



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIAS
DEPARTAMENTO DE ENGENHARIA DE TRANSPORTES
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE TRANSPORTES

DÊNYS ARAÚJO SANTOS

**DIAGRAMAS VEICULARES ESPAÇO-TEMPO EM VIAS URBANAS UTILIZANDO
A VISÃO COMPUTACIONAL**

FORTALEZA

2017

DÊNYS ARAÚJO SANTOS

DIAGRAMAS VEICULARES ESPAÇO-TEMPO EM VIAS URBANAS UTILIZANDO A
VISÃO COMPUTACIONAL

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

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

Coorientador: Prof. André Luiz Barbosa Nunes da Cunha, Ph.D.

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)

- S234d Santos, Dênnys.
Diagramas veiculares espaço-tempo em vias urbanas utilizando a visão computacional / Dênnys Santos.
– 2017.
81 f. : il. color.
- Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de PósGraduação em Engenharia de Transportes, Fortaleza, 2017.
Orientação: Prof. Dr. Flávio José Craveiro Cunto.
Coorientação: Prof. Dr. André Luiz Barbosa Nunes da Cunha.
1. Fluxo microscópico urbano. 2. Diagrama espaço-tempo. 3. Visão computacional. 4. Feature-based tracking. I. Título.

CDD 388

DÊNENYS ARAÚJO SANTOS

DIAGRAMAS VEICULARES ESPAÇO-TEMPO EM VIAS URBANAS UTILIZANDO A
VISÃO COMPUTACIONAL

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

Aprovada em: 29/08/2017.

BANCA EXAMINADORA

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

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

Prof. Dr. Manoel Mendonça de Castro Neto
Universidade Federal do Ceará (UFC)

Profa. Dra. Helena Beatriz Bettella Cybis
Universidade Federal do Rio Grande do Sul (UFRGS)

FORTALEZA
2017

Dedico aos meus pais Jacinto Eliseu e Lúcia de Fátima e ao meu irmão Dênyson Eliseu.

AGRADECIMENTOS

A Deus, por tudo.

Aos meus pais Jacinto Eliseu e Lúcia de Fátima e ao meu irmão Dênyson Eliseu por tudo que são.

Ao professor, orientador e amigo Flávio Cunto por todos os imensuráveis ensinamentos acadêmicos, profissionais e pessoais.

Ao coorientador André Cunha pela dedicação na construção deste trabalho e aos professores Manoel Castro e Helena Cybis pelas imensas contribuições.

A amiga Vanessa pelo carinho e parceria em todos os momentos do mestrado.

A todos que participaram da Equipe de Visão Computacional, responsável por dar vida a este projeto.

A namorada Tanara Araújo, por tudo que é.

Aos amigos Robson Gilney e Jorge França pela irmandade.

Aos amigos de Fortaleza, em especial Leonardo Rocha e Camilo Damasceno por abrirem suas casas.

A todos do PETRAN pelos conhecimentos e momentos compartilhados, em especial aos integrantes do GTTEMA.

À administração do Shopping Del Paseo que possibilitou a realização das filmagens utilizadas neste trabalho.

A todos que fizeram parte desta viagem.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES – Código de Financiamento 001).

“Não temas a pressão. Lembra-te que é ela que transforma um pedaço de carvão em diamante.”
(Tiago 1:3,4)

RESUMO

A gestão do tráfego veicular urbano brasileiro carece de estratégias mais robustas para estimação de variáveis desagregadas com alto nível de acurácia. O diagrama espaço-tempo é uma ferramenta clássica de análise de tráfego, mas ainda relevante nos dias de hoje. Por sua vez, a Visão Computacional tem sido amplamente utilizada com sucesso em estudos de tráfego. Dentre os principais métodos utilizados nestes estudos, o rastreamento baseado em pontos notáveis (*Feature-based tracking*) tem se mostrado o mais apropriado para o ambiente urbano por lidar bem com situações de oclusão parcial dos veículos, interrupções de movimentos dos veículos entre outras. Assim, este trabalho teve como objetivo a construção de diagramas veiculares espaço-tempo utilizando a Visão Computacional para estimação de variáveis do fluxo microscópico urbano. Por conseguinte, esta dissertação propõe um método para auxiliar estudos desagregados de tráfego interrompido veicular urbano através de diagramas espaço-tempo. O algoritmo desenvolvido neste trabalho apresentou uma taxa de acertos de 91,52% para a contagem veicular. A seguir, conduziu-se um estudo de caso para estimar variáveis de caracterização de tráfego urbano de fluxo interrompido através de diagramas espaço-tempo construídos através de informações veiculares extraídas pelo algoritmo de Visão Computacional. Pôde-se fazer estimação dos seguintes parâmetros: comprimento veicular, distância entre veículos parados, comprimento de fila, número de veículos parados, número de mudanças de faixa, velocidade média, atraso médio e *headway*. Ao fim, constatou-se a robustez do algoritmo de Visão Computacional desenvolvido bem como a fidelidade dos diagramas espaço-tempo. Portanto, o método proposto neste trabalho mostrou-se ser viável e flexível para diversos estudos desagregados de tráfego veicular microscópico urbano.

Palavras-chave: fluxo microscópico urbano, diagrama espaço-tempo, visão computacional, *feature-based tracking*.

ABSTRACT

The Brazilian management of urban vehicular traffic lacks robust strategies for disaggregated variables estimation with a high level of accuracy. The space-time diagram is a classic tool for traffic analysis and still relevant nowadays. In turn, the Computer Vision has been widely used successfully in traffic studies. Amongst the main methods used in these studies, the Feature-based tracking has proved to be the most suitable for the urban environment for dealing adequately with situations of partial occlusion of vehicles, interruptions of vehicle movements among others. Thus, this work aims to use Computer Vision to produce space-time diagrams and to estimate urban microscopic flow variables. Therefore, this dissertation proposes a method to assist disaggregated studies of urban vehicular traffic through space-time diagrams. The algorithm developed in this work had a success rate of 91,52% for vehicle counting. Then, a case study was conducted to estimate variables of characterization of urban traffic of interrupted flow through the space-time diagrams created by using the vehicular information extracted by the Computer Vision algorithm. The following parameters were estimated: vehicle length, distance between stopped vehicles, queue length, number of stopped, number of lane changes, average speed, average delay and headway. By the end, the robustness of the Computer Vision algorithm as well as the fidelity of the space-time diagrams were verified. Therefore, the method proposed in this work proved to be viable and flexible to be used in several disaggregated studies of urban microscopic vehicular traffic.

Keywords: urban microscopic flow, space-time diagram, computer vision, feature-based tracking.

LISTA DE FIGURAS

Figura 1 - Exemplo de diagrama espaço-tempo (Autor)	21
Figura 2 - Diagramas espaço-tempo representando ondas de choque (Coifman, 1997)	22
Figura 3 - Diagrama espaço-tempo 3D (Anwar et al., 2014)	23
Figura 4 - À esquerda, modelos veiculares definidos para uso do algoritmo. À direita, exemplo de detecção dos veículos (Buch et al., 2008)	25
Figura 5 - À esquerda, imagem original. Ao centro, subtração de fundo. À direita, detecção veicular (Câmara et al., 2015)	26
Figura 6 - Detecção veicular através de contorno ativo (Peterfreund, 1999)	26
Figura 7 - À esquerda, detecção de pontos. Ao centro, rastreamento dos pontos detectados. À direita, hipóteses veiculares para agrupamento (Beymer et al., 1997)	27
Figura 8 - Método proposto para desenvolvimento da dissertação (Autor)	31
Figura 9 - Etapas metodológicas do estudo de caso	33
Figura 10 - Diagrama para o algoritmo de rastreamento de veículos (Autor)	36
Figura 11 - Definição da região de interesse – ROI (Autor)	37
Figura 12 - Homografia executada pelo algoritmo (Autor)	38
Figura 13 - Superior: veículo na região de interesse. Inferior: subtração de fundo (Autor)	39
Figura 14 - Regiões do processamento do algoritmo e exemplo de rastreamento (Autor)	39
Figura 15 - Resultado da contagem veicular (Autor)	44
Figura 16 - Localização da interseção analisada (Google Earth)	46
Figura 17 - Posicionamento da câmera para obtenção de imagens de vídeo do tráfego (Autor)	47
Figura 18 - Maior (esquerda) e menor (direita) distância entre veículos parados (Autor)	51
Figura 19 - Representação gráfica dos headways veiculares (Autor)	57

LISTA DE TABELAS

Tabela 1 - Parâmetros calibrados do algoritmo de Visão Computacional (Autor)	43
Tabela 2 - Comparação entre as contagens volumétricas reais e a obtidas pelo algoritmo (Autor)	43
Tabela 3 - Estatística descritiva da contagem veicular (Autor).....	45
Tabela 4 - Estimação do comprimento veicular individual (Autor).....	50
Tabela 5 - Estimação da distância entre veículos parados e do comprimento de fila (Autor) .	51
Tabela 6 - Estatística descritiva da estimação da distância entre veículos parados e do comprimento de fila (Autor)	52
Tabela 7 - Estimação de velocidade média e atraso veicular (Autor)	54
Tabela 8 - Estatística descrita da estimação de velocidade média e atraso veicular (Autor) ...	55
Tabela 9 - Estatística descritiva da estimação de headways (Autor).....	56
Tabela 10 - Estimação de número de mudanças de faixa (Autor).....	57

SUMÁRIO

1	INTRODUÇÃO.....	13
1.1	Problema de Pesquisa.....	15
1.2	Questões de Pesquisa	16
1.3	Objetivos de Pesquisa	16
1.3.1	<i>Objetivo Geral</i>	16
1.3.2	<i>Objetivos Específicos</i>	16
1.4	Estrutura da Dissertação	17
2	REVISÃO DA LITERATURA.....	18
2.1	Tráfego Urbano Interrompido	18
2.1.1	<i>Diagramas Espaço-Tempo</i>	20
2.2	Visão Computacional Aplicada a Estudos de Tráfego Veicular	24
2.2.1	<i>Ferramentas Computacionais</i>	29
3	MÉTODO PROPOSTO	31
3.1	Investigação das Estratégias de Visão Computacional	31
3.2	Desenvolvimento do Algoritmo de Visão Computacional.....	32
3.3	Calibração do Algoritmo de Visão Computacional.....	32
3.4	Aplicação de Estudo de Caso.....	33
3.4.1	<i>Definição da Área de Estudo</i>	33
3.4.2	<i>Aquisição de Imagens</i>	34
3.4.3	<i>Pré-Processamento dos Vídeos</i>	34
3.4.4	<i>Construção dos Diagramas Espaço-Tempo</i>	34
3.4.5	<i>Estimação de Variáveis de Fluxo Interrompido</i>	35
4	DISCUSSÃO DOS RESULTADOS	36
4.1	Desenvolvimento do Algoritmo de Visão Computacional.....	36
4.2	Calibração do Algoritmo de Visão Computacional.....	41
4.3	Aplicação de Estudo de Caso.....	45
4.3.1	<i>Definição da Área de Estudo</i>	45
4.3.2	<i>Aquisição de Imagens</i>	46
4.3.3	<i>Pré-Processamento dos Vídeos</i>	47
4.3.4	<i>Construção dos Diagramas Espaço-Tempo</i>	48
4.3.5	<i>Estimação de Variáveis</i>	48
5	CONCLUSÃO.....	58

REFERÊNCIAS.....	62
APÊNDICE A	68
APÊNDICE B.....	69

1 INTRODUÇÃO

Fenômenos como a elevação do nível de saturação da malha viária urbana aumentam a complexidade deste sistema que requer estratégias cada vez mais robustas para atender as necessidades da gestão do tráfego e da segurança viária. Por sua vez, os estudos que embasam a gestão do tráfego urbano demandam levantamentos minuciosos de informações e a aplicação destas informações em tempo real tem se tornado cada vez mais importante do ponto de vista operacional (Coifman *et al.*, 1998; Tancredi e Widmer, 2012). Assim, o grau de dificuldade de aquisição e a capacidade de processamento dos dados são dois dos principais condicionantes para a aplicação de cada método de estudo de tráfego. Estas informações são utilizadas em análises que possibilitam a caracterização e o diagnóstico da problemática através da estimação de variáveis de tráfego. Este processo culmina em uma compreensão mais coerente da problemática e, conseqüentemente, fundamenta a atividade de tomada de decisões.

As principais atividades do meio acadêmico e técnico da engenharia de transportes envolvem a avaliação de cenários e a proposição de alternativas, sendo o uso de ferramentas computacionais uma prática rotineira e, nos dias de hoje, essencial. Nestas aplicações computacionais, busca-se a representação do comportamento real dos usuários/veículos através de modelos (matemáticos e estatísticos) calibrados e validados. Para uma representação adequada e, conseqüentemente, resultados condizentes com a realidade, estes mecanismos requerem dados de entrada detalhados e precisos, os quais os principais métodos de estimação encontram grande dificuldade em prover.

Uma solução para contornar a dificuldade da coleta de grande parte dos dados relacionados ao tráfego veicular consiste em analisar um diagrama espaço-tempo, estratégia clássica para obtenção das informações veiculares com um alto nível de detalhamento. O diagrama espaço-tempo consiste em uma ferramenta simples e efetiva de análise de tráfego que compila diversas informações sobre os veículos ao passo que rastreia a posição de cada um ao longo do tempo e do sentido de percurso (Hoel *et al.*, 2011).

Por meio da análise do diagrama espaço-tempo pode-se estimar, a partir da investigação de trajetórias veiculares individuais, desde variáveis desagregadas como *headway* e espaçamento, velocidade, aceleração e quantidade de manobras de mudanças de faixa, até variáveis coletivas do tráfego como fluxo, densidade, comprimento de fila etc. (Daganzo, 1997). Um aprofundamento do estudo destas variáveis (através de combinações das trajetórias)

permite, inclusive, que se observe conflitos veiculares, ajudando a compreensão dos padrões de comportamento veiculares também no que concerne à segurança viária.

No entanto, a construção do diagrama espaço-tempo é uma tarefa de alta dificuldade tendo em vista a minuciosidade das informações necessárias, bem como a natureza dinâmica do comportamento dos veículos. De modo geral, a construção do diagrama passa por uma aquisição constante e em curtos intervalos de tempo de informações precisas sobre a posição dos veículos conforme eles trafegam por uma determinada região de interesse sob análise.

A dificuldade de aquisição de dados vem sendo minimizada ao longo das últimas três décadas com o avanço de técnicas e tecnologias de coleta, de modo que se fez possível dispensar a presença de observadores humanos em campo. De acordo com o Manual de Estudos de Tráfego do Departamento Nacional de Infraestrutura de Transportes (DNIT, 2006), um pesquisador experiente consegue contar e classificar até 350 veículos por hora por sentido de tráfego de modo que o nível de precisão das informações não seja comprometido. Entretanto, estas duas atividades apenas não são capazes de ajudar satisfatoriamente na compreensão do movimento de cada veículo. Por outro lado, os instrumentos tecnológicos apresentam uma capacidade de coleta e processamento de dados muito superior e, em geral, podem trabalhar ininterruptamente. Estes instrumentos são classificados quanto à sua natureza como: intrusiva, como tubos pneumáticos, sensores piezelétricos, laços indutivos etc.; e não intrusiva, como sensores infravermelhos, radares sonoros e processadores de imagens, dentre outros (Leduc, 2008; Klein, 2001).

A utilização de dispositivos processadores de imagens para análise de tráfego veicular tem sido investigada e seu uso vem sendo difundido e aplicado em inúmeros estudos. Dentre as vantagens, destacam-se a acurácia dos resultados, a ausência de interrupções no tráfego durante seu manuseio, a possibilidade de intervenções em tempo real e o custo relativamente baixo de aquisição e manutenção dos equipamentos (Hartmann *et al.*, 1996). O processamento em tempo real destas informações, por exemplo, possibilita intervenções imediatas da gestão operacional do tráfego, como temporização semafórica, controle de velocidade, sinalização interativa etc.

O uso de sistemas artificiais para obtenção de informações de imagens é conhecido como Visão Computacional (do inglês *Computer Vision*). A Visão Computacional é uma área do conhecimento dedicada ao desenvolvimento de métodos computacionais para extrair informações a partir de imagens digitais (Setchell, 1997). Sua utilização em sistemas de transporte rodoviário foi inicialmente motivada pela necessidade de informações mais detalhadas e em tempo real sobre o fluxo veicular que permitisse o aperfeiçoamento de sistemas

inteligentes de transportes (*Intelligent Transportation Systems – ITS*) em *freeways* (Hoose, 1992; Coifman *et al.*, 1998). Atualmente, apresenta-se como uma área de pesquisa relativamente consolidada e vem sendo aplicada em diversos campos de estudos, dentre eles a engenharia de tráfego, assistindo na coleta e no processamento de dados (Saunier e Sayed, 2006a; Cunha, 2013; Câmara *et al.*, 2015).

Na engenharia de tráfego, as principais tarefas da Visão Computacional consistem na detecção e rastreamento veicular (*vehicle detection and tracking*) ao longo de segmentos viários, assim como classificação dos diferentes tipos de veículos (*vehicle classification*). As informações obtidas podem ser utilizadas para estimação do fluxo veicular, confecção de diagramas espaço-tempo, detecção e classificação de conflitos veiculares, reconhecimento de placas e aferição de velocidades, entre outros (Hartmann *et al.*, 1996; Sullivan *et al.*, 1997; Coifman, 1998; Gupte *et al.*, 2002; Tancredi e Widmer, 2012). De modo geral, a Visão Computacional aplicada à engenharia de tráfego consiste, basicamente, em adquirir imagens de tráfego com o auxílio de câmeras de vídeo e utilizar uma rotina computacional para extrair informações sobre os veículos, fomentando os mais diversos tipos de análise.

A maioria das abordagens de processamento de imagens aplicadas na engenharia de transportes encontradas na literatura tem sido desenvolvidas para rodovias onde o fluxo é predominantemente ininterrupto (Coifman *et al.*, 1998; Jung e Ho, 1999; Gupte *et al.*, 2002; Cunha, 2013). Por outro lado, o ambiente urbano de fluxo interrompido, principalmente nas proximidades das interseções, propõe desafios mais complexos ao uso da Visão Computacional. Os principais fatores que dificultam o uso da Visão Computacional no ambiente urbano são: o regime de paradas, a existência de obstáculos obstruindo parcialmente os veículos, a proximidade entre os veículos, a semelhança entre as velocidades e os movimentos de mudanças de faixa e de conversão (Saunier e Sayed, 2006a). Portanto, o fluxo interrompido urbano foi escolhido como cenário desta pesquisa pelo maior grau de complexidade de análise (inclusive frente ao sucesso da aplicação da Visão Computacional), em detrimento do menor número de estudos encontrados na literatura.

1.1 Problema de Pesquisa

Tendo em vista a discussão levantada até então, identifica-se como problema de pesquisa o fato de que os principais métodos de estudo de tráfego voltados à estimação de atributos que representem o fluxo veicular em áreas urbanas não contemplam um levantamento minucioso de dados desagregados que permitam uma descrição das trajetórias individuais

eficiente para uso na gestão operacional. Portanto, a utilização da Visão Computacional é abordada nesta dissertação como uma estratégia de obtenção de parâmetros veiculares em ambiente urbano de fluxo interrompido, o qual possui características que aumentam o grau de complexidade de sua análise.

1.2 Questões de Pesquisa

A contextualização apresentada nas seções anteriores culmina em provocar as seguintes questões de pesquisa que norteiam esta dissertação:

- i. Quais são os aspectos, inerentes às principais estratégias de processamento de imagens da Visão Computacional aplicadas a estudos de tráfego, que influenciam a capacidade de rastreamento veicular?
- ii. Como extrair informações veiculares individuais precisas no tráfego urbano interrompido através da Visão Computacional?
- iii. Como maximizar a precisão de estimação de fluxo e de rastreamento veicular do método proposto para extração de informações veiculares utilizando a Visão Computacional?
- iv. Qual a adequabilidade da estimação de parâmetros de fluxo veicular microscópico através da aplicação da Visão Computacional para vias urbanas de Fortaleza?

1.3 Objetivos de Pesquisa

1.3.1 Objetivo Geral

Diante da problemática retratada, o objetivo principal desta dissertação é propor um método para executar estudos desagregados de tráfego veicular microscópico urbano que permita estimar variáveis como fluxo, velocidade, *headway* e espaçamento, quantidade de mudanças de faixa, dimensões veiculares, atraso, comprimento de fila e número de paradas, com o auxílio de diagramas espaço-tempo.

