada	Detec. Correta	Taxa de Det. Correta	Segmentação	Agrupamento	Dupla Contagem	Falso	
								Pos.	Neg.
V1 (Alto)	420	380	236	56.2	6	43	80	15	141
V24 (Médio)	287	295	203	70.7	0	19	64	9	65
V45 (Alto)	199	214	145	72.9	3	17	37	12	37

Fonte: Autor (2017)

Tabela 10 - Análise detalhada – Estratégia Baseada em Características

Video	Cont. Real	Cont. Estimada	Detec. Correta	Taxa de Det. Correta	Segmentação	Agrupamento	Dupla Contagem	Falso	
								Pos.	Neg.
V1 (Alto)	420	435	293	69.8	60	20	54	0	111
V24 (Médio)	287	288	203	70.7	38	25	22	2	70
V45 (Baixo)	199	213	163	81.9	26	7	16	1	38

Fonte: Autor (2017)

A estratégia baseada em regiões apresentou uma taxa média de detecção correta de 66,6%, com seu desempenho melhorando conforme a diminuição do tráfego. Segundo CÂMARA (2014), as principais fontes de erro dessa estratégia (falsos negativos e dupla contagem) se dão por conta da baixa detecção de motos e da grande variação da velocidade dos veículos, respectivamente. As motos são agrupadas com outros veículos quando o fluxo interrompido é retornado. Além disso, durante o fluxo livre, passam tão rapidamente que não há tempo hábil para rastrearlas corretamente. Com relação à dupla contagem, além da variação na velocidade dos veículos, a interrupção do fluxo se revelou prejudicial, uma vez que os veículos parados passaram a ser considerados como parte do plano de fundo e, ao se movimentarem, foram contabilizados novamente.

Por sua vez, a estratégia baseada em características teve uma taxa média de acerto de 74,1%, apresentando desempenho superior. Assim como na outra estratégia, a taxa de acerto evoluiu com a diminuição do fluxo. As principais limitações da estratégia se deram por conta da baixa detecção de motos e bicicletas (resultando em uma grande quantidade de falsos negativos) e da segmentação de veículos de grande porte, como caminhões e ônibus.

As duas estratégias apresentaram o melhor desempenho durante a execução de vídeos com fluxo baixo. Isso se deveu à menor formação de filas e ao maior espaçamento entre veículos durante a movimentação, facilitando a execução correta das etapas de detecção, agrupamento e rastreamento.

A estratégia baseada em características apresentou uma menor quantidade de agrupamentos errados de veículos, menor dupla contagem e quase inexistência em termos de falsos positivos. A menor quantidade de agrupamentos inadequados se deve à própria proposta da estratégia em si, que detecta diversos cantos de um veículo e os liga com base nas distâncias máximas delimitadas e no padrão de movimentação destes pontos. Assim, a possibilidade de dois ou mais veículos serem unidos se torna bem menor do que na estratégia baseada em regiões, onde pixels com propriedades de intensidade semelhantes são condensados em uma mesma região (*blobs*).

Com relação à menor quantidade de dupla contagem, nessa estratégia, a etapa de subtração de fundo utiliza um método adaptativo e em constante alteração, evitando que os veículos sejam assumidos como fundo fixo mesmo após muitos frames parados. Isso não ocorre na estratégia baseada em regiões, onde os veículos são assumidos como fundo e contabilizados novamente no reinício do movimento. Por fim, a quase inexistência de falsos positivos detectados se dá por conta da existência de parâmetros de calibração que exigem uma quantidade mínima de cantos detectados (*features*) para que um agrupamento seja considerado um veículo. Assim, com base no ajuste de parâmetros é possível evitar a contabilização de falsos agrupamentos criados por variações de iluminação na pista.

A principal limitação dos dois métodos no cenário em questão consistiu na detecção insatisfatória de motocicletas e bicicletas. A baixa resolução das imagens, associada às pequenas dimensões desses veículos, tem importante efeito negativo no fenômeno, sendo difícil observar com clareza algumas motos mesmo no vídeo original. Assim, muitas vezes os veículos leves não são agrupados porque não há quantidade suficiente de cantos detectados em virtude da baixa resolução e da instabilidade da câmera, sujeita à ação do vento.

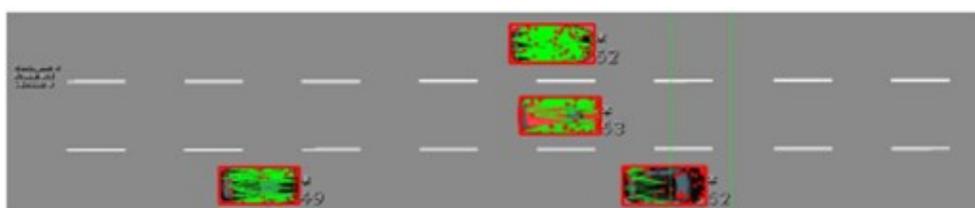
O comportamento dos usuários também dificulta a detecção por parte do algoritmo: mesmo em situações de fluxo interrompido, as motos trafegam entre as filas de carro, formando verdadeiros comboios com quase nenhum espaço entre elas. Em situações de veículos parados, diversas motos são agrupadas juntamente com carros e ônibus, por conta da distância mínima entre eles e de não existir diferença de velocidade entre os veículos nessas situações.

A instabilidade da câmera também apresenta efeito negativo na execução do algoritmo. Por conta do forte vento a que está sujeita, a câmera varia sua posição, ainda que ligeiramente, com bastante frequência (em intervalos de segundos). Como resultado disso, o algoritmo acaba perdendo pontos detectados, muitas vezes fragmentando o agrupamento originário formado. Essa é a principal razão dos altos valores de segmentação. Importante também indicar que a segmentação dos veículos de grande porte, como ônibus e caminhões, tem relação direta com suas grandes dimensões, sendo difícil para o algoritmo manter ligações duradouras entre vários pontos distantes, ainda mais em um cenário de baixa resolução e sem estabilidade.

Outro aspecto a ser mencionado diz respeito à posição e ao ângulo de câmera, que dificultam a formação de agrupamentos corretos. Como os agrupamentos são feitos e mantidos com base nas distâncias horizontal e vertical entre pontos, a identificação correta dos agrupamentos passa pela separação entre eles, com base nas distâncias entre os dois veículos. Diferentemente da situação real trabalhada, com visão “de frente”, desfavorecendo a observação do espaço entre os veículos, uma visão de cima seria ideal, partindo do centro da região de interesse da via e com a menor inclinação ou projeção de sombra dos veículos possível.

Nesse sentido, LIRA *et al.* (2017) analisaram a eficiência de contagens volumétricas para cenários controlados gerados no microssimulador VISSIM, com posicionamento da câmera como descrito acima. O ângulo de filmagem é apresentado na Figura 18. As contagens volumétricas apresentaram erros entre 1% e 3%. É importante indicar que o algoritmo utilizado foi o mesmo com que se desenvolveu este trabalho, tendo sido a calibração dos cenários feita com base em observações dele provenientes. Assim, fica clara a importância das condições de câmera e do espaçamento entre os veículos para a detecção e contagem. Apesar disso, deve-se lembrar que o experimento utilizou-se de um cenário ideal, com condições controladas e sem a presença de veículos leves, diferentemente do trabalho aqui apresentado.

Figura 18 - Ângulo de câmera utilizado pelo microssimulador VISSIM



6 CONCLUSÕES

Em um contexto de rápido desenvolvimento tecnológico, a multiplicação das câmeras e dos sistemas de monitoramento propiciou o surgimento de novas ferramentas utilizadas no planejamento, na operação e na manutenção dos sistemas de transportes. A evolução da Visão Computacional tornou possível a criação de algoritmos que detectam, rastreiam e contam veículos de forma automatizada, com base na utilização de imagens de vídeo.