1.3.2 Objetivos Específicos

Para alcançar tal objetivo, propõe-se os objetivos específicos dispostos em sequência metodológica:

- i. Identificar os aspectos fundamentais das principais estratégias de processamento de imagens da Visão Computacional que influenciam o rastreamento veicular do tráfego interrompido;
- ii. Construir um algoritmo de Visão Computacional para executar a extração de informações veiculares individuais detalhadas;
- iii. Calibrar o algoritmo de Visão Computacional adotando como medidas de desempenho a contagem e o rastreamento veicular;
- iv. Efetivar um estudo de caso para construção de diagramas espaço-tempo, estimação de variáveis de fluxo veicular interrompido e avaliação da aplicabilidade do algoritmo de utilizando a Visão Computacional.

1.4 Estrutura da Dissertação

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

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

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

2 REVISÃO DA LITERATURA

Este capítulo divide-se em duas seções para melhor apresentar a fundamentação teórica de cada aspecto envolvido no desenvolvimento deste trabalho. Inicialmente, tem-se uma discussão sobre os princípios dos estudos de tráfego direcionada para o tráfego urbano interrompido e diagramas espaço-tempo. A seguir, apresenta-se noções sobre a Visão Computacional, as principais particularidades e aplicações a sistemas de transporte. O objetivo é proporcionar um embasamento teórico sobre a engenharia de tráfego e os conceitos elementares voltados para análise do tráfego veicular em ambiente urbano bem como do uso da Visão Computacional como ferramenta de análise.

2.1 Tráfego Urbano Interrompido

De acordo com o *Institute of Transportation Engineers* (ITE, 2009), a engenharia de transportes trata, de modo geral, de aplicar tecnologia e princípios de planejamento de caráter científico, além de design funcional, operação e administração de instalações nos diversos modos de transportes para promover movimentos de pessoas e bens. Por sua vez, a ocorrência destes deslocamentos deve ser de tal forma que apresente cinco aspectos gerais: segurança, conforto, conveniência, economia e responsabilidade ambiental (Roess *et al.*, 2011).

Almejando atingir os objetivos supracitados, utiliza-se, por exemplo, de estratégias de controle dos fluxos de modo a garantir que o movimento dos veículos nas vias, bem como a interação entre os diversos modos de transporte, dê-se de forma organizada e previsível. O *Highway Capacity Manual* (HCM) discute métodos de caracterização do fluxo e de gestão voltados para o controle dos fluxos de tráfego como controle semaforico, imposição de limites de velocidade entre outros (TRB, 2010).

Com o controle dos fluxos, busca-se, sobretudo, reduzir a probabilidade de ocorrência de acidentes à medida que se almeja atingir níveis máximos de utilização da infraestrutura viária. As principais discussões e estratégias para implementação de medidas que proporcionem segurança nas vias estão contempladas no *Highway Safety Manual* (HSM) (AASHTO, 2010). Sabe-se que uma das formas mais triviais de aumentar a segurança no fluxo, principalmente de veículos, é aumentando a distância entre os mesmos. Eis que surge, então, um dos principais dilemas enfrentados pelos técnicos de transportes: aumentar a segurança sem reduzir a fluidez veicular, e vice-versa.

O tráfego veicular é usualmente abordado em duas situações distintas de acordo com o ambiente: tráfego rural e tráfego urbano. Em geral, o tráfego rural caracteriza-se por movimentos entre centros urbanos por fluxos ininterruptos, usando infraestruturas de maior porte como as rodovias. Em contrapartida, o tráfego urbano ocorre no próprio espaço urbano das cidades, tendo como característica principal o fluxo interrompido em avenidas, ruas etc. (TRB, 2010).

O fluxo contínuo ou ininterrupto é aquele onde não há interrupções periódicas na corrente de tráfego provocadas por fatores externos como semáforos, sinais de trânsito entre outros, característica marcante do tráfego rural. Deste modo, as características do fluxo contínuo são baseadas apenas nas interações entre os veículos, tendo, portanto, uma complexidade de análise relativamente baixa. Por outro lado, o fluxo interrompido é marcado pela existência de interferência de estímulos do meio externo sob a corrente, o que ocorre praticamente em todo o tráfego urbano. Estas interferências externas acabam fazendo com que o comportamento do movimento dos veículos não seja mais ditado apenas pelas interações entre os veículos, conseqüentemente aumentando o grau de dificuldade de sua análise (TRB, 2010; Roess *et al.*, 2011).

Em termos de análise, o tráfego veicular é dividido em duas categorias para estudo: fluxo macroscópico e microscópico. O fluxo macroscópico observa a corrente de tráfego em si, considerando que os veículos e usuários são semelhantes, simplificando a análise e o processo de modelagem matemática e calibração (May, 1990; Gazis, 2002). Nesta abordagem, os parâmetros investigados são basicamente volume, velocidade e densidade, bem como as relações entre si, partindo dos conceitos desenvolvidos por Greenshields (Greenshields *et al.*, 1935).

Já o fluxo microscópico parte da ideia de descrever o comportamento da corrente a partir da reação de cada veículo/usuário aos estímulos do tráfego e externos, considerando variações aleatórias de seus perfis de comportamento, do padrão de chegada de veículos, entre outros fatores. As principais variáveis observadas para a caracterização do fluxo microscópico são o *headway*, o espaçamento e o tempo perdido, enquanto a medida de desempenho mais utilizada é o atraso (May, 1990; Gazis, 2002).

Todas as esferas de análise de tráfego já mencionadas são objetos dos mais diversos tipos de estudos de tráfego. De acordo com Roess *et al.* (2011), estes estudos têm como base processos de coletas de dados e podem ser classificados quanto sua finalidade entre as seguintes denominações: estudos volumétricos, estudos de velocidade, estudos de tempo de viagem, estudos de atraso, estudos de acidentes, estudos de estacionamentos, estudos de boa circulação

e trânsito, estudos de pedestres, estudos observacionais e estudos de calibração. Há ainda outros tipos de estudos como origem-destino, ocupação veicular e fluxo em interseções que se complementam e fomentam a compreensão da problemática envolvida em cada situação sob análise.

Cada um destes possui métodos específicos para guiar suas execuções e estratégias distintas de coleta de dados, podendo ser executados de forma manual, semi-automatizada ou automatizada (DNIT, 2006; Elefteriadou, 2014). Outra característica apresentada por grande parte dos estudos de tráfego é o uso de modelagem matemática e/ou estatística, fazendo uso de modelos determinísticos ou estocásticos para representar o comportamento dos veículos na corrente, assim como pedestres, ciclistas etc.

Em particular, o estudo desenvolvido nesta dissertação volta-se para a análise microscópica do fluxo interrompido do tráfego urbano, lidando com ambientes próximos a interseções semaforizadas, como introduzido no Capítulo 1. Interseções são pontos críticos no sistema viário uma vez que possuem um grande potencial para gerar conflitos entre os modos de transporte que usam tal estrutura viária (ITE, 2009; Roess *et al.*, 2011). Nas proximidades de interseções semaforizadas são esperadas paradas (desaceleração) e retomadas (acelerações) de movimentos e mudanças de faixa na seção à montante do sinal, bem como conversões na seção à jusante. Um dos principais efeitos colaterais dos conflitos que surgem nas interseções é o fenômeno do congestionamento, que afeta o desempenho global do sistema de forma significativa à medida que aumenta o tempo perdido nas viagens.

Nas interseções semaforizadas os congestionamentos podem ser observados e analisados através de um diagrama de onda de choque, conhecida como *shock-wave* (Akçelik *et al.*, 2002; Omid, 2013). Por definição, onda de choque é o limite em uma corrente de tráfego que representa uma descontinuidade no domínio de densidade de fluxo (May, 1990; Roess *et al.*, 2011). Assim, análise de ondas de choque consiste em uma técnica para identificar áreas congestionadas em uma via e, também, estimar a taxa de formação e dissipação de filas decorrentes do congestionamento (Izadpanah *et al.*, 2009). Para que se visualize uma onda de choque, faz-se necessário construir um diagrama espaço-tempo, discutido na subseção seguinte.

2.1.1 Diagramas Espaço-Tempo

De acordo com Anwar *et al.* (2014), o diagrama espaço-tempo surgiu entre as décadas de 50 e 60 e é uma ferramenta relevante na era atual de abundância de informações. O estudo de como a posição dos veículos muda ao longo do tempo e de suas interações são

necessárias para entender o fluxo e os problemas de segurança do tráfego (Kanagaraj *et al.*, 2015). Conforme explicado no capítulo anterior, o princípio deste tipo diagrama veicular é rastrear os veículos a curtos intervalos de tempo conforme se movimentam nas vias, obtendo um gráfico bidimensional. Através de sua análise pode se obter diversas informações veiculares desagregadas e coletivas, como *headways*, espaçamento, velocidade, aceleração, volume, fluxo entre outros.

A partir da obtenção de tais parâmetros de fluxo veicular, medidas de desempenho como o atraso veicular médio podem ser estimadas. O atraso veicular é definido como o tempo acrescido à viagem de um veículo devido à existência de, entre outros fatores, interseções semaforizadas. Leva-se em consideração o atraso da desaceleração do veículo ao aproximar-se da interseção, o tempo que permanece parado e o atraso de aceleração quando da retomada do movimento (Quiroga *et al.*, 1999). Medidas de desempenho como esta são informações valiosas para aplicação na gestão operacional do tráfego.

No exemplo da Figura 1 estão descritas graficamente as trajetórias de 7 veículos em um determinado trecho e durante certo período. Neste gráfico, a distância horizontal entre os trajetos remete ao *headway* (tempo) entre os veículos, enquanto a distância vertical consiste no espaçamento. Pode-se obter também as velocidades instantânea e média e acelerações através das diferenças de tempo e espaço dos pontos do trajeto dos veículos. Além disso, uma análise do diagrama espaço-tempo pode revelar a distância entre os veículos quando parados e a proximidade quando em movimento, o que fomenta estudos de tráfego e segurança viária como a microssimulação.

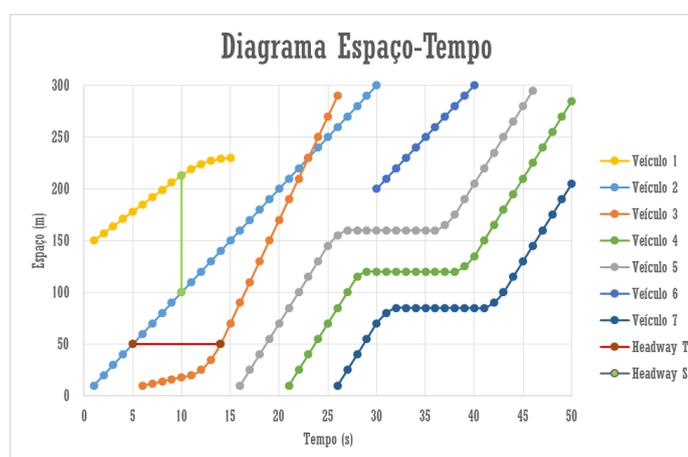


Figura 1 - Exemplo de diagrama espaço-tempo (Autor)

Para efeito de elucidação, considere-se que no exemplo da Figura 1 esteja representado o diagrama espaço-tempo de uma faixa de via em análise. Assim, o Veículo 1 está

na posição 150 quando do início da plotagem, segue com diminuição de velocidade e desaparece, onde o motivo pode ser sua saída da via para estacionamento ou mudança de faixa. O Veículo 2 tem um movimento praticamente constante, enquanto o Veículo 3 surge com uma velocidade um pouco inferior ao Veículo 2, acelerando logo em seguida e o ultrapassando no tempo de aproximadamente 24 segundos do diagrama. Os Veículos 5, 7 e 8 demonstram o comportamento de uma fila, com velocidades e *headways* aproximadamente iguais, sofrendo o efeito da onda de choque como efeito de uma possível semaforização na interseção. Por fim, o Veículo 6 surge na posição de 200 metros, possivelmente vindo de uma outra faixa e desaparece por efeito de já não estar mais na área rastreada. Vale ressaltar que sobre o Veículo 6 pode-se inferir ainda que provavelmente não deve ter saído de um estacionamento por não apresentar aceleração (trecho curvo) no início de seu trajeto.

No gráfico superior da Figura 2, tem-se a representação de onda de choque ilustrando a posição de cada veículo representado por uma curva ao longo do tempo. Por sua vez, no gráfico inferior da mesma figura, está apresentada a relação entre a velocidade de cada veículo ao longo do tempo. Percebe-se o grau de riqueza de informações que diagramas podem ter, de modo que suas aplicações vão além de detectar ondas de choque.

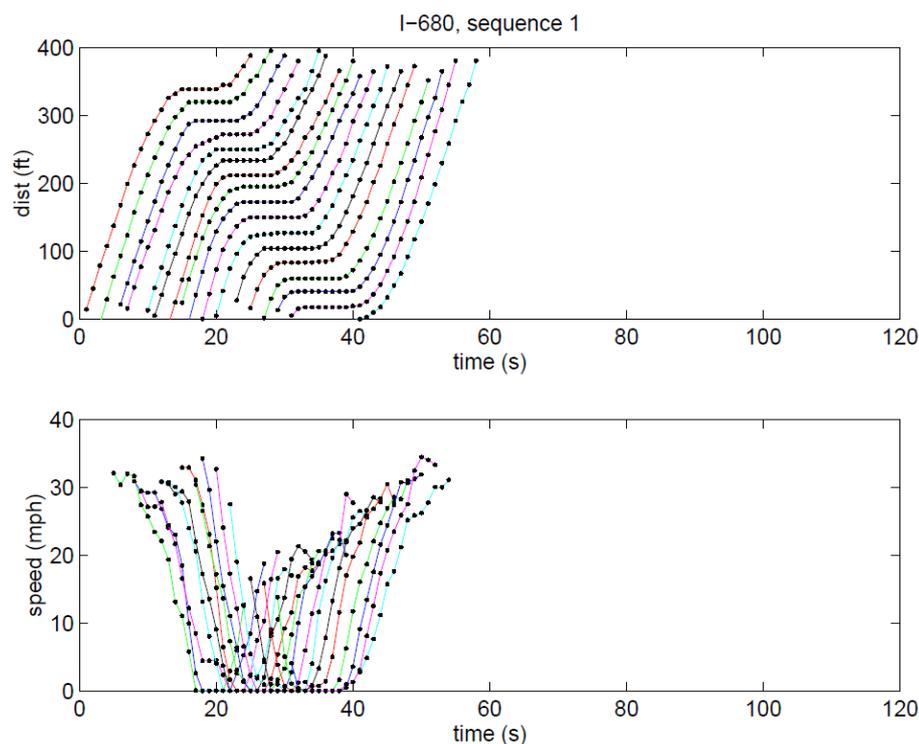


Figura 2 - Diagramas espaço-tempo representando ondas de choque (Coifman, 1997)

O diagrama espaço-tempo tem passado por evoluções e nos dias de hoje já se tem desenvolvido ferramentas para adicionar uma terceira dimensão. O diagrama espaço-tempo 3D diferencia-se do tradicional 2D por ter informações da posição dos veículos nas duas direções do plano da via além da dimensão temporal. O resultado é um gráfico tridimensional que pode ser associado à rede viária de onde se deseja realizar análise. Com efeito, torna-se possível uma análise não mais simplesmente de veículos em uma via em uma direção, mas de todos os veículos na rede (Anwar *et al.*, 2014; Kim *et al.*, 2015) (Figura 3).

No diagrama espaço-tempo 3D as duas dimensões do plano horizontal são as posições do veículo, enquanto a dimensão vertical diz respeito ao tempo. Na Figura 3, cada fatia horizontal do diagrama espaço-tempo 3D ilustra a posição do veículo no espaço em relação ao instante observado. Assim, a projeção de todas as posições em um plano horizontal representa a trajetória do veículo enquanto percorria a região observada. Logo, no exemplo, o veículo entra no diagrama no tempo T_1 e sai no tempo T_2 , de modo que o tempo que ele leve para percorrer o trecho representado da via é $T_2 - T_1$.

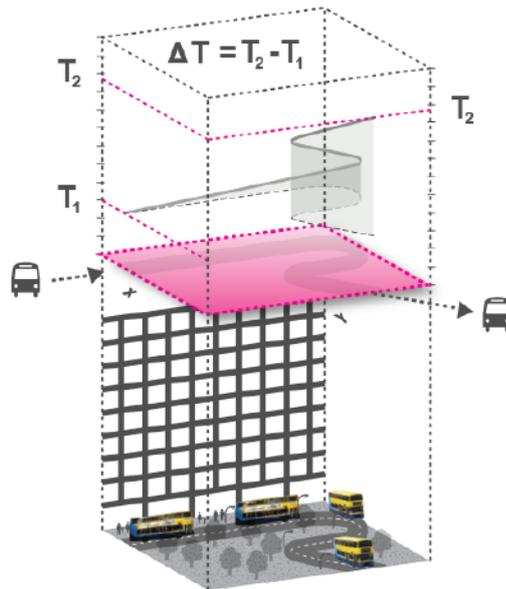


Figura 3 - Diagrama espaço-tempo 3D (Anwar *et al.*, 2014)

O grande desafio então para o uso dos diagramas espaço-tempo é consolidar técnicas e desenvolver ferramentas de coleta de dados com a capacidade de fornecer dados desagregados sobre o rastreamento. A seção a seguir trará uma discussão de como a Visão Computacional pode ajudar o desenvolvimento desta tarefa.

2.2 Visão Computacional Aplicada a Estudos de Tráfego Veicular

As mais recentes influências dos avanços tecnológicos sobre a engenharia de transportes estão ligadas ao desenvolvimento dos Sistemas Inteligentes de Transporte (do inglês *Intelligent Transportation Systems – ITS*). De acordo com a *World Road Association*, ITS refere-se, essencialmente, ao uso integrado de tecnologias de informação e comunicação nos transportes com três propósitos principais: melhorar a mobilidade de pessoas e bens; aumentar a segurança, reduzindo o congestionamento do tráfego e incidentes de forma eficaz; e contribuindo para o cumprimento das metas e objetivos da política de transportes.

Os ITS já atingiram um nível de desenvolvimento tal que já é possível, por exemplo, prover o monitoramento automático do tráfego veicular, buscando ir além de análise de fluxo agregado, mas fornecendo informações individuais dos veículos. Os impactos vão além da redução do labor humano, que é limitado e suscetível a erros conforme se aumenta a carga de tarefas laboriais. Através dos ITS pode-se ter uma melhor compreensão do tráfego permitindo melhorias na gestão do tráfego, o que implica, por exemplo, na possibilidade de redução dos congestionamentos, acidentes, emissões etc. (Saunier e Sayed, 2006b).

Tratando-se de monitoramento automático do tráfego veicular, uma das estratégias mais utilizadas dentre os recursos dos ITS é o monitoramento por vídeo. Saunier e Sayed (2006a) e Cunha (2013) apresentam vantagens de utilizar o monitoramento por sensores de vídeo como: facilidade de instalação e não intrusividade, principalmente quando comparado a detectores de *loop* magnéticos; possibilidade de se obter descrição detalhada dos parâmetros de tráfego e de rastrear os veículos; possibilidade de abranger grandes áreas com poucos equipamentos; e o baixo custo de aquisição dos dispositivos necessários.

No que concerne às ferramentas de monitoramento por vídeo, a Visão Computacional surge, para a engenharia de transportes, como alternativa de estratégia para realizar análises e extrair informações do fluxo veicular. Em geral, utiliza-se de algoritmos computacionais com métodos desenvolvidos de acordo com o objetivo almejado. Beymer *et al.* (1997) discute os princípios e etapas de execução das quatro principais estratégias de rastreamento e detecção veicular que vigoram até os dias de hoje, a saber: *Model-based tracking*, *Region-based tracking*, *Active contour-based tracking* e *Feature-based tracking*, os quais serão discutidos com mais profundidade a seguir.

O rastreamento baseado em modelos (*Model-based tracking*) consiste em reconhecer, com alta eficácia, modelos de veículos em 2D ou 3D informados previamente pelo usuário (Figura 4). A partir da definição de um plano de fundo da imagem (*background*) que

representa a parte imóvel do vídeo, os algoritmos identificam os modelos veiculares dentre os objetos móveis, fazendo a detecção, rastreamento e classificação do fluxo de veículos. Apesar de ter uma baixa demanda de processamento computacional, esta abordagem tem um grande desafio que dificulta sua utilização. A grande desvantagem consiste na necessidade de criação de inúmeros modelos detalhados que representem satisfatoriamente toda a diversidade de formas de veiculares existentes. (Gardner e Lawton, 1996; Coifman *et al.*, 1998; Saunier e Sayed, 2006a; Buch *et al.*, 2008).

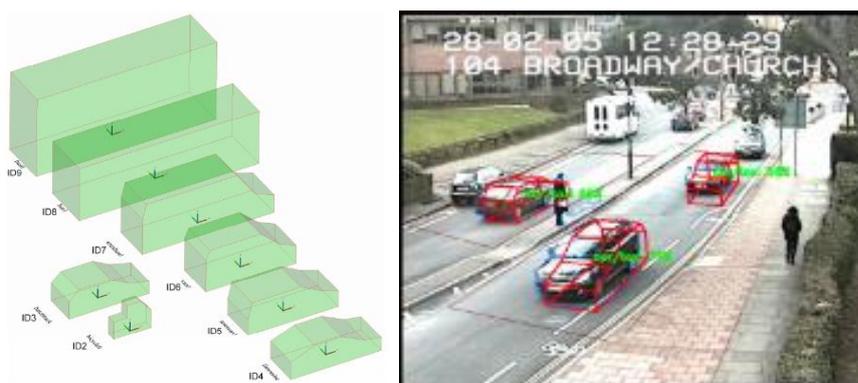


Figura 4 - À esquerda, modelos veiculares definidos para uso do algoritmo. À direita, exemplo de detecção dos veículos (Buch *et al.*, 2008)

Na estratégia baseada em regiões (*Region-based tracking*) os algoritmos procuram identificar manchas (*blobs*) que se movem entre quadros (*frames*) consecutivos da imagem, sem a necessidade explícita da definição de modelos (Figura 5). Como o *Model-based tracking*, nessa estratégia define-se uma etapa de subtração de fundo, para gerar um fundo estático que represente a região de interesse sem a presença de veículos. O algoritmo procura então, a partir da imagem de fundo, *pixels* que tenham alterado seus valores de intensidade acima de um limiar definido. Assim, as *blobs* detectadas são associadas a hipóteses veiculares, sendo então rastreadas ao longo do tempo. Este método de rastreamento apresenta bons resultados quando utilizado em condições de tráfego com fluxo livre (sem congestionamento) pela baixa demanda de processamento.

Entretanto, sob condições congestionadas de tráfego, comumente constatadas no tráfego urbano, veículos próximos acabam se ocluindo parcialmente, dificultando a definição dos limites desses veículos no vídeo. Além disso, há uma tendência de que as *blobs* paradas percam sua intensidade ao longo do tempo, passando a se confundir com o *background*, culminando com o seu desaparecimento. Uma consequência direta é a dupla contagem em função do reaparecimento da *blob* quando o veículo reinicia o movimento (Coifman *et al.*, 1998;

Jung e Ho, 1999; Gupte *et al.*, 2002; Atev *et al.*, 2005; Saunier e Sayed, 2006a; Câmara *et al.*, 2015).



Figura 5 - À esquerda, imagem original. Ao centro, subtração de fundo. À direita, detecção veicular (Câmara *et al.*, 2015)

O rastreamento baseado em contornos ativos (*Active contour-based tracking*) atua de forma semelhante ao método baseado em regiões, porém busca detectar e rastrear simplesmente os contornos das bordas de veículos. Para executar esta tarefa utiliza-se da modelagem de plano de fundo (*background*) e o mantém sucessivamente atualizado em quadros subsequentes. A vantagem deste método reside no fato de que há uma menor complexidade de processamento computacional envolvida. Entretanto, o algoritmo apresenta dificuldades em sua inicialização devido a sua alta sensibilidade, apresentando problemas para iniciar o rastreamento automaticamente (Koller *et al.*, 1994; Coifman *et al.*, 1998; Peterfreund, 1999; Chang *et al.*, 2003; Saunier e Sayed, 2006).



Figura 6 - Detecção veicular através de contorno ativo (Peterfreund, 1999)

A estratégia de rastreamento baseada em pontos notáveis (*Feature-based tracking*), por sua vez, abandona a ideia de rastreamento de objetos como um todo, seguindo traços

peculiares, tais como pontos do objeto rastreado (Figura 7). O algoritmo que utiliza este princípio tem potencial para ser utilizado em diferentes condições de iluminação, já que essa abordagem de rastreamento busca os traços mais marcantes em diferentes situações, como faróis, para-choques, retrovisores etc. Além disso, o rastreamento de pontos, ao invés de todo o veículo, pode permitir que, mesmo em situações de oclusão parcial, alguns pontos permaneçam visíveis e, portanto, passíveis de acompanhamento (Coifman *et al.*, 1998; Saunier e Sayed, 2006a; Kanhere *et al.*, 2007; Cunha, 2013).



Figura 7 - À esquerda, detecção de pontos. Ao centro, rastreamento dos pontos detectados. À direita, hipóteses veiculares para agrupamento (Beymer *et al.*, 1997)

O processamento dos pontos pelo algoritmo que adota a estratégia baseada em pontos notáveis pode, no entanto, requerer um esforço computacional que torne problemática a execução do algoritmo em tempo real, principalmente em condições de operação próximas à capacidade da via. Este desafio está relacionado principalmente à tarefa de rastreamento e, a seguir, agrupamento dos pontos através de hipóteses veiculares. Além disso, sob condições de fluxo interrompido, típico do tráfego urbano, há ainda outro fator para aumentar a complexidade computacional que consiste no movimento praticamente idêntico dos veículos que trafegam próximos uns dos outros. Para contornar esta situação, costuma-se utilizar restrições de proximidade espacial e velocidade semelhante entre os pontos para guiar as hipóteses de agrupamento (Saunier e Sayed, 2006a).

Entre as estratégias de Visão Computacional apresentadas, a *Feature-based tracking* vem se afirmando, com base na revisão da literatura, como a mais apropriada para obtenção de informações veiculares desagregadas. Além disso, apresenta-se como a mais robusta para lidar com as principais dificuldades inerentes à análise de vídeos de tráfego urbano. Portanto, será utilizada neste trabalho com o propósito de extração de informações veiculares pela análise de vídeos de fluxo urbano, objetivando a confecção de diagramas veiculares

espaço-tempo (Coifman *et al.*, 1998; Saunier e Sayed, 2006a; Kanhere *et al.*, 2007; Cunha, 2013).

Beymer *et al.* (1997) avaliaram a estratégia baseada em pontos marcantes para detecção veicular e estimação em tempo real de parâmetros tráfego em uma rodovia. Em relação a detecção, obtiveram taxas de acerto de 73,9% em vídeos de congestionamento pesado, 89,6% em vídeos noturnos, 85,3% em imagens de interseções urbanas e 94,2% para vídeos envolvendo fluxo livre e congestionamento. No que diz respeito a estimação de parâmetros de tráfego, em 44 horas de vídeo analisados, obteve-se erros de menos de 15% para fluxo, espaçamento e densidade em praticamente 80% das amostras, e erros de 2,2% para velocidade. Percebeu-se que os erros em estimação de fluxo, densidade e espaçamento estavam associados a duplas contagens e veículos não contados. Ao fim, constatou-se a aptidão do algoritmo em lidar com cenas noturnas e com as variações das sombras veiculares ao longo do dia.

Saunier e Sayed (2006a) avaliaram a estratégia *Feature-based tracking* em um estudo focado em interseções urbanas. Os resultados gerais apresentaram uma média de acertos de veículos corretamente detectados de 88,4%. Neste estudo, detectaram algumas fontes de erros: longas distâncias provocavam perdas de pontos, vibração da câmera e segmentação de veículos longos. Por outro lado, notou-se o correto rastreamento de pedestres e cadeirantes cruzando as vias.

Cunha (2013) apresentou um sistema automático para obter parâmetros macroscópicos e microscópicos de tráfego veicular em rodovias utilizando a biblioteca *OpenCV*. Nesse trabalho, obteve-se uma taxa de acerto de 92,7% na estimação das velocidades dos veículos em relação à valores obtidos por uso de um radar.

Vários são os fatores que influenciam no êxito da análise dos vídeos de cada estratégia de Visão Computacional, destacando-se o posicionamento da câmera em relação à via como um dos fatores que mais acarretam erros de contagem (Cunha, 2013; Câmara *et al.*, 2015). O posicionamento da câmera pode ter influência de diferentes modos: pode distorcer o tamanho do veículo ao longo da via, quando se trata de uma visão frontal do tráfego, sendo necessário o uso de um procedimento de ortorretificação conhecido como homografia; pode favorecer a ocorrência de oclusão de veículos, quando em uma vista lateral do fluxo um veículo obstrui a visibilidade de outro posicionado logo atrás, causando uma contagem onde na verdade deveriam ser duas etc. (Tsai, 1987).

Ainda sobre o posicionamento da câmera, outro ponto relevante é a altura desta em relação à via, pois influi diretamente no desempenho do algoritmo. Câmeras mais afastadas da via captam veículos com menos pontos (*pixels*), sendo mais difícil obter informações sobre os

mesmos. Por outro lado, é importante destacar que câmeras muito próximas da via detectam objetos maiores, o que implica em maior demanda de processamento por parte do algoritmo (Tsai, 1987).

Outro fator que influencia no desempenho e viabilidade de aplicação da Visão Computacional em estudos de tráfego é a capacidade de processamento dos *hardwares* empregados, bem como o ambiente de desenvolvimento do algoritmo. A próxima subseção trará uma discussão sobre o ambiente de programação.

2.2.1 Ferramentas Computacionais

O processamento de imagens é uma tarefa que vem sendo facilitada pelos avanços tecnológicos, de modo que há diversas aplicações computacionais voltadas para esta área. Dentre eles, pode-se citar a biblioteca *OpenCV* que, dentre todas suas aplicações, também lida com o processamento de imagens.

OpenCV é uma iniciativa de código aberto que começou a ser desenvolvido em 1999 por Gary Bradsky e atualmente suporta uma grande variedade de linguagens de programação como *C++*, *Python*, *Java* e etc., estando disponível em diferentes plataformas incluindo *Windows*, *Linux*, *Android*, *IOS* etc. A biblioteca *OpenCV* atualmente conta com mais de 2500 algoritmos computacionais que podem ser empregados em diversas aplicações na área de Visão Computacional, incluindo detecção e reconhecimento de objetos, rastreamento de movimentos e classificação de ações humanas registradas em vídeo (OpenCV, 2014). O potencial da biblioteca *OpenCV* é tão expressivo que grandes empresas mundiais fazem uso de seu material como a *Google*, *Yahoo*, *Microsoft*, *Intel*, *IBM*, *Sony*, *Honda*, *Toyota* (Bradski e Kaheler; 2008).

Para a tarefa de programação há diversos Ambientes de Desenvolvimento Integrado (*Integrated Development Environment – IDE*), dentre eles *Visual Studio*, *Eclipse*, *Spyder* e o próprio *IPython*. A escolha do ambiente de programação depende, entre outros, da experiência do usuário e dos recursos necessários de acordo com os objetivos do projeto.

Dentre as linguagens em que a biblioteca *OpenCV* está disponível, o *Python* vem ganhando destaque. Trata-se de uma linguagem de programação criada por Guido van Rossum e se tornou popular devido à simplicidade e legibilidade do código. Por si, *Python* tem uma velocidade de processamento mais lenta quando comparada a outras linguagens como *C/C++*, mas esta dificuldade pode ser solucionada facilmente através de extensões com *C/C++*. Por

exemplo, o *OpenCV-Python* é um empacotador de *Python* em torno de uma implementação original em *C++*.

3 MÉTODO PROPOSTO

No decorrer deste capítulo será apresentado o procedimento metodológico proposto para obtenção de dados desagregados de movimentos veiculares em vias urbanas e consequente aplicação na confecção de diagramas espaço-tempo. Serão apresentados e discutidos também as subetapas deste método, estabelecidas de acordo com os objetivos específicos, visando atingir a proposta geral da pesquisa.

A análise proposta nesta dissertação consiste nas quatro etapas metodológicas sequenciais apresentadas a seguir: i) investigação da adequabilidade das principais estratégias de processamento de imagens da Visão Computacional ao estudo de tráfego urbano; ii) desenvolvimento de algoritmo de Visão Computacional; iii) calibração do algoritmo de Visão Computacional; iv) efetivação de estudo de caso para construção de diagramas espaço-tempo, estimação de variáveis de fluxo veicular urbano interrompido e avaliação da aplicabilidade do algoritmo de Visão Computacional. A Figura 8 apresenta o resumo gráfico dessas etapas que serão detalhadas nas subseções seguintes.

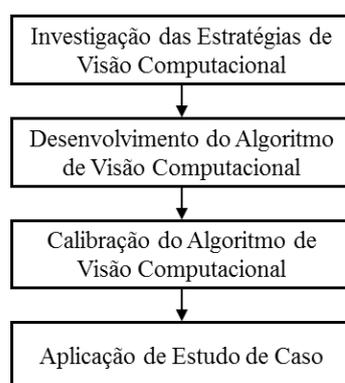


Figura 8 - Método proposto para desenvolvimento da dissertação (Autor)

3.1 Investigação das Estratégias de Visão Computacional

A proposta desta etapa metodológica é a execução de uma revisão da literatura buscando identificar os principais aspectos das estratégias de Visão Computacional que precisam ser considerados para aplicação de rastreamento veicular em fluxo urbano interrompido. O objetivo é dar suporte para definição da melhor estratégia de Visão Computacional a ser adotada de acordo com o propósito da aplicação. Esta investigação está inserida e apresentada na revisão de literatura apresentada no Capítulo 2.

3.2 Desenvolvimento do Algoritmo de Visão Computacional

Esta etapa é voltada para a codificação do algoritmo de Visão Computacional para processamento de imagens de vídeos. Elegeu-se a estratégia de detecção e rastreamento baseada em pontos notáveis (*Feature-based tracking*) de acordo com a investigação da etapa anterior. O algoritmo foi sistematizado em etapas que serão apresentadas e discutidas no Capítulo 4.

A linguagem de programação utilizada foi *Python 2.7* apoiada no repositório de bibliotecas de Visão Computacional de uso livre denominado *OpenCV 3.0.0 (Open Source Computer Vision Library)*. A plataforma de programação utilizada foi *Spyder* e operando no sistema operacional *Windows 7*. Todas as escolhas levam em consideração a rapidez, versatilidade e disponibilidade com baixo custo dessas ferramentas. Ao fim do processamento, o algoritmo de Visão Computacional deveria estar apto a gerar um relatório contendo informações detalhadas sobre o rastreamento dos veículos, bem como uma estimativa de fluxo veicular.

3.3 Calibração do Algoritmo de Visão Computacional

O algoritmo de Visão Computacional proposto nesta dissertação para análise de tráfego veicular urbano interrompido através da confecção de diagramas espaço-tempo foi calibrado em duas etapas, utilizando a estimativa de fluxo, bem como o rastreamento dos veículos como medidas de desempenho da precisão do algoritmo. A primeira etapa partiu de uma análise dos parâmetros influenciáveis, enquanto a segunda etapa consistiu em uma variação sistematizada dessas variáveis para, através de tentativas e erros, encontrar os melhores resultados para as medidas de desempenho adotadas.

A seguir, foi conduzida uma avaliação de precisão de detecção que utilizou os resultados da calibração e realizou-se uma tipificação dos erros, classificando as detecções como: verdadeiro positivo, falso positivo, falso negativo, segmentação, agrupamento e múltipla contagem. Verdadeiro positivo consiste no acerto da hipótese veicular, enquanto falso positivo ocorre quando o algoritmo assume uma hipótese erroneamente como veículo e falso negativo acontece quando um veículo percorre a região de interesse sem ser detectado corretamente pelo algoritmo. A segmentação veicular ocorre quando os pontos de um veículo são associados sob hipóteses de dois ou mais veículos, enquanto o agrupamento ocorre quando dois ou mais veículos são associados sob hipótese de um único veículo. Por fim, dupla/múltipla contagem ocorre quando o mesmo veículo é contabilizado mais de uma vez durante sua passagem pela

região de interesse determinada no algoritmo, podendo ocorrer principalmente em função de paradas e retomadas de movimentos.

3.4 Aplicação de Estudo de Caso

A última etapa do método proposto nesta dissertação consiste em um estudo de caso para efetivar a construção de diagramas espaço-tempo além de avaliar a aplicabilidade do algoritmo de Visão Computacional proposto na subseção 3.2. Por sua vez, esta etapa é constituída pelas cinco subetapas metodológicas sequenciais (Figura 9): i) definição da área de estudo; ii) aquisição de imagens; iii) pré-processamento dos vídeos; iv) construção dos diagramas espaço-tempo; v) estimação de variáveis de fluxo interrompido.

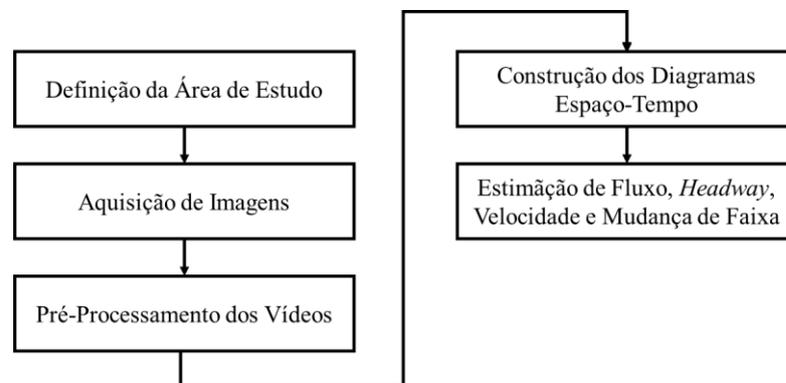


Figura 9 - Etapas metodológicas do estudo de caso

3.4.1 Definição da Área de Estudo

Conforme delineado no decorrer dos capítulos anteriores, este trabalho visa uma análise voltada ao tráfego urbano em vias arteriais nas proximidades de interseções semaforizadas. A definição da área de estudo será baseada nos seguintes critérios:

- Interseção em via arterial urbana com no mínimo duas faixas de tráfego por sentido;
- Fluxo veicular interrompido por sinalização semafórica;
- Possibilidade de plano de filmagem com boa abrangência de captura do fluxo à montante e à jusante da interseção em análise;
- Ausência ou pouca quantidade de pontos de obstrução da vista da câmera sobre a corrente, como a presença de árvores, curvas horizontais, placas de sinalização de trânsito etc.

3.4.2 Aquisição de Imagens

A aquisição de imagens foi efetuada através do uso de câmeras de vídeo, posicionadas em edifício situado em via que atendia às condições descritas na seção anterior. As filmagens foram realizadas em dias típicos e em intervalos de, no mínimo, uma hora e meia. Buscou-se posicionar a câmera com um ângulo que minimizasse a deformação dos veículos (consequentemente diminuindo a demanda de processamento da etapa de homografia) e com uma visão superior do fluxo para evitar problemas como obstruções e sombras, com base nas experiências relatadas por Tsai (1987), Cunha (2013) e Câmara *et al.* (2015).

3.4.3 Pré-Processamento dos Vídeos

A subetapa de pré-processamento consiste em algumas verificações buscando a máxima eficiência da etapa futura de processamento dos vídeos pelo algoritmo. A primeira das verificações diz respeito à qualidade das imagens em relação a movimento brusco e/ou perda de enquadramento da câmera. Nesse momento também é verificada a existência de anomalias diversas como obstrução da câmera por algum corpo estranho. Uma vez constatada a qualidade das filmagens, fez-se um particionamento dos vídeos em intervalos de quinze minutos (intervalo mínimo normalmente utilizado em pesquisas volumétricas), para facilitar a análise.

3.4.4 Construção dos Diagramas Espaço-Tempo

Esta etapa inicia com a própria aplicação do algoritmo de Visão Computacional baseado em pontos notáveis (*Feature-based tracking*) para análise dos vídeos. Para cada execução, em geral, fez-se uma configuração prévia do algoritmo para carregar o vídeo desejado, bem como ajustar a região de interesse que pode variar de vídeo para vídeo. A seguir, a execução do algoritmo gerou relatórios com informações como: coordenadas dos veículos; estimação de velocidade; identificação dos veículos entre outras.