Dentre as principais estratégias de rastreamento e contagem veicular, destacam-se a estratégia baseada em regiões (*region based*, em inglês) e a estratégia baseada em características (*feature based*). A estratégia baseada em regiões detecta pixels de intensidade semelhante, agrupando-os com base em sua proximidade e formando os *blobs*, os quais são assumidos como veículos, sendo rastreados. Já a estratégia baseada em características abandona a ideia de rastrear veículos como um todo e passa a rastrear características que se destacam em um automóvel, como, por exemplo, faróis e vidros de um carro.

O presente trabalho comparou desempenho em termos de contagens volumétricas das duas estratégias quando aplicadas a um mesmo cenário urbano, caracterizado pelo tráfego interrompido, apresentando menor espaçamento entre veículos e grande diversidade de veículos (carros, ônibus, caminhões, motocicletas e bicicletas).

Para tanto, foram utilizados 45 vídeos coletados no cruzamento entre as avenidas Borges de Melo e Luciano Carneiro, tendo sido os vídeos coletados por CÂMARA (2014), que em seu trabalho realizou a análise do desempenho da estratégia baseada em regiões. Cada vídeo utilizado apresenta duração de 15 minutos. Os vídeos foram classificados em três categorias de nível de fluxo (fluxo alto, médio e baixo) com base na quantidade de veículos contabilizados em cada vídeo.

Procedeu-se então à análise da estratégia baseada em características. Foram feitas modificações no algoritmo, considerando o interesse do trabalho exclusivamente em contagens volumétricas. Em seguida, os parâmetros de detecção, agrupamento e rastreamento do algoritmo foram calibrados com base em observação direta, até que os vídeos analisados (três vídeos em cada nível de fluxo)

apresentassem um erro percentual menor do que 7%. De posse dos resultados, as duas estratégias foram então comparadas.

A comparação entre as duas estratégias indicou que a estratégia baseada em características apresentou desempenho superior em termos de contagens volumétricas em área urbana. Com erros percentuais de apenas 8,05 % (fluxo alto), 7,76 % (fluxo médio) e 6,42 % (fluxo baixo), essa estratégia foi superior à estratégia baseada em regiões, que apresentou erros de 13,39 %, 12,23 % e 7,48 %, respectivamente. A estratégia baseada em características obteve ainda uma menor dispersão e um maior coeficiente de determinação (R^2) em cada um dos três níveis de fluxo analisados.

Também foi realizada uma análise detalhada das duas estratégias. Nessa comparação, foram selecionados três vídeos (um referente a cada nível de fluxo) e então analisou-se, para cada uma das estratégias, todos os frames executados. O objetivo dessa análise foi verificar a taxa de detecção correta das duas estratégias, uma vez que a análise macroscópica incorpora erros de não detecção de motos ou múltiplas contagens de veículos de grande porte. Além disso, a análise detalhada permitiu reconhecer as principais fontes de erro em cada estratégia.

A estratégia de rastreamento baseada em características apresentou novamente desempenho superior, com taxas de detecção correta de 69,8 %, 70,7 % e 81,9 % para os fluxos alto, médio e baixo, respectivamente, indicando uma taxa média de 74,1 % de detecção correta. A estratégia baseada em regiões, por sua vez, apresentou taxas de detecção corretas de 56,2 %, 70,7 % e 72,9 % para os mesmos níveis de fluxo, resultando em uma média de 66,6 % de detecção correta.

Ademais, o método baseado em características apresentou uma menor quantidade de erros de agrupamento e de dupla contagem, além de uma menor detecção de falsos positivos, indicando que a estratégia possui maior capacidade de lidar com a peculiaridade do tráfego urbano, onde os veículos mantêm-se mais próximos e também parados por longos períodos, facilitando erros de agrupamento e de dupla contagem. Por outro lado, essa estratégia apresentou uma quantidade significativa de segmentações, observadas principalmente em veículos de grande porte e associadas aos fortes ventos que impedem a estabilização da câmera.