De posse das coordenadas dos veículos ao longo do tempo obtidas na etapa de aplicação do algoritmo, foram construídos os diagramas espaço-tempo dos vídeos. Os dados dos rastreamentos foram importados no *software Microsoft Excel* pela facilidade de análise proporcionada pelos recursos de sua interface gráfica. Uma vez importados, os dados receberam

tratamento para detectar e eliminar possíveis inconsistências. Por fim, as informações de posição e tempo foram organizadas para plotagem dos diagramas espaço-tempo.

3.4.5 Estimação de Variáveis de Fluxo Interrompido

Nesta etapa foram estimados os seguintes parâmetros de fluxo veicular microscópico: comprimento veicular, distância entre veículos parados, comprimento de fila, velocidade média, atraso médio, número de paradas, *headways* e número de mudanças de faixa. A estimação de fluxo foi contemplada na etapa de calibração, juntamente com o processo de tipificação dos erros, para que se pudesse analisar a robustez do algoritmo.

O comprimento dos veículos foi estimado pela diferença entre as coordenadas médias frontais e traseiras, enquanto a distância entre veículos parados utilizou a diferença entre a coordenada traseira do veículo líder e a coordenada dianteira do veículo seguidor. Assim, o comprimento de fila consiste na diferença entre a coordenada dianteira do primeiro veículo e a coordenada traseira do último veículo parado na fila.

Para estimar a velocidade foi utilizada a informação do instante em que o veículo surgiu e do instante em que deixou a região de interesse, associado ao comprimento percorrido. Em seguida, a velocidade média estimada foi utilizada para determinar o atraso médio dos veículos no trecho estudado. A estimação do número de paradas realizadas, por sua vez, faz parte do processo de estimação do atraso médio.

A estimação de *headways* foi executada obtendo a diferença entre os instantes em que os veículos passam por um ponto tomado como referência. Por fim, o número de mudanças de faixa foi estimado através da comparação entre as trajetórias nos diagramas espaço-tempo e o comportamento real dos veículos nos vídeos.

4 DISCUSSÃO DOS RESULTADOS

Este capítulo tem como objetivo principal apresentar e discutir os resultados obtidos pela implementação do método proposto no capítulo anterior para o desenvolvimento deste trabalho. No decorrer do capítulo, abordar-se-á o desenvolvimento do algoritmo de Visão Computacional bem como sua calibração, além da aplicação do estudo de caso que culmina com a estimação de variáveis de fluxo interrompido urbano.

4.1 Desenvolvimento do Algoritmo de Visão Computacional

As etapas metodológicas para desenvolvimento do algoritmo de detecção e rastreamento veicular foram definidas com base no trabalho de Beymer (1997), Saunier e Sayed (2006a), Cunha (2013) e na experiência de Câmara *et al.* (2015). O algoritmo possui 8 etapas sequenciais, a saber: entrada de dados, definição da região de interesse, homografia, subtração de fundo, detecção de pontos, rastreamento de pontos, agrupamento de pontos e saída de dados (Figura 10). As etapas são discutidas ao longo desta seção exemplificando com os vídeos utilizados na aplicação do estudo de caso.

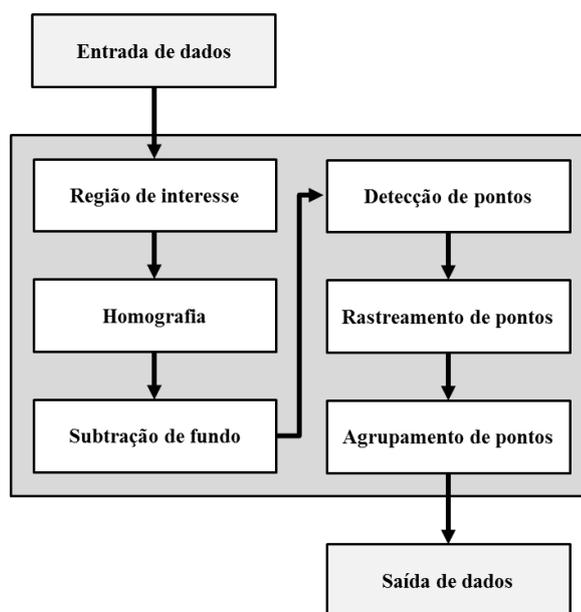


Figura 10 - Diagrama para o algoritmo de rastreamento de veículos (Autor)

A primeira etapa (entrada de dados) consiste em informar ao algoritmo o vídeo a ser analisado. No decorrer do processo há outras entradas de informações referentes a configurações e calibrações que serão discutidas ao longo do texto. Assim, as entradas de dados

foram os vídeos de tráfego que foram selecionados após passarem pelo procedimento de pré-processamento.

A seguir, a definição da região de interesse (do inglês *Region of Interest - ROI*), como o próprio nome sugere, refere-se à determinação da área da imagem de vídeo na qual se deseja que o algoritmo atue. Definiu-se para análise a área que envolve uma faixa central de tráfego, a segunda no sentido da esquerda para a direita, com base nos vídeos que foram processados para estimação das variáveis de tráfego (discussão na subseção 4.3.5). Portanto, em dimensões reais, a área equivale a aproximadamente 352 metros quadrados, onde o comprimento analisado da via é 110 metros e a largura equivale a 3.2 metros. Em *pixels*, a área equivale a um polígono com comprimento de 420 *pixels*, largura maior de 23 *pixels* e largura menor de 10 *pixels* (Figura 11).

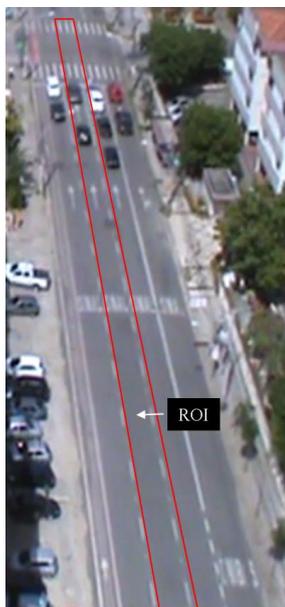


Figura 11 - Definição da região de interesse – ROI (Autor)

A restrição da *ROI* tem diversos motivos, sobressaindo dois: evitar que movimentos fora da zona de interesse sejam analisados pelo algoritmo, acarretando erros; e diminuir o tempo de processamento. Pode-se observar que na Figura 11 há um deslocamento da *ROI* em relação à delimitação da faixa de tráfego. Este cuidado foi tomado devido ao posicionamento da câmera em relação à via que por vezes ocasiona a projeção de parte dos veículos na faixa à esquerda dentro da *ROI* e de pontos dos veículos dentro da *ROI* na faixa à direita, quando estes percorriam muito próximos dos limites das faixas em questão.

O módulo denominado Homografia foi desenvolvido por Cunha (2013) e inserido no código para corrigir possíveis distorções das imagens que resultaria em variação no tamanho

dos veículos conforme se movimentassem e aumentaria as dificuldades da etapa de agrupamento, assim como as estimações dos parâmetros de tráfego. A maior correção foi na largura da faixa que à montante media 23 *pixels* e 10 à jusante. O resultado de uma homografia pode ser observado na Figura 12.

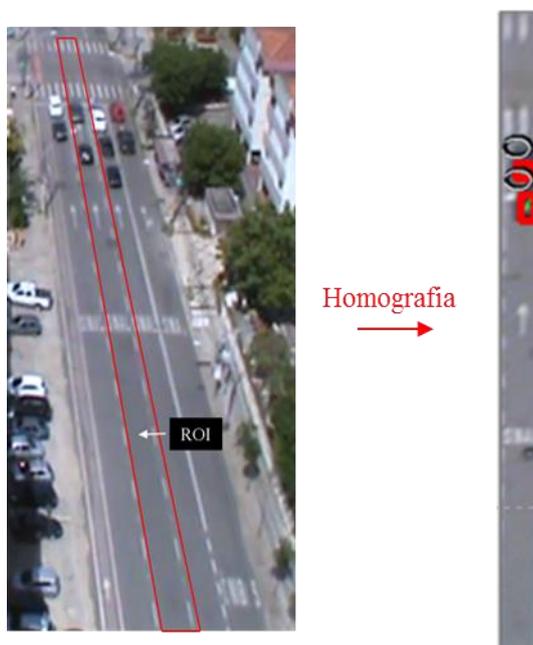


Figura 12 - Homografia executada pelo algoritmo (Autor)

A etapa de subtração de fundo, necessária para diferenciar o que está se movendo (*foreground*) do que não (*background*) foi implementada neste trabalho utilizando uma combinação de estratégias. Inicialmente, fez-se uso da técnica tradicional que emprega a função *MOG2* disponível na biblioteca *OpenCV*. Dentre as três rotinas disponíveis (*MOG*, *MOG2* e *GMG*), a *MOG2* é a que consegue lidar melhor com as variações de luminosidade da imagem (Zivkovic, 2004).

A seguir, codificou-se uma estratégia que utiliza um fundo fixo inicial como referência para melhorar a qualidade dos pontos para serem utilizados na etapa de detecção. Por fim, acrescentou-se uma função para calcular a diferença entre quadros e usar o resultado para atualizar continuamente o fundo (*background*). A combinação dessas três estratégias teve a intenção de tornar o algoritmo capaz de se adaptar a variações de iluminação e vibrações na câmera. Entretanto, a utilização de fundo fixo implica na necessidade de iniciar o processamento em um momento em que não haja veículos na via. Essa limitação precisa ser contornada durante a evolução do código, pois quanto maior o fluxo maior a dificuldade de se

encontrar instantes que atendam à esta condição. O resultado desta etapa pode ser visto na Figura 13.



Figura 13 - Superior: veículo na região de interesse. Inferior: subtração de fundo (Autor)

Para a tarefa de detecção de pontos fez-se uso da função *Shi-Tomasi Corner Detector* (`cv2.goodFeaturesToTrack()`) desenvolvida por Shi e Tomasi (1994), disponível na biblioteca *OpenCV*. A detecção de novos pontos foi restringida para acontecer em uma área denominada região de detecção de pontos, localizada nos primeiros metros da *ROI* (no sentido do fluxo). Esta medida implica na incapacidade de detectar veículos que adentrem a faixa após essa região. Entretanto, esta restrição foi adotada como forma de reduzir a demanda de processamento do algoritmo para este trabalho. A área da região de detecção de novos pontos é definida pela largura da faixa (obtida automaticamente) e pelo comprimento que deve ser informado manualmente e que neste trabalho foi definido como 100 *pixels* (Figura 14).

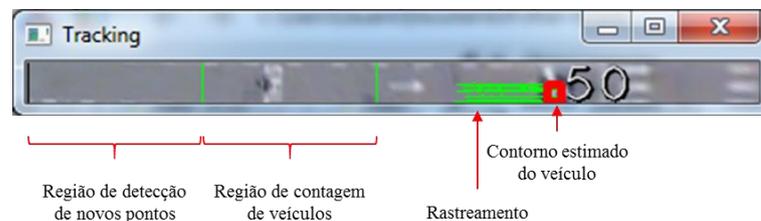


Figura 14 - Regiões do processamento do algoritmo e exemplo de rastreamento (Autor)

O próximo passo é o rastreamento dos pontos detectados na etapa anterior pelo algoritmo *Shi-Tomasi Corners Detector*. Os pontos detectados dentro da região de detecção de novos pontos são então rastreados até que os veículos deixem a região de interesse ou até que, por algum motivo, deixem de ser rastreados (Figura 14). Desta forma, os pontos detectados são utilizados como dados de entrada no algoritmo de rastreamento desenvolvido por Lucas e Kanade (1981), denominado *Optical Flow* e que pode ser encontrado na biblioteca *OpenCV* como `cv2.calcOpticalFlowPyrLK()`. Vale salientar que ambas funções *Shi-Tomasi Corner*

Detector e *Optical Flow* não sofreram quaisquer alterações para este trabalho, cabendo apenas a implementação e devida calibração, variando os parâmetros através de forma empírica.

Ao passo que rastreia os veículos, o algoritmo faz uma estimação de contagem veicular. Criou-se uma região de contagem de veículos (Figura 14) logo após a região de detecção de novos pontos, cuja área é definida pela largura da faixa (obtida automaticamente) e por um comprimento informado manualmente e que neste trabalho foi definido como 100 *pixels*. Para serem contados os veículos precisam percorrer toda a região de contagem de veículos, onde são rastreados e testados sob as hipóteses de agrupamentos veiculares (descritas no parágrafo seguinte), e cruzar a linha que define o limite.

A última etapa de processamento do algoritmo consiste no processo de agrupamento dos pontos através de hipóteses veiculares. O processo é feito, inicialmente, calculando velocidade a cada *frame* de cada *feature* (ponto) detectado na região de detecção. A velocidade é calculada nas duas direções (horizontal e vertical) ao longo da região de contagem de veículos. Ao mesmo tempo, calcula-se também a diferença das distâncias verticais e horizontais das posições dos pontos entre si. Em seguida, a partir de uma matriz de relacionamento entre os pontos, atribuem-se valores de identificação (IDs) iguais para os pontos que hipoteticamente compõe o mesmo veículo, procedimento realizado também a cada quadro processado do vídeo (*frame*). Então, para cada quadro, são determinados os quatro pontos extremos do grupo de pontos de mesmo ID, sendo possível o esboço de um retângulo representando a área do veículo ao longo de toda a extensão restante da região de interesse (Figura 14).

Outra restrição implementada, denominada de “radar”, consiste em restringir o agrupamento de pontos à proximidade angular entre eles (além da proximidade espacial), aumentando a cautela nas formulações de hipóteses veiculares. A função “radar” testada nesse algoritmo visa prevenir que pontos de veículos paralelos ou distantes, porém com movimentos semelhantes, sejam considerados um. Na prática, o “radar”, através de um coeficiente linear e outro angular, restringe os pontos testados sob a hipótese de pertencerem ao mesmo veículo, de modo que quanto menor forem esses parâmetros, menor a distância e menor o ângulo entre dois pontos com movimentos semelhantes para que eles sejam testados sob a hipótese veicular. O parâmetro linear refere-se à menor distância entre os pontos, enquanto o parâmetro angular toma como norte o sentido do fluxo.

Com efeito, se dois pontos cuja reta imaginária que os liga possui ângulo de zero grau em relação ao sentido do fluxo, estes são considerados com maior probabilidade de pertencerem ao mesmo veículo do que dois outros pontos cuja reta imaginária que os ligam

formam um ângulo de noventa graus com o sentido do fluxo. Logo, o parâmetro angular varia entre zero e noventa graus nos quatro quadrantes. Por sua vez, o parâmetro de distância linear exige do algoritmo uma boa capacidade de detecção de pontos para que o veículo seja melhor definido. A ideia é que vários pontos próximos sejam constatados como pertencentes ao mesmo veículo, ao invés de pontos nas extremidades ligados sob hipóteses veiculares. A partir destas informações dos pontos rastreados pelo algoritmo pode-se obter o valor médio entre os dois pontos extremos frontais que seria uma estimativa do posicionamento do para-choque dianteiro quando o veículo é um carro, por exemplo.

Um dos maiores desafios encontrados neste trabalho consiste nas paradas que os veículos executam em função das interseções semaforizadas, um desafio inerente do fluxo interrompido à aplicação da Visão Computacional. Os veículos parados tendem a desaparecer pela diminuição dos valores atribuídos aos pontos detectados em função da estratégia de atualização do plano de fundo ao longo do tempo (discutido na etapa de subtração de plano de fundo). Assim, concebeu-se uma estratégia especial para lidar com veículos parados que consiste em guardar as informações dos pontos associados ao mesmo ID (identificação) quando o veículo para até o momento que voltem a se movimentar, de modo que os pontos não sejam perdidos nem desagrupados.

Por fim, o resultado do processamento, obtido na etapa denominada de saída de dados, sofre um tratamento para eliminar informações repetidas, gerando um arquivo de formato *.csv*. O arquivo traz as seguintes informações quadro a quadro: velocidade média, velocidade instantânea, o respectivo quadro, o ID do veículo, a contagem de veículos (no quadro atual de processamento) e a posição em “x” e “y” do ponto médio frontal e posterior do veículo (ver Apêndice A). Vale salientar que, para a velocidade média, considerou-se o tempo necessário para percorrer toda a região de interesse, enquanto para velocidade instantânea a velocidade foi calculada para a distância percorrida a cada quadro (*frame*). Estes dados são então importados no *Microsoft Excel* para tratamento, estimação dos parâmetros e plotagem dos diagramas espaço-tempo, a ser discutido na subseção 4.3.4.

4.2 Calibração do Algoritmo de Visão Computacional

A calibração do algoritmo para aplicação neste trabalho foi efetivada em duas etapas, a saber: identificação de parâmetros influentes; e estratégia sistemática de tentativa e erro. A calibração objetivou o desempenho – por ordem de prioridade – do rastreamento e da contagem veicular, ambos consequência da qualidade da detecção e do agrupamento dos pontos

detectados. Atualmente, o algoritmo possui no total 33 parâmetros passíveis de calibração dos quais 19 foram identificados como parâmetros influentes e selecionados para calibração após análise conceitual e testes para observação de sensibilidade utilizando os vídeos destinados a aplicação do estudo de caso.

Os parâmetros selecionados para a segunda etapa da calibração estão apresentados na Tabela 1 a seguir. Depois, os parâmetros foram variados individualmente observando as medidas de desempenho supracitadas através de uma sistematização de tentativas e erros, pois a limitação de tempo para o processamento dificultou a adoção de uma estratégia de calibração mais sofisticada como algoritmo genético. Vale salientar que a calibração foi voltada para a contagem e rastreamento de automóveis.

Os melhores resultados encontrados heurísticamente para cada uma das variáveis foram então combinados e testados adotando-se a combinação que atendeu aos critérios no menor tempo de processamento. No total, 43 combinações foram testadas até alcançar resultados satisfatórios para calibração do algoritmo e aplicação do estudo de caso, discutido na seção seguinte.

Após análise gráfica dos diagramas espaço-tempo produzidos, culminando com o fim da calibração, foi feita uma avaliação comparativa entre a contagem volumétrica real e a contagem estimada pelo algoritmo (Tabela 2), novamente utilizando os vídeos dos quais foram estimadas as variáveis de tráfego. Os processamentos foram observados de modo a se constatar a robustez do algoritmo quanto à contagem veicular, bem como obter uma tipificação dos erros ocorridos.

De início, percebe-se que os valores estimados pelo algoritmo foram em alguns processamentos ligeiramente superiores à contagem real em função do número de duplas contagens. Nas ocasiões em que a contagem estimada pelo algoritmo foi inferior à contagem real o motivo foi a quantidade de falsos negativos. Estes resultados condizem com a experiência compartilhada por Beymer (1997) onde os falso negativos ocorreram principalmente para veículos em alta velocidade devido, acredita-se, ao pouco tempo para detectar um número razoável de pontos para serem testados sob a hipótese veicular. Não ficou suficientemente claro o porquê da ocorrência do erro de dupla contagem, fazendo-se necessária uma investigação aprofundada deste erro em trabalhos futuros. Deve-se ressaltar também que, ao contrário de outras aplicações encontradas na literatura, não foram constatados erros conhecidos por “segmentação” e “falso positivo”.

Tabela 1 - Parâmetros calibrados do algoritmo de Visão Computacional (Autor)

Subetapa	Parâmetro	Descrição
Entrada de Dados	<i>NFramesNoExecuted</i>	Opção de redução da quantidade de quadros processados
Identificação de Pontos	<i>maxCorners</i>	Número máximo de pontos detectados por quadro
	<i>detect_interval</i>	Intervalo de quadros para detecção de novos pontos
	<i>NMaxFeaturesAtScreen</i>	Número máximo de pontos acumulados na tela
	<i>maskball</i>	Região circular de inibição de detecção de novos pontos
	<i>qualityLevel</i>	Qualidade mínima de aceitação dos pontos em relação à medida de qualidade do melhor ponto
	<i>minDistance</i>	Distância euclidiana mínima considerada na detecção de pontos em um dado quadro
Rastreamento de Pontos	<i>blockSize</i>	Tamanho médio de um bloco de pontos para calcular a relação de cada pixel com a vizinhança
	<i>winSize</i>	Tamanho da janela de pesquisa em cada nível da pirâmide iterativa do método de Lucas-Kanade
	<i>maxLevel</i>	Número de níveis da pirâmide de Lucas-Kanade
	<i>GoodFeaturesLimit</i>	Critério qualitativo dos pontos rastreados pelo fluxo ótico por verificação entre quadros sucessivos
Agrupamento de Pontos	<i>PreLoadingLimit</i>	Comprimento da região de detecção de pontos
	<i>DeltaXLimit_Group</i> <i>DeltaYLimit_Group</i>	Limite máximo de agrupamento de dois pontos na direção “x” e “y”
	<i>SupLimitRelativeVel</i> <i>InfLimitRelativeVel</i> <i>SupLimitAbsoluteVel</i> <i>InfLimitAbsoluteVel</i>	Limites máximo e mínimo de similaridade de velocidade relativa e absoluta entre dois pontos
	<i>MaxNpointsRejectLikeGroup</i>	Número mínimo de pontos para rejeitar uma hipótese veicular sob forma de agrupamento

Tabela 2 - Comparação entre as contagens volumétricas reais e a obtidas pelo algoritmo (Autor)

Vídeo	Contagem Real	Contagem Estimada	Verdadeiro Positivo	Falso Negativo	Dupla Contagem	Agrupamento	Contagem Correta	Veículos Perdidos	Tempo de Vídeo tv (s)	Tempo de Processamento tp (s)	tp / tv
01	131	132	120	5	6	0	91,60%	3,82%	867	2745	3,2
02	126	126	111	6	7	1	88,10%	4,76%	843	2853	3,4
03	107	105	101	4	2	0	94,39%	3,74%	756	6029	8,0
04	134	135	121	6	7	0	90,30%	4,48%	955	2954	3,1
05	107	108	93	5	7	1	86,92%	4,67%	772	2683	3,5
06	142	151	129	2	11	0	90,85%	1,41%	945	3300	3,5
07	105	103	101	3	1	0	96,19%	2,86%	847	2563	3,0
08	125	125	115	5	5	0	92,00%	4,00%	864	2420	2,8
09	115	117	109	2	4	0	94,78%	1,74%	898	2131	2,4
10	112	109	105	5	2	0	93,75%	4,46%	890	1969	2,2
11	125	130	114	3	8	0	91,20%	2,40%	832	3471	4,2
12	76	76	67	3	4	1	88,16%	3,95%	606	1284	2,1

A análise da comparação entre a contagem volumétrica real e a estimada pelo algoritmo indicou um volume médio de aproximadamente 117 veículos para vídeos com duração média de 14 minutos. O algoritmo desenvolvido apresentou uma taxa de sucesso (taxa de contagem correta) da ordem de 91.52%, com taxa de veículos perdidos de 3.52% (Tabela 2 e Figura 15). A taxa de sucesso atende às expectativas referentes à utilização da estratégia de Visão Computacional conforme a revisão de literatura, bem como ao sucesso de sua utilização em estudos e na gestão do tráfego urbano.

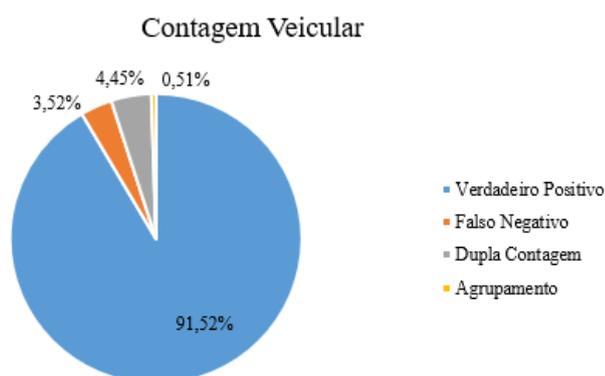


Figura 15 - Resultado da contagem veicular (Autor)

A qualidade dos diagramas espaço-tempo em relação à precisão do rastreamento em si foi objetivo de avaliação de um trabalho produzido pela Equipe de Estudos sobre Visão Computacional do Grupo de Pesquisa em Transporte, Trânsito e Meio Ambiente (GTTEMA) do Departamento de Engenharia de Transportes (DET) da Universidade Federal do Ceará (UFC). Neste estudo o algoritmo foi calibrado para processar vídeos produzidos em simulações utilizando o *software VISSIM* variando o fluxo veicular e a distância vertical (altura) entre o cenário modelado, altura obtida no próprio *software*. Os dados de rastreamento providos pelo *VISSIM* foram comparados com o rastreamento obtido pelo algoritmo de Visão Computacional desenvolvido utilizando as gravações feitas dos veículos na modelagem do *VISSIM*. Ao fim, a estimativa das coordenadas apresentou médias das diferenças entre -0,64 e 0,89 m, enquanto para o comprimento veicular variou entre -0,52 e 0,11 m. A contagem veicular obteve erros abaixo de 3,4% e a estimativa de velocidade teve erros de 0,95 km/h e 1,10 km/h para velocidade média e instantânea, respectivamente.

Apesar da robustez do algoritmo, notou-se certa dificuldade em lidar com grandes variações de iluminação ocorridas em alguns vídeos que, portanto, não foram processados. Esta fragilidade acredita-se estar associada principalmente à estratégia de subtração de *background* adotada que toma como base um fundo fixo. Os parâmetros da função *MOG2* foram variados

na busca de uma calibração que contornasse a situação, porém ao passo que os ruídos eram diminuídos, menos pontos eram detectados e, conseqüentemente, rastreados e contados.

Vale a pena destacar ainda o tempo de processamento dos vídeos pelo algoritmo (Tabela 2). Percebe-se que o tempo de processamento foi sempre superior ao tempo de vídeo processado (flutuando entre 2 e 3 vezes), com exceção do Vídeo 03. A justificativa para a disparidade do tempo de processamento do Vídeo 3 está na presença de um veículo de grande porte (caminhão articulado) para o qual o algoritmo não havia sido calibrado, o que demandou um maior tempo de processamento de seus pontos detectados e agrupados. De fato, observando a Tabela 3, percebe-se que ao excluir o tempo de processamento do Vídeo 03 a média de tempo de processamento tem redução considerável, bem como o coeficiente de variação. Contudo, acredita-se que o tempo de processamento possa ser reduzido com medidas simples como a redução da resolução dos vídeos. Ademais, a Tabela 3 ilustra os comentários feitos anteriormente sobre a contagem real ligeiramente inferior à contagem estimada e a taxa de detecção correta e de veículos perdidos.

Tabela 3 - Estatística descritiva da contagem veicular (Autor)

	Contagem Real	Contagem Estimada	Verdadeiro Positivo	Contagem Correta	Veículos Perdidos	Tempo de Processamento (s)		tp ¹ / tv	tp ² / tv
						tp ¹	tp ²		
Média	117,08	118,08	107,17	91,52%	3,52%	2866,83	2579,36	3,44	3,03
Máximo	142	151	129	96,19%	4,76%	6029	3471	7,97	4,17
Mínimo	76	76	67	86,92%	1,41%	1284	1284	2,12	2,12
Desvio Padrão	16,77	18,64	15,42	2,77%	1,10%	1108,80	591,22	1,48	0,59
Coefficiente de Variação	14,32%	15,79%	14,39%	3,03%	31,25%	38,68%	22,92%	42,98%	19,55%

tp¹: análise estatística do tempo de processamento considerando o Vídeo 03.

tp²: análise estatística do tempo de processamento desconsiderando o Vídeo 03.

4.3 Aplicação de Estudo de Caso

4.3.1 Definição da Área de Estudo

Para a consolidação deste trabalho, escolheu-se a interseção entre a Avenida Santos Dumont e a Rua Vicente Leite, no bairro Aldeota, Fortaleza – CE (Figura 16). Observando os critérios estabelecidos para escolha da interseção, os fatores decisivos foram a importância do fluxo da avenida, a existência e o acesso a edifício com altura adequada para posicionamento de câmera para aquisição das imagens e a possibilidade de uma visão do fluxo sem obstruções.

A Avenida Santos Dumont é uma importante via arterial da cidade, interligando zonas Leste e Oeste, incluindo bairros residenciais, comerciais e áreas de lazer, inclusive dando acesso ao litoral leste. Funciona em binário com a Avenida Dom Luís, outra importante via da cidade, além de ser uma alternativa aos usuários da Avenida Heráclito Graça e Avenida da

Abolição. Vale salientar que a imagem 3D da via (obtida através do *Google Earth*) está desatualizada. Atualmente a via opera em sentido único, com quatro faixas de tráfego, sendo a da extrema direita dedicada para o transporte público e dispondo de ciclofaixa na extrema esquerda. Com isso, as árvores do canteiro central foram removidas, permitindo uma visada sem obstruções do fluxo.

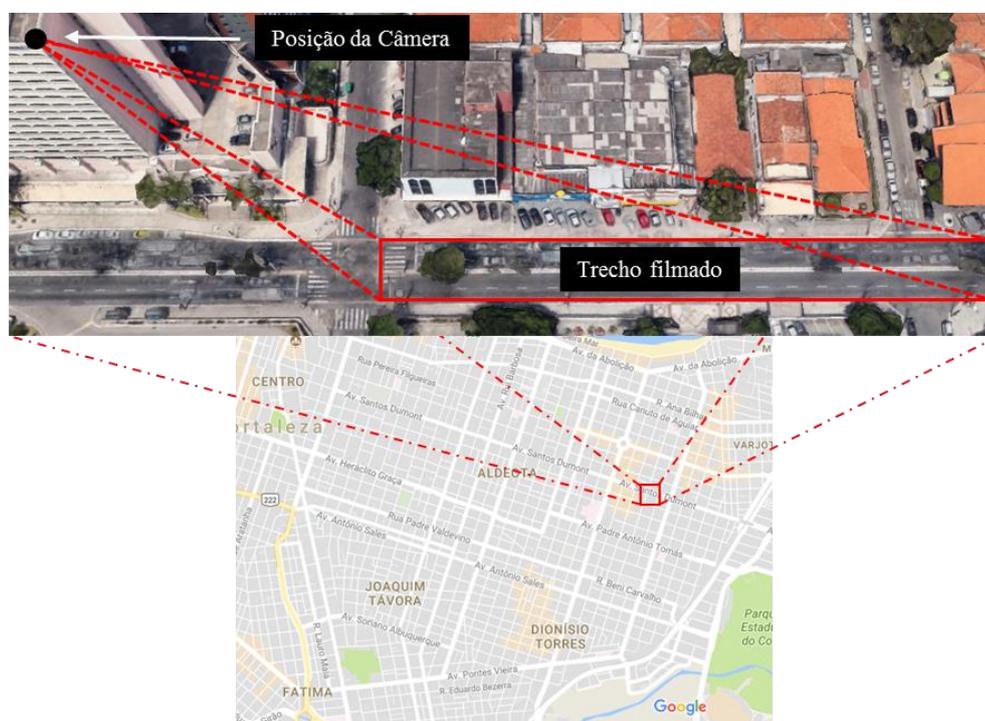


Figura 16 - Localização da interseção analisada (*Google Earth*)

4.3.2 Aquisição de Imagens

A coleta de vídeos foi feita pelo posicionamento manual de uma câmera filmadora SONY sobre a platibanda do edifício comercial Torre Del Paseo com o auxílio de um tripé regulável. A câmera foi instalada e estabilizada a aproximadamente 60 metros de altura em relação à via de modo a garantir um enquadramento da quadra à jusante, como mostra a Figura 17. O posicionamento foi feito manualmente/empiricamente tal que os veículos apresentassem a menor deformação possível de suas dimensões ao longo do trecho em análise, conforme as condições de instalação da câmera no topo do edifício.

Além disso, buscou-se um ângulo em que a imagem dos veículos não sofresse alterações para que não houvesse perdas de pontos rastreados pelo algoritmo. Para explicitar este cuidado, se a câmera fosse instalada em posição vertical (0° em relação ao eixo vertical da câmera), as imagens trariam a parte frontal dos veículos que estivessem surgindo na filmagem

(para-choque e para-brisa dianteiros etc.), enquanto que, à medida que os mesmos fossem percorrendo a região de captura, as imagens passariam a capturar a parte traseira dos veículos deixando a filmagem (para-choque e para-brisa traseiros etc.). Assim, optou-se por obter uma visão posterior do fluxo com ângulo de aproximadamente 60° em relação ao eixo vertical do centro da câmera, evitando também a obstrução entre veículos.

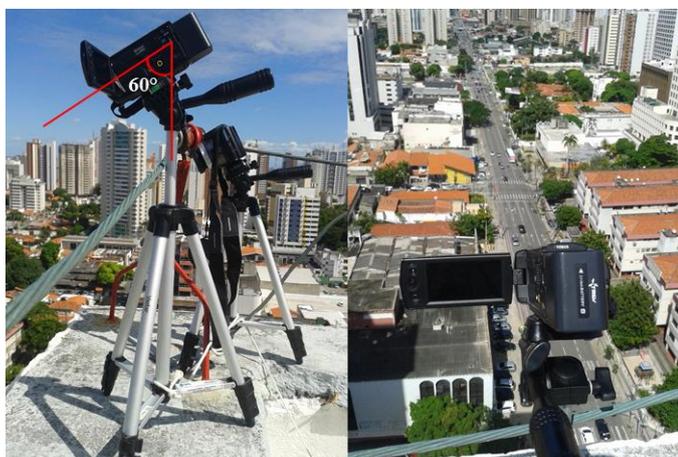


Figura 17 - Posicionamento da câmera para obtenção de imagens de vídeo do tráfego (Autor)

As filmagens foram executadas em dias úteis e nos horários entre 12h00min às 15h00min. Os vídeos foram capturados em períodos de filmagens sempre superiores a uma hora para evitar problemas no início e final da coleta e, em seguida, segmentados para análise, consolidando 6 horas de filmagens.

4.3.3 Pré-Processamento dos Vídeos

Os vídeos foram capturados e mantidos em resolução de 720x480 pixels com o objetivo principal de conseguir o máximo número de pontos para rastreamento. Em seguida, os vídeos foram convertidos para AVI (*Audio Video Interleave*) e tiveram o áudio removido com uso do *software Freemake Video Converter* buscando reduzir o tamanho – uma vez que a câmera filmava sob o formato MPG.

Para a construção dos diagramas espaço-tempo, os vídeos foram divididos em intervalos de 15 minutos, intervalo mínimo normalmente considerado em pesquisas volumétricas, favorecendo também a construção e análise dos diagramas espaço-tempo. Nesta etapa também foram verificados problemas com relação à filmagem, como movimento da câmera e obstrução por algum corpo estranho.

4.3.4 Construção dos Diagramas Espaço-Tempo

Os vídeos foram processados executando o algoritmo desenvolvido neste trabalho utilizando o *IDE Spyder*, parte do pacote *Anaconda 4.0.0*. Fez-se uso da linguagem de programação *Python 2.7* para utilização da biblioteca *OpenCV 3.0.0*. O processamento foi executado em um computador *notebook Dell Inspiron R15*, com processador *Intel Core i5-2430M CPU* de 2.4 GHz e 6 Gb de memória *RAM*, operando em um sistema operacional *Windows 7* de 64 bits.

De posse dos dados extraídos pelo algoritmo, os diagramas espaço-tempo foram plotados para os 12 vídeos processados, todos tendo como *ROI* uma faixa central do tráfego – como mencionado anteriormente. Para a construção dos diagramas utilizou-se dois dados extraídos pelo algoritmo: posição do centro do para-choque dianteiro dos veículos e o respectivo tempo. O tempo foi convertido para segundos, uma vez que o algoritmo fornece em quadros (*frames*). Assim, gráficos de dispersão foram plotados utilizando o *software Microsoft Excel*. Vale salientar que o algoritmo estima as informações dos veículos rastreados por quadro e não por veículo.

Os diagramas espaço-tempo construídos estão apresentados no Apêndice B e mostram-se fiéis aos comportamentos reais dos veículos após análise comparativa visual. Ao analisar manualmente os gráficos, pode-se perceber nitidamente variações dos movimentos veiculares, como aceleração, desaceleração e paradas. Os diagramas trazem ainda duas informações extras relevantes: posição da faixa de retenção e instante de início do tempo de verde. Assim, faz-se notável um indício visual da formação de pelotões nos ciclos. Além disso, pode-se perceber movimentos de mudanças de faixa. Contudo, as mudanças de faixa precisam de uma atenção especial devido ao fato de que, por vezes, podem ser na verdade perda de rastreamento por motivos diversos como movimento da câmera, qualidade dos pontos detectados, entre outros fatores.

4.3.5 Estimação de Variáveis

Após a aquisição de dados individuais de rastreamento dos veículos e construção dos diagramas espaço-tempo, estimou-se as seguintes variáveis inerentes a estudos e gestão do

tráfego urbano interrompido: comprimento veicular, distância entre veículos parados, comprimento de fila, velocidade média, atraso médio e *headway*. Além disso, buscou-se extrair informações referentes à robustez do algoritmo que também serão discutidos a partir da próxima subseção, a saber: número de trajetórias rastreadas, número de paradas e número de mudanças de faixa.

4.3.5.1 Comprimento Veicular

Para a estimação do comprimento veicular médio utilizou-se uma amostra de 158 veículos que tiveram todos os seus percursos rastreados sem anormalidades (perda ou incoerência no diagrama espaço-tempo) na região de interesse. Desta amostra, a metade corresponde a veículos que tiveram o movimento interrompido em função da interseção semaforizada, enquanto os demais percorreram a *ROI* sem interrupção do movimento ou redução significativa da velocidade. De posse da amostra supracitada, estimou-se o comprimento médio de cada veículo através da diferença entre a coordenada 'x' dianteira e a coordenada 'x' traseira obtidas como dados de saída do algoritmo.

A seguir, obteve-se a média dessa diferença calculada ao longo de um trecho de 40 metros da via a partir de 10 metros depois do ponto de início da região de interesse. Esse cuidado foi tomado para assegurar que a estimação do comprimento fosse iniciada quando o veículo tivesse surgido por completo na região analisada (de fato percebeu-se a estimação de pequenas dimensões veiculares nos primeiros 10 metros). Por outro lado, o limite máximo foi adotado para evitar que a distorção do vídeo original (em função do ângulo de captura) pudesse interferir na estimação do comprimento veicular. Os comprimentos médios de todos os veículos da amostra estão apresentados na Tabela 4.

Vale salientar que apesar de se ter tomado o cuidado de realizar as filmagens em horários onde a luz solar produzisse sombras mínimas, os veículos dos primeiros e últimos vídeos de cada dia ainda apresentavam sombra considerável, tendenciando a estimação de veículos maiores do que a realidade. Por outro lado, por vezes os pontos extremos dos veículos detectados pelo algoritmo eram na verdade pontos internos como para-brisa frontal e traseiro, o que levava à estimação de veículos menores do que de fato eram. Ao fim, obteve-se a estimativa de comprimento veicular médio de 4,85 metros, com mediana igual a 4,68 metros e coeficiente de variação da ordem de 27%.