A principal limitação observada, entretanto, é comum aos dois métodos: a baixa detecção de veículos leves, resultando em uma alta quantidade de falsos negativos. Isso acontece por conta das pequenas dimensões desses veículos e das altas velocidades desenvolvidas quando o sinal está aberto. Além disso, com o tráfego parado, aproximam-se muito umas das outras, dificultando a detecção individual. Outro fator importante é a baixa resolução da câmera utilizada, dificultando ainda mais o processo de detecção de motocicletas e bicicletas.

Existe também a necessidade de um maior aprofundamento nas etapas do algoritmo referentes à detecção de pontos e ao rastreamento. A falta do completo domínio na compreensão dos parâmetros existentes pode impedir a obtenção de resultados superiores em termos de agrupamento e contagem. Além de uma aprofundada pesquisa sobre os aspectos que geram dúvidas, acredita-se que a avaliação de cenários controlados, com variação estratégica desses parâmetros, pode auxiliar na maior compreensão do efeito isolado de cada variável.

Por fim, cabe destacar a presença de diversos elementos que comprometem a detecção e o rastreamento adequado por parte do algoritmo, dificultando, conseqüentemente, as contagens. Além das peculiaridades do fluxo interrompido, fatores como a instabilidade da câmera, o ângulo de gravação e a baixa resolução das imagens têm impacto direto na qualidade dos resultados. No cenário analisado, todos esses fatores se fazem presentes ao mesmo tempo, prejudicando os valores finais. Nesse sentido, uma sugestão é a de analisar o impacto de cada um desses fatores de forma isolada e controlada, buscando avaliar quais parâmetros possuem maior influência em cada aspecto, além de determinar quais valores de calibração minimizam os efeitos adversos de cada uma das condições não controladas.

Uma vez superadas as limitações em termos de tempo de processamento e de reconhecimento de veículos de dimensões diferenciadas, os resultados obtidos a partir da aplicação em cenário urbano do algoritmo baseado em características indicam que a utilização de algoritmos de Visão Computacional com essa estratégia pode, sim, se tornar uma importante ferramenta no auxílio da gestão do tráfego em tempo real.

REFERÊNCIAS BIBLIOGRÁFICAS

BARCELLOS, P. R. M. **Detecção e Contagem de Veículos em Vídeos de Tráfego Urbano**. (2014). Dissertação (Mestrado em Ciência da Computação) – Instituto de Informática, Programa de Pós-Graduação em Computação, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2014.

BARCELLOS, P.; GOMES, V. e SCHARCANSKI, J. Shadow detection in camera-based vehicle detection: survey and analysis. (2016). **Journal of Electronic Imaging**, 18 maio 2016.

BRASIL, Ministério do Meio Ambiente. **Mobilidade Sustentável**. Brasília: 2012. Disponível em: <<http://www.mma.gov.br/cidades-sustentaveis/urbanismo-sustentavel/mobilidade-sustentavel>>. Acesso em: 8 abr. 2017.

BRITTO, G. R. **Desenvolvimento de Algoritmo para “Tracking” de Veículos**. (2011). Monografia (Graduação em Engenharia de Sistemas Eletrônicos) – Escola Politécnica da Universidade de São Paulo, São Paulo, 2011.

BUCH, N.; VELASTIN, S.A.; ORWELL, J. **A Review of Computer Vision Techniques for the Analysis of Urban Traffic**. (2011). IEEE Transactions on Intelligent Transportation Systems, [S.1.], v.12, n.3, p920-939, Sept. 2011

BUCH, N.; YIN, F.; ORWELL, J.; MAKRIS, D.; VELASTIN, S.A. **Urban Vehicle Tracking Using a Combined 3D Model Detector and Classifier**. (2009). Lecture Notes in Computer Science, vol 5711. Springer, Berlin, Heidelberg.

CÂMARA, S. M. **A utilização da Visão Computacional em contagens volumétricas de tráfego em áreas urbanas**. (2014). Monografia (Graduação em Engenharia Civil) – Centro de Tecnologia, Universidade Federal do Ceará, Fortaleza, 2014.

CENTER FOR TRANSPORTATION RESEARCH AND EDUCATION. Traffic Handbook. **Traffic Volume Counts**. Disponível em: < <http://www.ctre.iastate.edu/pubs/traffichandbook/3trafficcounst.pdf>>. Acesso em: 25 maio 2017.

COIFMAN, B.; BEYMER, D.; MCLAUHLAN, P. e MALIK, J. **A real-time computer vision system for vehicle tracking and traffic surveillance**. (1998). Institute of Transportation Studies, University of California, Berkeley, Department of Electrical Engineering and Computer Sciences, University of California, Berkeley.

DEPARTAMENTO NACIONAL DE INFRA-ESTRUTURA DE TRANSPORTES.
Manual de estudos de tráfego. Rio de Janeiro, RJ, 2006.

FAN, Z.; ZHOU, J.; GAO, D.; ZHIHENG, L. **Contour Extraction and Tracking of Moving Vehicles for Traffic Monitoring.** (2002). IEEE 5th International Conference on Intelligent Transportation Systems.

FEDERAL HIGHWAY ADMINISTRATION RESEARCH AND TECHNOLOGY. Traffic Detector Handbook. **Chapter 2 – Sensor Technology.** Disponível em: <<https://www.fhwa.dot.gov/publications/research/operations/its/06108/02.cfm>>. Acesso em: 2 junho 2017.

GUPTA, S.; MASOUD, O.; MARTIN, R. F. K. e PAPANIKOLOPOULOS, N. P. **Detection and Classification of Vehicles.** (2002). IEEE. Transaction on Intelligent Transportation Systems, vol. 3.

HUANG, D.; CHEN, C.; HU, W.; YI, S. e LIN, Y. **Feature-Based Vehicle Flow Analysis and Measurement for a Real-Time Traffic Surveillance System.** (2012). Dayeh University, National Kaohsiung University of Applied Sciences, National Penghu University of Science and Technology, National Changhua University of Education. Taiwan.

KOLLER, D. **Model-Based Object Tracking in Road Traffic Scenes.** (1996). Disponível em: <<http://www.vision.caltech.edu/koller/ModelTracking.html>> Acesso em: 4 junho 2017.

LAURESHYN, A. **Application of automated video analysis to road user behavior.** (2010). Traffic and Roads, Department of Technology and Society, Faculty of Engineering, Lund University, Lund, Sweden.

LESSARD, A.; BELISLE, F.; BILODEAU, G.A. e SAUNIER, N. **The CountingApp, or How to Count Vehicles in 500 Hours of Video.** (2016). Polytechnique Montréal, WSP Canada Inc. Montreal, Canada.

LIRA, J.; LIMA, M.; FROTA, J.; CUNTO, F. **Qualidade de Estratégias de Visão Computacional na Confecção de Diagramas Espaço-Tempo em Áreas Urbanas.** (2017). In: ASSOCIAÇÃO NACIONAL DE PESQUISA E ENSINO EM TRANSPORTES (ANPET), 2017, Recife.

MORSE, P.; ST-AUBIN, P.; MIRANDA-MORENO, L. e SAUNIER, N. **Transferability Study of Video Tracking Optimization for Traffic Data Collection and Analysis.** (2015). McGill University, Polytechnique Montréal. Montreal, Canada.

OPENCV. OpenCV-Python Tutorials. **Feature Detection and Description - Shi-Tomasi Corner Detector & Good Features to Track.** Disponível em: < http://docs.opencv.org/3.0-beta/doc/py_tutorials/py_feature2d/py_shi_tomasi/py_shi_tomasi.html>. Acesso em: 4 maio 2017.