Tabela 4 - Estimação do comprimento veicular individual (Autor)

Ciclo	ID	Comprimento (m)	Ciclo	ID	Comprimento (m)	Ciclo	ID	Comprimento (m)	Ciclo	ID	Comprimento (m)
1	1	3,66	13	41	3,45	24	81	3,78	37	121	4,68
	2	5,70		42	6,09		82	5,85		122	5,28
	3	4,48		43	3,36	25	83	4,19		123	3,86
	4	3,88		44	2,50		84	2,03		124	5,30
	5	4,45	14	45	6,10	26	85	4,80	38	125	3,68
	6	4,46		46	3,21		86	4,42		126	3,26
2	7	6,21	15	47	5,90		87	3,91	39	127	3,35
	8	4,47		48	5,52		88	3,77		128	5,49
	9	6,09	16	49	2,96		89	4,63		129	4,06
	10	5,46		50	6,91		90	3,93		130	3,51
3	11	4,31	17	51	4,41	27	91	4,26	40	131	3,82
	12	3,94		52	5,54		92	5,09		132	3,28
	13	2,83	18	53	5,03	28	93	4,08	41	133	5,04
	14	6,25		54	4,94		94	5,25		134	4,48
4	15	4,29		55	4,75	29	95	3,76	42	135	8,35
	16	4,39		56	4,98		96	4,29		136	2,76
5	17	3,50		57	4,23		97	4,03	43	137	6,18
	18	4,68		58	4,20		98	2,18		138	5,90
6	19	4,27	59	3,69	30		99	4,08		139	4,10
	20	4,64	60	4,88			100	5,24		140	6,69
	21	4,66	61	6,14	31	101	4,23	141		5,08	
	22	4,18	62	4,73		102	6,10	142		5,82	
7	23	3,63	19	63	4,51	32	103	5,38	44	143	5,92
	24	4,13		64	4,11		104	4,73		144	5,25
8	25	6,85	20	65	4,83	33	105	5,71	45	145	6,08
	26	5,49		66	2,81		106	5,92		146	4,81
9	27	3,83		67	5,40		107	4,63	46	147	5,64
	28	6,51		68	5,82		108	6,04		148	4,62
10	29	5,98	21	69	3,81	34	109	5,31		149	7,88
	30	4,80		70	5,18		110	5,36		150	7,54
11	31	12,78		71	5,99		111	5,26	47	151	6,40
	32	5,04		72	4,63		112	4,59		152	6,96
	33	3,54		73	3,18		113	6,70	48	153	4,52
	34	3,34		74	4,69		114	3,70		154	7,67
12	35	4,47	22	75	4,89	35	115	4,91	49	155	8,34
	36	5,52		76	4,01		116	6,81		156	6,78
	37	4,09		77	3,36	36	117	4,85	50	157	2,65
	38	4,33		78	5,02		118	5,11		158	4,07
	39	5,89	23	79	4,83	119	5,25				
	40	2,22		80	4,28	120	4,81				

4.3.5.2 Distância entre Veículos Parados e Comprimento de Fila

Para estimar a distância média entre veículos parados e o comprimento médio das filas formadas observou-se os ciclos onde havia pelo menos dois veículos parados em função da interseção semaforizada. Esta condição foi satisfeita em 19 ciclos, totalizando uma amostra

com 49 veículos, cujas distâncias entre si e comprimentos de fila estão apresentados na Tabela 5. As situações de maior e menor distância entre veículos parados estão ilustradas na Figura 18, onde as linhas vermelhas indicam quais veículos devem ser considerados.



Figura 18 - Maior (esquerda) e menor (direita) distância entre veículos parados (Autor)

Tabela 5 - Estimação da distância entre veículos parados e do comprimento de fila (Autor)

Ciclo	ID	Distância Entre Veículos Parados (m)	Comprimento de fila (m)	Veículos Parados
1	1-2	2,57	17,28	3
	2-3	4,11		
2	4-5	2,72	12,15	2
3	6-7	4,37	9,87	2
7	8-9	5,31	13,57	2
12	10-11	4,17	19,58	2
13	12-13	2,51	16,80	3
	13-14	3,83		
	15-16	3,27	10,11	2
19	17-18	3,03	36,16	5
	18-19	4,44		
	19-20	3,19		
	20-21	3,56		
21	22-23	13,90	21,15	2
22	24-25	4,37	11,51	2
23	26-27	3,09	16,14	3
	27-28	2,57		
27	29-30	4,25	27,77	3
	30-31	6,45		
30	32-33	3,42	9,47	2
35	34-35	3,86	9,77	2
36	36-37	2,94	19,72	3
	37-38	4,08		
38	39-40	3,02	11,47	2
39	41-42	3,30	10,33	2
41	43-44	3,41	9,16	2
43	45-46	2,45	15,80	3
	46-47	3,54		
46	48-49	3,50	10,81	2

A Tabela 6 apresenta um resumo da estimação através de estatística descritiva da amostra.

Tabela 6 - Estatística descritiva da estimação da distância entre veículos parados e do comprimento de fila (Autor)

	Média	Máximo	Mínimo	Desvio Padrão	Coefficiente de Variação	Mediana	15° Percentil	85° Percentil
Distância Entre Veículos Parados (m)¹	3,97	13,90	2,45	2,06	51,95%	3,50	2,76	4,37
Distância Entre Veículos Parados (m)²	3,62	6,45	2,45	0,88	24,22%	3,46	2,73	4,36
Comprimento de fila (m)	15,43	36,16	9,16	6,76	43,83%	12,86	9,85	19,93
	2,45	5,00	2,00	0,74	30,20%	2,00	2,00	3,00

distância¹: análise estatística da distância entre veículos considerando o ciclo 21.

distância²: análise estatística da distância entre veículos desconsiderando o ciclo 21.

As observações feitas no tópico anterior (estimação de comprimento veicular) sobre os pontos extremos detectados são válidas aqui também e influenciam principalmente na estimação da distância média entre veículos parados. Observe que há duas estimações para a distância entre veículos parados: na primeira, considera-se todos os 19 ciclos onde havia pelo menos dois veículos parados na interseção semaforizada; na segunda, exclui-se o ciclo onde se notou um comportamento atípico onde um condutor optou por manter uma distância considerável para o veículo parado à sua frente (ciclo 21 – Tabela 6). Assim, percebeu-se que a estimação da distância entre veículos parados tornou-se mais coerente de acordo com a observação dos vídeos processados. De fato, nota-se que a média, o desvio padrão e, conseqüentemente o coeficiente de variação, sofrem redução significativa na segunda estimação, enquanto a mediana e o 15° e 85° percentil não. Portanto, estimou-se uma distância média entre os veículos parados igual a 3,62 metros com coeficiente de variação da ordem de 24%.

Um ponto importante que merece destaque é a diferença entre a distância média entre veículos parados obtida neste estudo e a que foi obtida por Lacerda e Castro-Neto (2013), quando calibraram o modelo de *car-following* Wiedemann-74 no software VISSIM. Na ocasião, em outro trecho da mesma via, coletou-se o valor de 1,9 metros para o parâmetro *ax* do modelo. Os motivos que causam tamanha discrepância precisam ser investigados, mas mudanças de comportamento do usuário e alterações na infraestrutura das vias podem ajudar a explicar o fenômeno.

Com relação ao comprimento das filas, percebe-se que, em geral, não foram formadas filas muito longas, sendo mais comum a parada de 2 ou 3 veículos por ciclo, conforme Tabela 6. A fila máxima é consequência da formação de parada de 5 veículos, enquanto que apenas em outros dois ciclos o comprimento ultrapassou o 85° percentil. Assim, estimou-se um

comprimento médio de fila igual a 15,43 metros com coeficiente de variação de aproximadamente 44%.

4.3.5.3 Velocidade, Atraso e Número de Paradas

A estimação da velocidade média e do atraso veicular foi executada com base na mesma amostra de 158 veículos, apresentada no tópico 4.3.5.1 (comprimento veicular) (Tabela 7). A velocidade média da corrente foi estimada de acordo com a Equação 1:

$$v_m = \frac{s_2 - s_1}{t_2 - t_1} \quad (\text{Equação 1})$$

onde:

v_m é a velocidade média;
 s_2 é a coordenada final do rastreamento;
 s_1 é a coordenada inicial;
 t_2 é o tempo final do rastreamento;
 t_1 é o tempo inicial.

Estimou-se a velocidade média para cada veículo que parou e, a seguir, obteve-se uma estimativa da velocidade média dos veículos que não pararam com uma amostra de mesmo tamanho. A amostra dos veículos que não pararam foi selecionada por ciclos de modo que, por ciclo, observou-se o mesmo número de veículos que pararam e que não pararam. Após a estimação da velocidade média, o tempo de percurso foi estimado com base no comprimento do trecho em análise que correspondia a 110 metros, com exceção dos ciclos 10, 11, 32 e 33 (destacados na tabela), onde o comprimento correspondia a 105 metros (Equação 2).

$$t_p = \frac{c_t}{v_m} \quad (\text{Equação 2})$$

onde:

t_p é o tempo de percurso;
 c_t é o comprimento do trecho;
 v_m é a velocidade média estimada na Equação 1.

De posse dos tempos de viagem dos veículos que pararam e dos que não pararam, estimou-se o atraso médio dos veículos por ciclo (Equação 3).

$$a_m = \frac{(t_{pp} - t_{pn}) * n_{vp}}{n_{vt}} \quad (\text{Equação 3})$$

onde:

a_m é o atraso médio de veículos por ciclo;
 t_{pp} é o tempo médio de percurso de veículos parados;
 t_{pn} é o tempo médio de percurso de veículos que não pararam;
 n_{vp} é o número de veículos que pararam;
 n_{vt} é o número total de veículos no ciclo.

Tabela 7 - Estimação de velocidade média e atraso veicular (Autor)

Ciclo	Veículos		Trajetórias Interrompidas		Trajetórias Livres		Atraso Veicular Médio (s)
	Total	Parados	Velocidade Média (km/h)	Tempo de Percurso (s)	Velocidade Média (km/h)	Tempo de Percurso (s)	
1	14	3	4,90	80,79	36,55	10,84	14,99
2	19	2	9,91	39,95	36,88	10,74	3,07
3	17	2	7,34	53,93	33,48	11,83	4,95
4	14	1	9,64	41,08	34,81	11,38	2,12
5	16	1	9,85	40,20	45,90	8,63	1,97
6	17	2	7,66	51,68	30,83	12,84	4,57
7	17	1	7,55	52,43	40,91	9,68	2,51
8	15	1	4,53	87,43	37,11	10,67	5,12
9	16	1	8,92	44,39	34,68	11,42	2,06
10 *	16	1	15,60	24,23	34,01	11,11	0,82
11 *	17	2	6,75	56,04	48,73	7,76	5,68
12	18	3	5,97	66,30	41,20	9,61	9,45
13	16	2	5,95	66,52	46,07	8,59	7,24
14	14	1	7,68	51,53	40,73	9,72	2,99
15	15	1	7,95	49,82	41,65	9,51	2,69
16	13	1	6,67	59,39	41,78	9,48	3,84
17	13	1	14,19	27,90	38,65	10,25	1,36
18	23	5	10,51	37,68	37,17	10,65	5,87
19	18	1	13,04	30,36	38,92	10,17	1,12
20	14	2	9,03	43,85	44,37	8,93	4,99
21	17	2	4,59	86,24	43,98	9,00	9,09
22	22	3	7,09	55,86	34,07	11,62	6,03
23	15	1	7,27	54,46	36,17	10,95	2,90
24	14	1	5,13	77,12	44,37	8,92	4,87
25	18	1	16,38	24,18	33,44	11,84	0,69
26	12	3	8,93	44,34	47,18	8,39	8,99
27	14	1	5,39	73,41	33,30	11,89	4,39
28	19	1	6,38	62,06	24,18	16,38	2,40
29	21	2	4,87	81,24	40,77	9,71	6,81
30	12	1	5,40	73,32	32,05	12,36	5,08
31	14	1	8,27	47,88	47,32	8,37	2,82
32 *	13	1	7,84	48,24	33,30	11,35	2,84
33 *	14	2	8,39	45,07	33,18	11,39	4,81
34	21	3	6,53	60,60	33,58	11,79	6,97
35	19	1	6,63	59,70	36,07	10,98	2,56
36	9	2	13,50	29,33	39,04	10,14	4,26
37	14	2	9,09	43,54	35,06	11,30	4,61
38	13	1	17,08	23,18	35,08	11,29	0,91
39	16	2	5,10	77,57	33,94	11,67	8,24
40	9	1	6,05	65,42	42,72	9,27	6,24
41	12	1	5,75	68,90	20,27	19,54	4,11
42	17	1	4,92	80,55	44,04	8,99	4,21
43	16	3	4,73	83,69	32,74	12,10	13,42
44	13	1	7,47	52,99	33,99	11,65	3,18
45	6	1	6,59	60,08	27,38	14,46	7,60
46	15	2	7,66	51,68	41,97	9,44	5,63
47	13	1	10,50	37,70	47,88	8,27	2,26
48	8	1	8,03	49,33	23,76	16,66	4,08
49	3	1	9,74	40,65	30,34	13,05	9,20
50	13	1	5,69	69,61	36,76	10,77	4,53

A Tabela 8 apresenta a estatística descritiva dos dados apresentados na Tabela 7. De acordo com a análise das amostras, velocidade média dos veículos que tiveram sua trajetória interrompida foi de 8,09 km/h, com tempo de percurso médio de 54,67 segundos. Enquanto isso, a velocidade média dos veículos que não pararam foi de aproximadamente 37,25 km/h, com tempo de percurso médio de 10,95 segundos. A velocidade média máxima para trajetórias interrompidas ocorreu em casos onde os veículos aproximaram-se da interseção próximo ao fim do tempo de vermelho, enquanto a velocidade mínima para trajetórias sem interrupção deu-se pela redução da velocidade de veículos para evitar parar no fim da fila. Ao fim, pode-se estimar um atraso veicular médio de 4,82 segundos para o trecho em análise.

Tabela 8 - Estatística descrita da estimação de velocidade média e atraso veicular (Autor)

	Veículos		Trajetórias Interrompidas		Trajetórias Livres		Atraso Veicular Médio (s)
	Total	Parados	Velocidade Média (km/h)	Tempo de Percurso (s)	Velocidade Média (km/h)	Tempo de Percurso (s)	
Média	14,88	1,58	8,09	54,67	37,25	10,95	4,82
Máximo	23	5	17,08	87,43	48,73	19,54	14,99
Mínimo	3	1	4,53	23,18	20,27	7,76	0,69
Desvio Padrão	3,74	0,85	3,05	17,08	6,29	2,19	2,97
Coefficiente de Variação	25,13%	53,84%	37,64%	31,24%	16,88%	20,03%	61,63%
Mediana	15	1	7,51	52,71	36,65	10,80	4,46
15º Percentil	12	1	5	38	33	9	2
85º Percentil	18	2	10	76	44	12	7

Conforme mencionado anteriormente (subseção 4.3.5.1), o rastreamento executado pelo algoritmo indica a parada de 79 veículos nos 50 ciclos considerados neste trabalho (Tabela 7). Entretanto, o algoritmo perdeu o rastreamento de outros 4 veículos que pararam, o que representa um erro de 4,76%, consideravelmente baixo e aceitável. Além disso, constata-se o rastreamento de 744 veículos que cruzaram a interseção. O número de trajetórias perdidas e de mudanças de faixa serão discutidos posteriormente (subseção 4.3.5.5).

4.3.5.4 Headway Veicular

A estimação de *headway* foi executada tomando como linha de referência a faixa de retenção dos veículos junto à faixa de pedestres, com erro de +/- 0,25 m. Assim, a cada ciclo, obteve-se os *headways* entre os veículos ao cruzarem a linha de referência, consolidando uma amostra de 744 veículos, apresentada sob a forma de estatística descritiva na Tabela 9. O “*headway 1*” significa a diferença temporal entre o instante em que o primeiro veículo do ciclo cruzou a linha de referência para o segundo e assim por diante. Assim, em todos os 50 ciclos

observados houve pelo menos 2 veículos (ou seja, 1 *headway*), ao passo que em apenas um ciclo houve 23 veículos cruzando a faixa de referência (ou seja, 22 *headways*).

Tabela 9 - Estatística descritiva da estimação de *headways* (Autor)

<i>Headway</i>	Amostra	Média	Desvio Padrão	Coefficiente de Variação	Mediana	Máximo	Mínimo	15° Percentil	85° Percentil
1	50	6,82	4,23	62,05%	6,31	17,72	1,60	2,58	11,59
2	50	4,31	3,19	73,94%	3,35	15,05	0,63	1,75	8,16
3	49	4,42	2,82	63,63%	3,84	13,58	1,13	1,78	6,75
4	49	4,45	3,46	77,79%	2,84	15,68	1,07	1,90	7,58
5	49	4,57	3,02	65,95%	3,57	13,91	1,13	1,78	7,07
6	48	4,31	3,60	83,52%	3,04	19,39	0,87	1,64	7,64
7	48	4,77	4,60	96,44%	3,02	25,36	0,83	1,84	8,25
8	47	4,50	3,31	73,62%	3,07	14,35	0,80	1,72	8,26
9	45	3,76	3,28	87,38%	3,14	22,39	1,17	1,65	4,70
10	45	4,26	3,40	79,76%	3,34	17,98	0,90	1,69	7,77
11	45	4,15	4,14	99,85%	2,87	27,03	1,20	1,63	6,73
12	42	4,71	3,88	82,45%	3,44	23,76	1,23	2,20	7,12
13	35	3,37	1,79	53,02%	3,07	8,21	1,17	1,49	5,06
14	26	3,40	2,23	65,74%	3,07	11,28	0,80	1,65	4,97
15	22	4,42	3,87	87,60%	2,82	15,01	1,23	1,81	7,25
16	16	4,60	3,55	77,19%	3,75	15,65	1,13	1,62	7,29
17	10	6,80	4,07	59,91%	6,77	12,88	1,53	2,39	11,51
18	7	2,66	2,25	84,60%	1,67	7,61	1,00	1,00	4,51
19	4	1,92	0,43	22,63%	2,04	2,37	1,23	1,52	2,29
20	4	3,50	1,14	32,60%	3,39	5,17	2,07	2,47	4,56
21	2	2,04	0,13	6,56%	2,04	2,17	1,90	1,94	2,13
22	1	5,04	0,00	0,00%	5,04	5,04	5,04	5,04	5,04

Os dados da Tabela 9 foram utilizados para a construção do gráfico ilustrado na Figura 19 que traz a estimação da média e da mediana dos *headways* ao longo dos veículos do ciclo, bem como do 15° e do 85° percentil. De acordo com o gráfico, percebe-se que há a formação de pelotões onde os *headways* entre o primeiro e segundo veículos são maiores em função da aceleração para sair do repouso. A seguir, ocorre uma estabilização dos *headways* indicando a relação entre veículos líderes e seguidores, mantendo praticamente a distância entre si. *Headways* a partir do 14° e 15° passam a ter menor representatividade em função do tamanho da amostra.

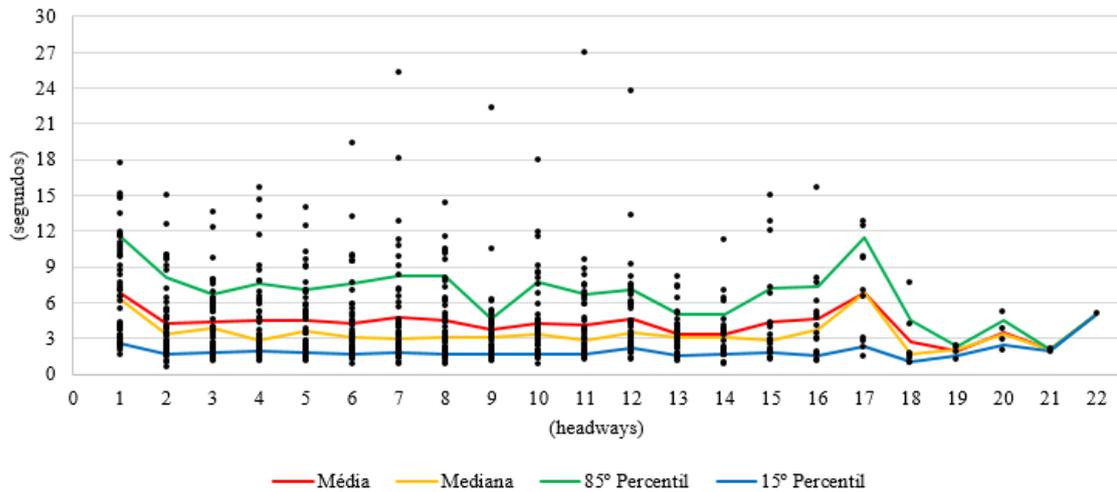


Figura 19 - Representação gráfica dos headways veiculares (Autor)

4.3.5.5 Número de Mudanças de Faixa

O número de mudanças de faixa é uma variável importante para a compreensão do perfil comportamental dos veículos, podendo ser utilizado, por exemplo, para construção de modelos de previsão de acidentes. Assim, os vídeos foram observados ao passo que eram comparados com os diagramas espaço-tempo produzidos pelo algoritmo para identificar os movimentos de mudança de faixa.

A Tabela 10 traz o número de mudanças de faixa observados por vídeo. Vale salientar que se definiu mudança de faixa como o movimento de saída da faixa e que o trecho considerado foi da entrada da região de interesse até a faixa de contenção. Buscou-se alguma relação entre os valores apresentados na tabela e o volume de veículos, mas aparentemente não há relação direta, indicando um comportamento aleatório de acordo com as filas que se formavam junto à faixa de retenção, com a velocidade do veículo líder entre outros fatores.

Tabela 10 - Estimação de número de mudanças de faixa (Autor)

	Vídeo											
	1	2	3	4	5	6	7	8	9	10	11	12
Número de Mudanças de Faixa	34	22	16	23	29	20	21	32	26	24	29	21

5 CONCLUSÃO

Este trabalho foi motivado pela dificuldade que os principais métodos de estudo de tráfego voltados ao fluxo veicular urbano têm de prover um levantamento minucioso de dados desagregados que permitam uma descrição eficiente das trajetórias veiculares individuais para uso na gestão operacional. A investigação do uso da Visão Computacional para obtenção de parâmetros veiculares vem se consolidando como uma estratégia de grande potencial.

No entanto, relatos de sua aplicação encontrados na literatura apontam para investigações de fluxo rodoviário não interrompido em detrimento de estudos de tráfego urbano interrompido. Assim, o grande objetivo deste trabalho foi propor um método para executar estudos desagregados de tráfego veicular microscópico urbano através de diagramas espaço-tempo construídos com uso da Visão Computacional.

A primeira conquista deste trabalho, referente ao primeiro objetivo específico traçado, consiste na melhor compreensão do princípio das principais estratégias de Visão Computacional aplicadas a estudos de tráfego. A partir dessa compreensão pôde-se determinar a estratégia baseada em pontos notáveis (*feature-based tracking*) como a que melhor se corresponde às demandas do tráfego urbano interrompido. Os principais motivos são a capacidade de atuar em diferentes condições de iluminação e a capacidade de perder parcialmente informações e ainda continuar rastreando o veículo sem perda da qualidade das informações. Além disso, o rastreamento através de pontos notáveis permitiu a implementação de restrições que, posteriormente, contribuíram para o sucesso das etapas do algoritmo desenvolvido. Por outro lado, ao passo que restrições foram adicionadas percebeu-se o acréscimo de demanda de processamento computacional que já é naturalmente alta na estratégia *Feature-based tracking*.

A seguir, o desenvolvimento do algoritmo de Visão Computacional para extração de informações veiculares individuais detalhadas foi executado com sucesso (construído com base na estratégia *Feature-based tracking*). A programação foi executada na linguagem *Python* utilizando-se a biblioteca *OpenCV*. A Visão Computacional, juntamente com a linguagem *Python* e a biblioteca *OpenCV* vêm se mostrando ferramentas importantes e potenciais para aplicação na Engenharia de Transportes entre outras áreas. O produto desta etapa metodológica foi um algoritmo com oito etapas bem definidas e capaz de contornar diversas dificuldades encontradas no ambiente de tráfego urbano como a parada de veículos, alcançando o segundo objetivo deste trabalho.

Algumas etapas do algoritmo merecem destaque: o processo de homografia desenvolvido por Cunha (2013) foi importante para corrigir as deformações das *ROIs*; a etapa de subtração de fundo foi desenvolvida com uso da função *MOG2* e da implementação de um fundo inicial que se adapta conforme as variações do ambiente; o código desenvolvido por Shi-Tomasi (1994) *cv2.goodFeaturesToTrack()* para detecção de pontos e o código desenvolvido por Lucas-Kanade (1981) *cv2.calcOpticalFlowPyrLK()* para rastreamento de pontos comprovaram sua robustez e atenderam às necessidades do algoritmo desenvolvido neste trabalho; e, por fim, o processo de agrupamento foi concebido através de restrições de movimento relativo e posicionamento entre os pontos detectados e rastreados conseguindo mantê-los atualizados ainda que parassem em qualquer momento e posição de seu percurso na região de interesse.

Através do processo de calibração, identificou-se os 19 parâmetros mais influentes (para o cenário em estudo) dentre os 33 existentes no algoritmo na versão utilizada neste estudo, de modo a concentrar os esforços para otimização dos resultados do processamento. A seguir, foram testadas 43 combinações para os parâmetros eleitos tendo como medidas de desempenho a qualidade do rastreamento e da contagem veicular. O processo de calibração destes parâmetros foi feito de forma heurística devido à restrição de tempo disponível.

Ao atingir o terceiro objetivo específico (calibração do algoritmo), os vídeos processados utilizando a calibração que melhor satisfaz às medidas de desempenho foram analisados para se obter descrição detalhada do desempenho do algoritmo, identificando acertos e tipificando erros. Constatou-se, então, uma taxa média de acertos de 91,52% para os 12 vídeos processados. Do total de erros, os erros de dupla contagem constituíram 4,45% enquanto a taxa média de veículos perdidos foi de 3,52% e agrupamentos representaram 0,51%. Em especial, o motivo da ocorrência dos erros de dupla contagem não ficou claro, fazendo-se necessária uma investigação dedicada a este erro em trabalhos futuros. Erros de falsos positivos e segmentações não foram constatados.

Por consequência, a aplicação do estudo de caso logrou sucesso com a obtenção de dados do rastreamento dos veículos em intervalos de 0,033 segundos. Os diagramas espaço-tempo foram construídos e analisados manualmente e mostraram-se condizentes com as trajetórias dos veículos representando bem mudanças de faixa, desacelerações e acelerações, e paradas.

A média dos comprimentos veiculares foi estimada em aproximadamente de 4,85 metros para uma amostra de 158 veículos, enquanto a distância entre veículos parados e comprimento de fila foram estimados em 3,62 e 15,43 metros, respectivamente, para uma

amostra de 49 veículos. Também foi possível estimar o número de veículos parados durante os ciclos, 79 veículos, de um total de 744 veículos que cruzaram a interseção na faixa analisada, bem como o número de mudanças de faixas que apresentou comportamento aleatório ao longo dos ciclos.

Em termos de informações desagregadas, obteve-se uma estimativa de velocidade média, atraso médio e *headway* para uma amostra de 158 veículos com uma precisão de +/- 0,25 metros. A estimativa da velocidade dos veículos que cruzaram a interseção sem parar (37,25 km/h) foi utilizada para estimar o atraso médio dos veículos (4,82 segundos) ao comparar com a velocidade média dos veículos que pararam (8,09 km/h). Por fim, o padrão decrescente da média dos primeiros *headways* estimados seguido de estabilização confirma a formação de pelotões nos ciclos em função da semaforização. Portanto, atingiu-se também o último objetivo proposto para este trabalho referente à efetivação de um estudo de caso para construção de diagramas espaço-tempo e estimação de variáveis de fluxo veicular interrompido.

Após atingir todos os objetivos específicos propostos para este trabalho, constatou-se a viabilidade do método para executar estudos desagregados de tráfego veicular microscópico urbano com auxílio de diagramas espaço-tempo construídos com aplicação da Visão Computacional.

Uma evolução natural deste trabalho consiste no aprimoramento contínuo do algoritmo e de suas aplicações. Sugere-se a implementação de uma interface gráfica para facilitar o uso e evitar a alteração não intencional do código-fonte. Outro aprimoramento necessário, na etapa da subtração de fundo, consiste em melhorar o processo de atualização para que os vídeos possam ter o processamento iniciado em momentos onde existam veículos dentro da região de interesse. Além disso, outra melhoria seria aumentar a capacidade de lidar com variações de iluminação e com vídeos de baixa qualidade, reduzindo a demanda de processamento. Com relação ao agrupamento, novas restrições podem ser avaliadas para diminuir o processamento das hipóteses veiculares e aumentar a taxa de sucesso do algoritmo.

Em relação às aplicações, o algoritmo pode ser avaliado em diferentes cenários: variando horários do dia para avaliar a robustez quanto a variação do fluxo; aumentando o número de faixas processadas para construir diagramas paralelos da via; testando diferentes posicionamentos da câmera para observar a influência do ângulo de captura sobre o desempenho do algoritmo; com calibração voltada para diferentes usuários como motocicletas, ônibus, bicicletas, pedestres etc.

Atualmente, o algoritmo só detecta novos pontos em uma fração da *ROI*. Com isso, veículos que adentrem a *ROI* depois desse limite não são considerados. A expansão dessa área

de detecção juntamente com a otimização das demais etapas (para reduzir o tempo de processamento) permitirá a observação de mais movimentos de mudança de faixa de veículos vindos de outras faixas. O mesmo vale para o sentido do rastreamento que atualmente é único, dificultando a análise de movimentos pedonais, por exemplo.

Entretanto, o algoritmo mostrou ter um grande potencial e com as devidas melhorias pode se tornar capaz de fornecer informações cada vez mais detalhas para estudos de Engenharia de Transportes. Diversas outras variáveis podem ser obtidas a partir do rastreamento de veículos pelo diagrama espaço-tempo como aceleração, fluxo de saturação, largura dos veículos, tempo para colisão (*Time to Collision – TTC*), taxa de desaceleração para evitar colisão (*Deceleration Rate to Avoid Collision – DRAC*) etc.

REFERÊNCIAS

AASHTO **Highway Safety Manual**. American Association of State Highway and Transportation Officials. 1st. ed., Washington, 2010.

AKÇELIK, R.; BESLEY, M. **Queue discharge flow and speed models for signalized intersections**. In: INTERNATIONAL TRANSPORTATION AND TRAFFIC THEORY, 15, 2002.

ANWAR, A.; ZENG, W.; ARISONA, S. M. The time space diagram revisited. **Transportation Research Board of the National Academies**, Washington, p. 1-7, 2014.

ATEV, S.; ARUMUGAM, H.; MASOUD, O.; JANARDAM, R. A video-based approach to collision prediction at traffic intersections. **IEEE, Transactions on Intelligent Transportation Systems**, v. 6, n. 4, p. 416-223, 2005.

BEYMER, D. *et al.* A real-time computer vision system for measuring traffic parameters. **IEEE Conference on Computer Vision and Pattern Recognition**, p. 495-501, 1997.

BRADSKI, G.; KAEHLER, A. **Learning OpenCV**. Sebastopol: O'Reilly Media Inc., 2008, 555 p., 2008.

BUCH, N.; ORWELL, J.; VELASTIN, S. A. **Detection and classification of vehicles for urban traffic scenes**. Institution of Engineering and Technology, p. 182-187, 2008.

CÂMARA, S. M.; SANTOS, D. A.; CUNTO, F. J. C. **Avaliação do uso da estratégia de visão computacional region based em pesquisas volumétricas em áreas urbanas**. In: CONGRESSO DE PESQUISA E ENSINO EM TRANSPORTES, 29, 2015, Ouro Preto. **Anais**. Ouro Preto, 2015, p. 1530-1541.

LACERDA, V.; CASTRO-NETO, M. M. **Considerações sobre a calibração do modelo de car-following do Vissim para vias arteriais urbanas**. In: CONGRESSO DE PESQUISA E ENSINO EM TRANSPORTES, 28, 2014, Curitiba. **Anais**. Curitiba, 2014.

CHANG, F.; CHEN, C-J.; LU, C-J. **A linear-time component-labeling algorithm using contour tracing technique**. *Computer Vision and Image Understanding*, p. 206-220, 2003.

COIFMAN, B. *et al.* A real-time computer vision system for vehicle tracking and traffic surveillance. **Transportation Research Part C: Emerging Technologies**, v. 6, n. 4, p. 271-288, 1998.

CUNHA, A. L. B. N. **Sistema automático para obtenção de parâmetros do tráfego veicular a partir de imagens de vídeo usando OpenCV**. 2013. Tese (Doutorado em Engenharia de Transportes). Universidade de São Paulo, 128 p., 2006.

CUNHA, A. L. B. N.; SETTI, J. R.; GONZAGA, A. **Comparação dos modelos de geração de background em processamento de vídeos de tráfego veicular**. In: CONGRESSO DE PESQUISA E ENSINO EM TRANSPORTES, 27, 2013, Belém. **Anais**. Belém, 2013, p. 254-265.

DAGANZO, C. F. **Fundamentals of transportation and traffic operations**. Emerald, v. 1, 1997, 356 p.

DNIT. Departamento Nacional de Infra-estrutura de Transportes. **Manual de estudos de tráfego**. Instituto de Pesquisas Rodoviárias. Rio de Janeiro, 2006, 384 p.

ELEFTERIADOU, L. **An introduction to traffic flow theory**. Springer, New York, 2014, 262 p.

GARDNER, W. F.; LAWTON, D. T. Interactive model-based vehicle tracking. **IEEE, Transactions on Intelligent Transportation Systems**, v. 18, n. 11, p. 1115-1121, 1996.

GAZIS, D. C.; **Traffic Theory**. New York: Kluwer Academic Publishers, 2002, 274 p., 2002.

GODBEHERE, A. B.; MATSUKAWA, A.; GOLBERG, K. **Visual tracking of human visitors under variable lighting conditions for a responsive audio art installation**. IEEE, American Control Conference, p. 4305-4312, 2012.

GREENSHIELDS, B. D.; BIBBINS, J. R.; CHANNING, W. S.; MILLER, H. H. **A study of traffic capacity; Highway Research Board**, Washington: National Research Council, v. 14, p. 448-477, 1935.

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

HARRIS, C.; STEPHENS, M. **A combined corner and edge detector**. Alvey Vision Conference, p. 147-151, 1988.

HARTMANN, D.; MIDDLETON, D.; MORRIS, D. **Assessing vehicle detection utilizing video image processing technology**. Research Report (1467-4). The Texas A&M University System, 1996.

HOEL, L. A.; GARBER, N. J.; SADEK, A. W. **Transportation infrastructure engineering: a multimodal integration**. Cengage Learning, v. 1, 674 p., 2011.

HOFMANN, M.; TIEFENBACHER, P.; RIGOLL, G. **Background segmentation with feedback: the pixel-based adaptive segmenter**. IEEE, Computer Vision and Pattern Recognition Workshops, p. 38-43., 2012.

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

INSTITUTE OF TRANSPORTATION ENGINEERS. **Transportation Planning Handbook**. Washington, D.C., 2009.

IZADPANA, P.; HELLINGA, B.; FU, L. **Automatic traffic shockwave identification using vehicles' trajectories**. In: ANNUAL TRB CONFERENCE, 88, 2009, Washington.

JUNG, Y-K.; HO, Y-S. **Traffic parameter extraction using video-based vehicle tracking**. In: INTERNATIONAL CONFERENCE ON INTELLIGENT TRANSPORTATION SYSTEMS, 1999, p. 764–769.

KANAGARAJ, V. *et al.* Trajectory and flow characteristics of mixed traffic. **Journal of the Transportation Research Record**, v. 2491, p. 1-11, 2015.

KANHERE, N. K.; BIRCHFIELD, S. T.; SARASUA, W. A. Real-time detection and tracking of vehicle base fronts for measuring traffic counts and speeds on highways. **Transportation Research Board**, Washington, D.C., 2007, p. 155–164.

KIM, J. *et al.* **Three-dimensional time-space grid allocation algorithm for traffic control of autonomous vehicles at an intersection**. In: INTERNATIONAL CONFERENCE ON CONTROL, AUTOMATION AND SYSTEMS, 15, 2015, Busan. **Proceedings**. Busan, 2015, p. 505-508.

KLEIN, L. A. **Sensor technologies and data requirements for ITS**. Boston: Editora Artech House, 549 p.

KOLLER, D.; WEBER, J.; MALIK, J. **Robust multiple car tracking with occlusion reasoning**. ECCV, p. 189-196, 1994.

LEDUC, G. **Road traffic data: collection methods and applications**. JRC Technical Notes, 53 p.

LUCAS, B.; KANADE, T. **An iterative image registration technique with an application to stereo vision**. IJCAI, p. 674-679, 1981.

MAY, A. D. **Traffic flow fundamentals**. Prentice-Hall, 464 p., 1990.

OMID, M. R. **Queue dissipation shockwave speed for signalized intersections**. 2013.

OpenCV, 2014, disponível em <http://opencv.org/>

PETERFREUND, N. Robust tracking of position and velocity with Kalman snakes. **IEEE, Transactions on Pattern Analysis and Machine Intelligence**, v. 21, n. 6, p. 564-569, 1999.

QUIROGA, C. A.; BULLOCK, D. Measuring control delay at signalized intersections. **Journal of Transportation Engineering**, 1999.

ROESS, R. P.; PRASSAS, E. S.; MCSHANE, W. R. **Traffic engineering**: 4th ed. New Jersey: Prentice Hall, Englewood Cliffs, 2011.

SAUNIER, N.; SAYED, T. A feature-based tracking algorithm for vehicles in intersections. **IEEE, Computer and Robot Vision**, 2006a.

SAUNIER, N.; SAYED, T. **A safety evaluation of an adaptive traffic**. Advances in Transportation Studies 2, p. 83-96, 2014.

SAUNIER, N.; SAYED, T. **Automated road safety analysis using video sensors**. Technical Report, University of British Columbia, 2006b, 19 p.

SETCHELL, C. J. **Applications of computer vision to road-traffic monitoring**. 1997. Thesis. University of Bristol, Bristol, UK, 170 p., 1997.

SHI, J.; TOMASI, C. Good features to track. **IEEE, Computer Vision and Pattern Recognition**, p. 593-600, 1994.

SULLIVAN, G. D.; *et al.* **Model-based vehicle detection and classification using orthographic approximations**. Image and Vision Computing, v. 15, n. 8, p. 649-654, 1997.

TANCREDI, P. R.; WIDMER, J. A. **Monitoramento do acesso de veículos de carga em vias urbanas**. In: CONGRESSO DE PESQUISA E ENSINO EM TRANSPORTES, 26, 2012, Joinville. **Anais**. Joinville, 2012, p. 96-107.

TRB, **Highway Capacity Manual**. Transportation Research Board, Washington, 2010.

TSAI, R. Y. A versatile camera calibration technique for high accuracy 3D machine vision metrology using off-the-shelf TV cameras and lenses. **IEEE, Journal of Robotics and Automation**, v. 3, n. 4, p. 323-344, 1987.

ZIVKOVIC, Z. **Improved adaptive Gaussian mixture model for background subtraction.**
In: INTERNATIONAL CONFERENCE, 17, 2004. **Proceedings.** 2004. p. 28-31.

APÊNDICE A

Tabela A. 1 - Dados de saída do algoritmo de Visão Computacional (Autor)

Velocidade Média (km/h)	ID	Velocidade Instantânea em X (km/h)	Frame	Contagem	X Frente (m)	Y Frente (m)	X Traseira (m)	Y Traseira (m)
45.4347602	2	45.12155678	2815	1	7.618174	5.506648	5.6547287	2.6478103
45.0303873	2	46.36905262	2816	1	8.047846	5.508135	6.0636781	2.6497726
45.9346263	2	48.00940238	2817	1	8.493957	5.552457	6.5310402	2.6956504
45.5846203	2	43.01413716	2818	1	8.891373	5.557606	6.9097188	2.7020188
45.6736099	2	46.52459884	2819	1	9.321276	5.549503	7.3415498	2.6927843
46.0414617	2	47.85908415	2820	1	9.766665	5.61563	7.8041972	2.762009
45.5815721	2	44.42240721	2821	1	10.17949	5.556505	8.1851607	2.6976903
44.8691759	2	42.38155016	2822	1	10.56631	5.604657	8.6067491	2.7527338
45.3812317	2	44.72929571	2823	1	10.98451	5.682565	8.9973573	2.8202221
45.5652354	2	46.77759052	2824	1	11.41726	5.659068	9.4368519	2.7980496
45.5895489	2	46.58787371	2825	1	11.85359	5.660356	9.8996841	2.7999524
45.1096815	2	43.69059616	2826	1	12.25861	5.640471	10.272117	2.7779879
45.3976043	2	45.60544245	2827	1	12.68625	5.688948	10.722839	2.8250292
45.7290818	2	49.50789572	2828	1	13.14607	5.686129	11.190772	2.8173075
45.7594197	2	48.13212545	2829	1	13.58623	5.666167	11.582608	2.8026137
45.2237691	2	39.6015521	2830	1	13.95016	5.723888	11.981418	2.8557569
45.7688696	2	47.28745446	2831	1	14.38888	5.73263	12.390275	2.8750862
45.4969422	2	42.28194883	2832	1	14.78239	5.759419	12.795122	2.8993628

APÊNDICE B

Este apêndice dedica-se a apresentar os diagramas espaço-tempo construídos através do processamento dos vídeos pelo algoritmo de Visão Computacional desenvolvido nesta dissertação.

Para facilitar a compreensão, os diagramas foram divididos em até três partes. O eixo “x” diz respeito ao tempo em segundos enquanto o eixo “y” representa a distância em metros. As linhas laranjas representam a faixa de retenção de veículos junto à interseção, as linhas verdes indicam o momento em que o inicia a fase da luz verde no semáforo da via em análise e os pontos azuis representam a posição dos veículos ao longo do tempo.