OPENCV. OpenCV-Python Tutorials. **Optical Flow - Lukas-Kanade method.** Disponível em: < http://docs.opencv.org/trunk/d7/d8b/tutorial_py_lucas_kanade.html> Acesso em: 4 maio 2017.

ROESS, R.; PRASSAS, E.; MCSHANE, W. **Traffic Engineering – Fourth Edition.** (2014). Polytechnic Institute of New York University. Editora Pearson.

SAUNIER, N. e SAYED, T. **A Feature-Based Tracking Algorithm for Vehicles in Intersections.** (2006). Polytechnique Montréal, University of British Columbia – Vancouver. Canada.

**APÊNDICE A – RESULTADOS DAS CONTAGENS DAS ESTRATÉGIAS
BASEADAS EM REGIÕES (RB) E EM CARACTERÍSTICAS (FB)**

Vídeo	Contagem Total	Carros	Veic. Leves	Veic. Pesados	Contagem RB	Erro % RB	Contagem FB	Erro % FB
V1	420	244	156	20	381	9.29	435	3.57
V2	402	233	149	20	411	2.24	381	5.22
V3	397	238	135	24	426	7.30	378	4.79
V4	382	185	176	21	339	11.26	387	1.31
V5	368	206	145	17	418	13.59	359	2.45
V6	367	182	163	22	394	7.36	381	3.81
V7	360	218	122	20	361	0.28	340	5.56
V8	358	227	106	25	391	9.22	361	0.84
V9	348	155	171	22	411	18.10	341	2.01
V10	347	220	102	25	442	27.38	399	14.99
V11	336	196	113	27	407	21.13	390	16.07
V12	335	218	81	36	375	11.94	416	24.18
V13	331	216	90	25	442	33.53	394	19.03
V14	331	149	158	24	326	1.51	324	2.11
V15	325	206	94	25	412	26.77	383	17.85
V16	322	154	149	19	191	40.68	219	31.99
V17	318	191	105	22	287	9.75	300	5.66
V18	314	199	90	25	277	11.78	327	4.14
V19	313	167	129	17	215	31.31	230	26.52
V20	305	200	84	21	281	7.87	303	0.66
V21	303	206	74	23	303	0.00	321	5.94
V22	299	196	76	27	286	4.35	285	4.68
V23	287	195	73	19	277	3.48	264	8.01
V24	287	187	76	24	294	2.44	288	0.35
V25	284	184	74	26	275	3.17	281	1.06
V26	283	188	71	24	315	11.31	284	0.35
V27	263	178	63	22	310	17.87	232	11.79
V28	252	163	64	25	297	17.86	222	11.90
V29	246	169	52	25	207	15.85	249	1.22
V30	243	176	53	14	229	5.76	248	2.06
V31	241	163	49	29	218	9.54	225	6.64
V32	239	165	57	17	240	0.42	229	4.18
V33	237	154	67	16	218	8.02	215	9.28
V34	237	157	58	22	194	18.14	268	13.08
V35	236	157	59	20	212	10.17	255	8.05
V36	236	166	53	17	211	10.59	247	4.66
V37	233	160	52	21	209	10.30	254	9.01
V38	230	156	53	21	242	5.22	236	2.61
V39	225	146	52	27	226	0.44	225	0.00
V40	223	153	51	19	212	4.93	246	10.31
V41	222	143	66	13	188	15.32	230	3.60

Vídeo	Contagem Total	Carros	Veic. Leves	Veic. Pesados	Contagem RB	Erro % RB	Contagem FB	Erro % FB
V42	215	135	56	24	213	0.93	213	0.93
V43	211	128	59	24	200	5.21	223	5.69
V44	206	135	47	24	197	4.37	229	11.17
V45	199	147	33	19	216	8.54	213	7.04