Figura A.1 - Diagrama espaço-tempo do Vídeo 01

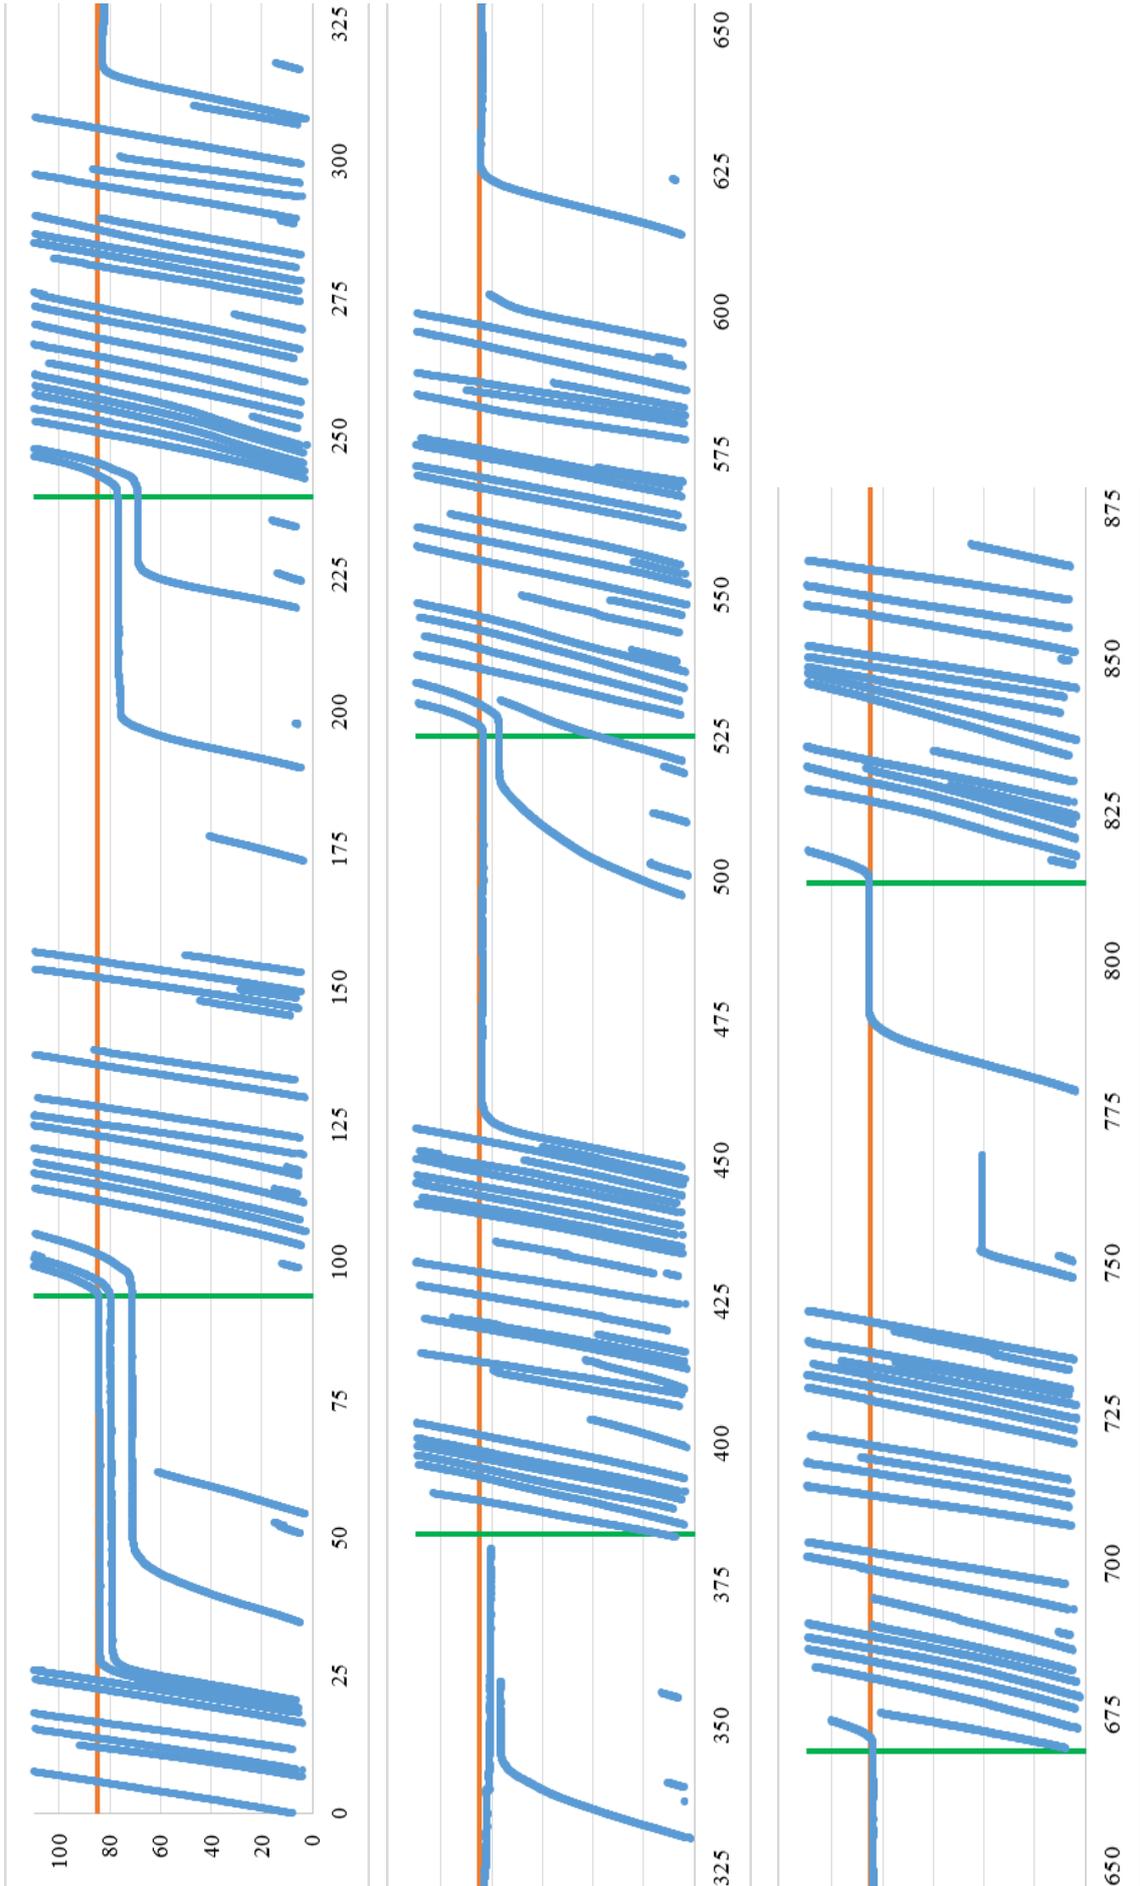


Figura A.2 - Diagrama espaço-tempo do Vídeo 02

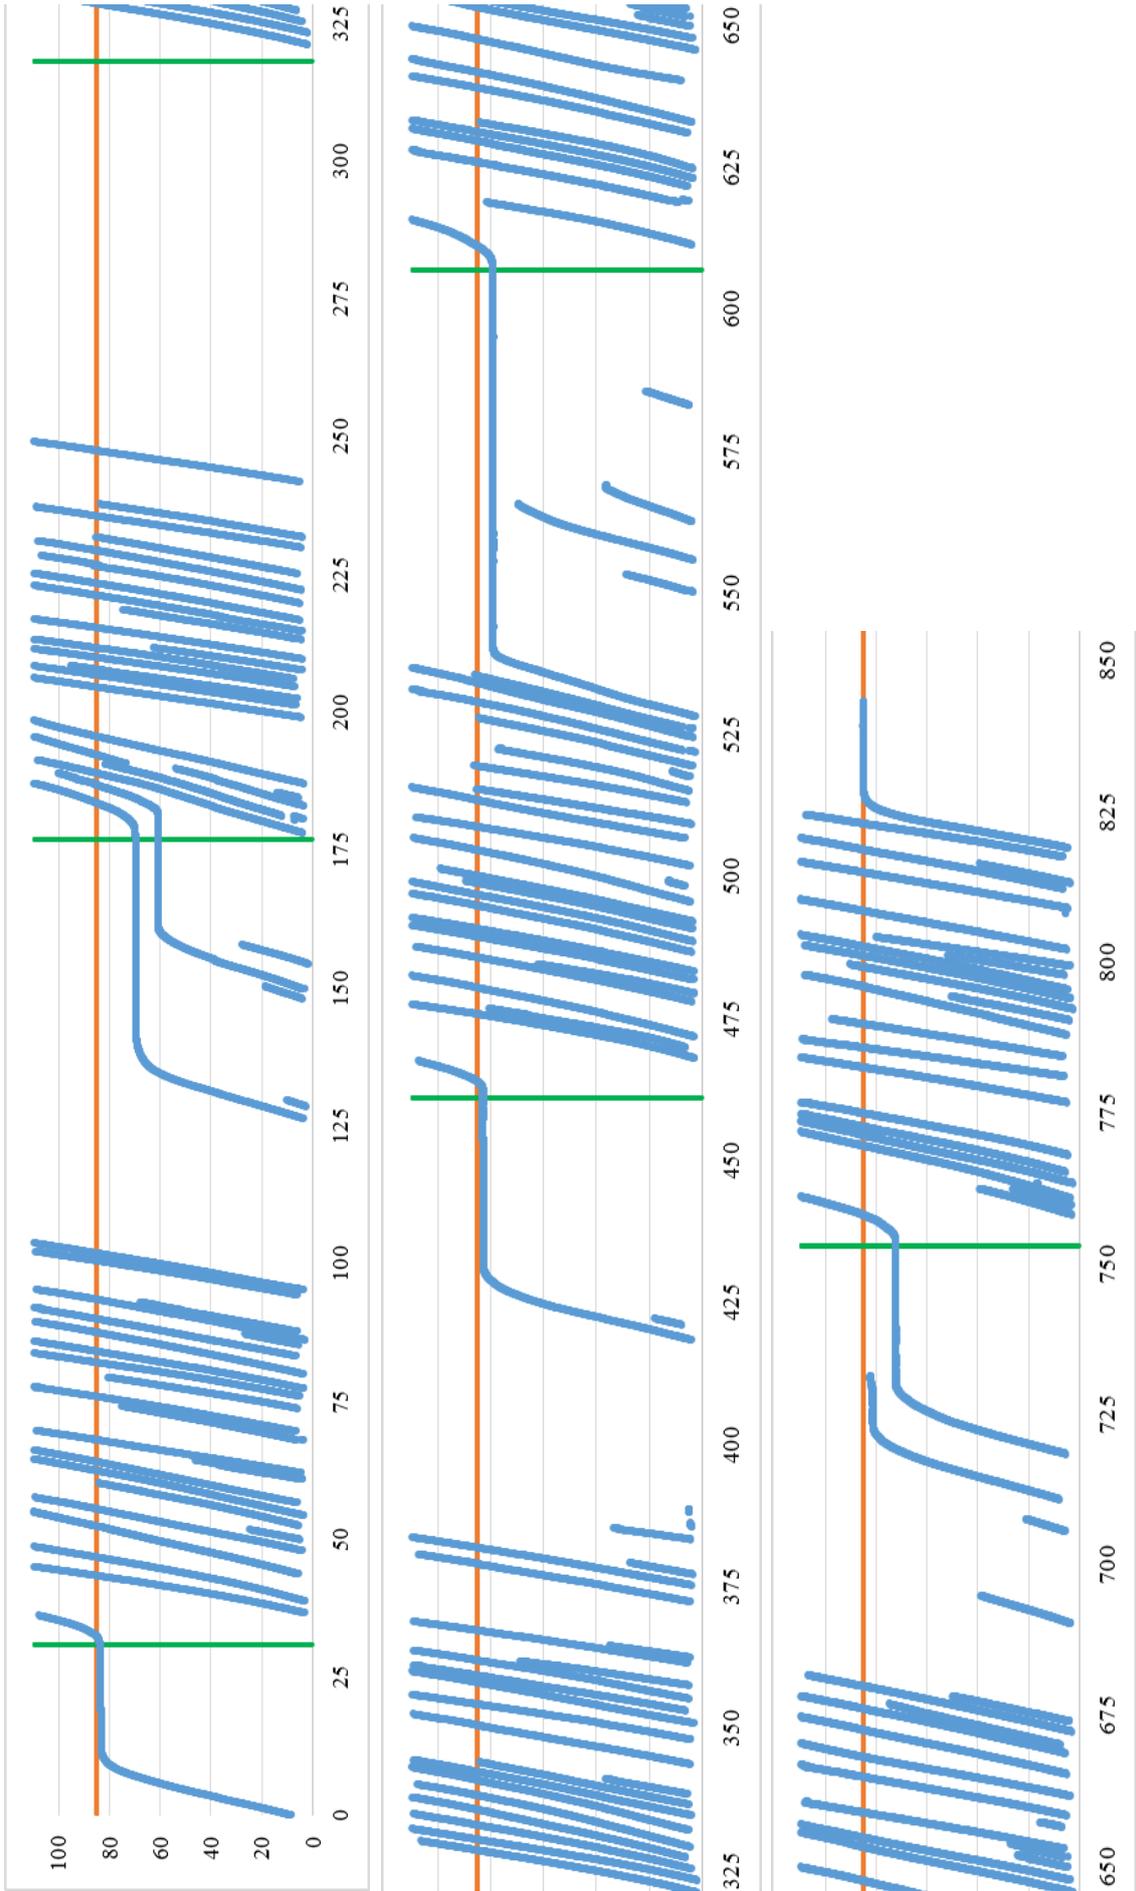


Figura A.3 - Diagrama espaço-tempo do Vídeo 03

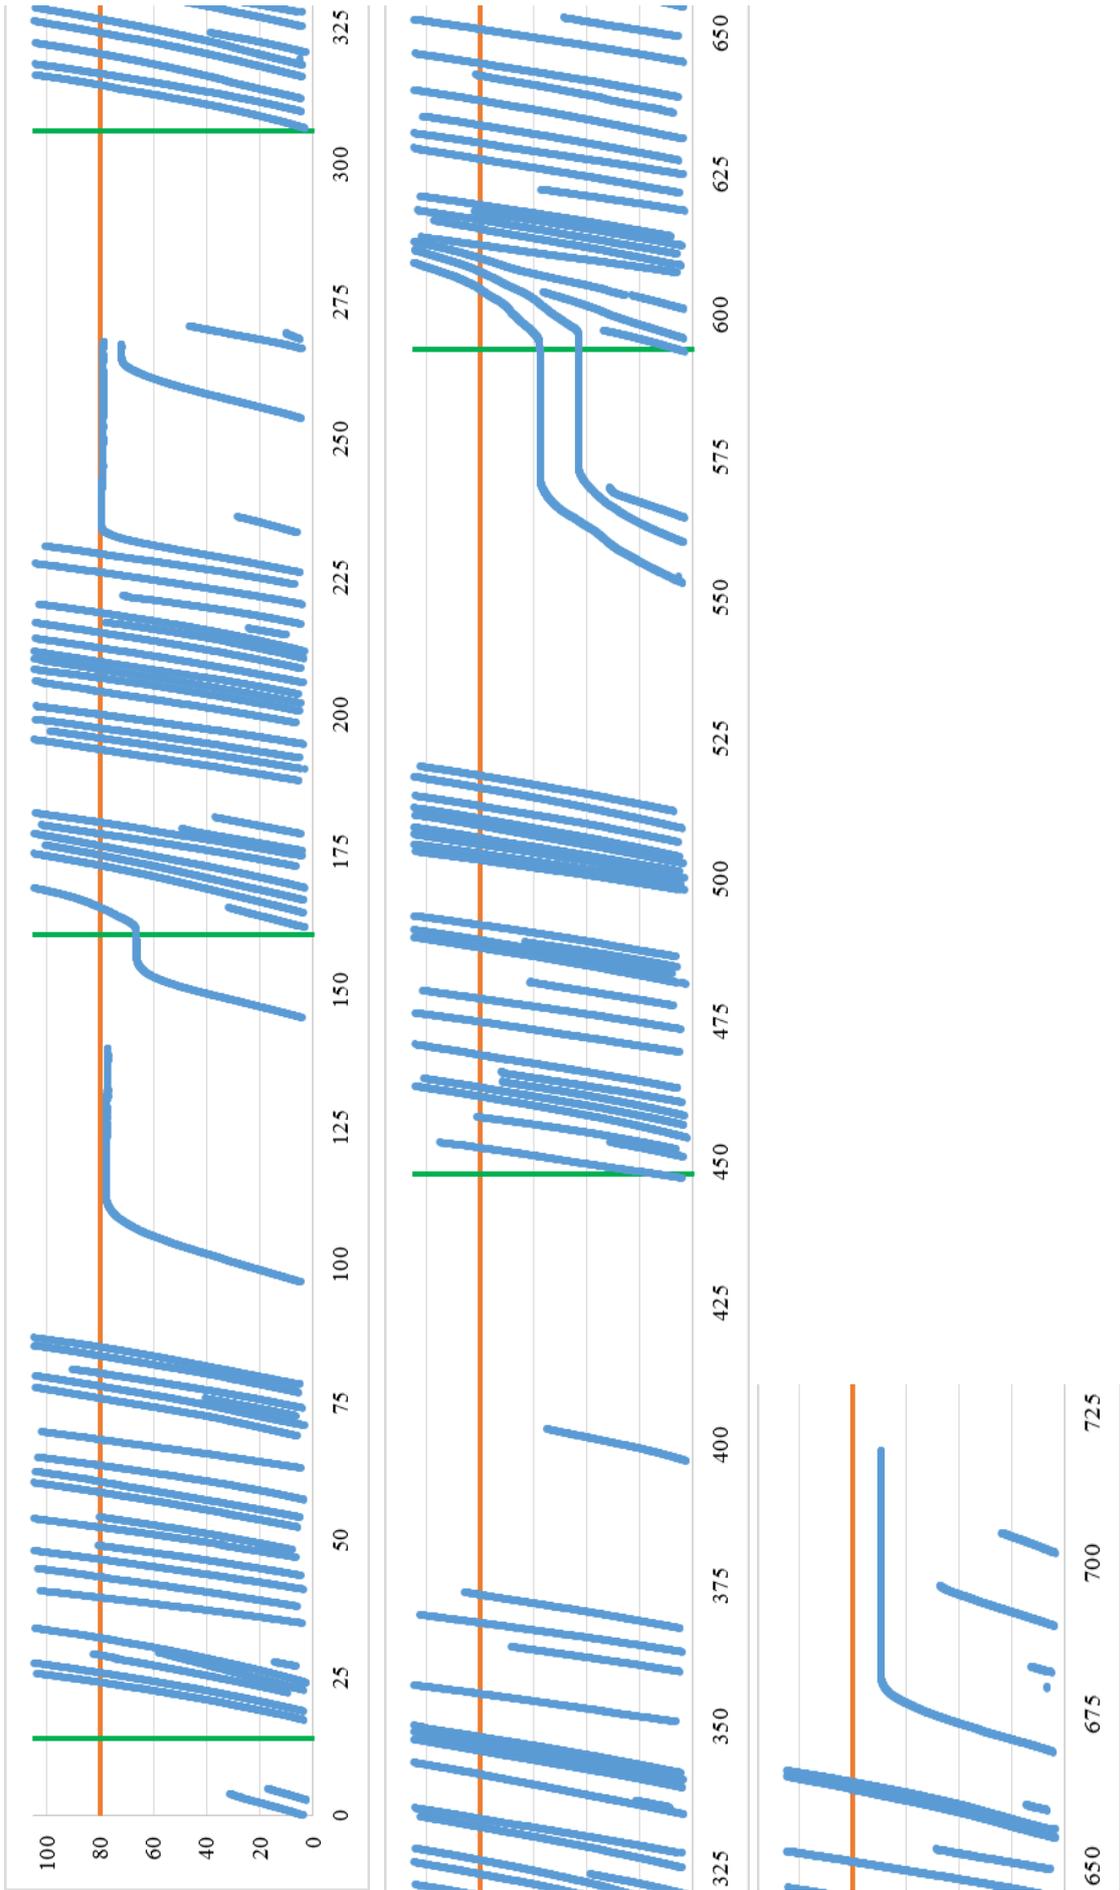


Figura A.4 - Diagrama espaço-tempo do Vídeo 04

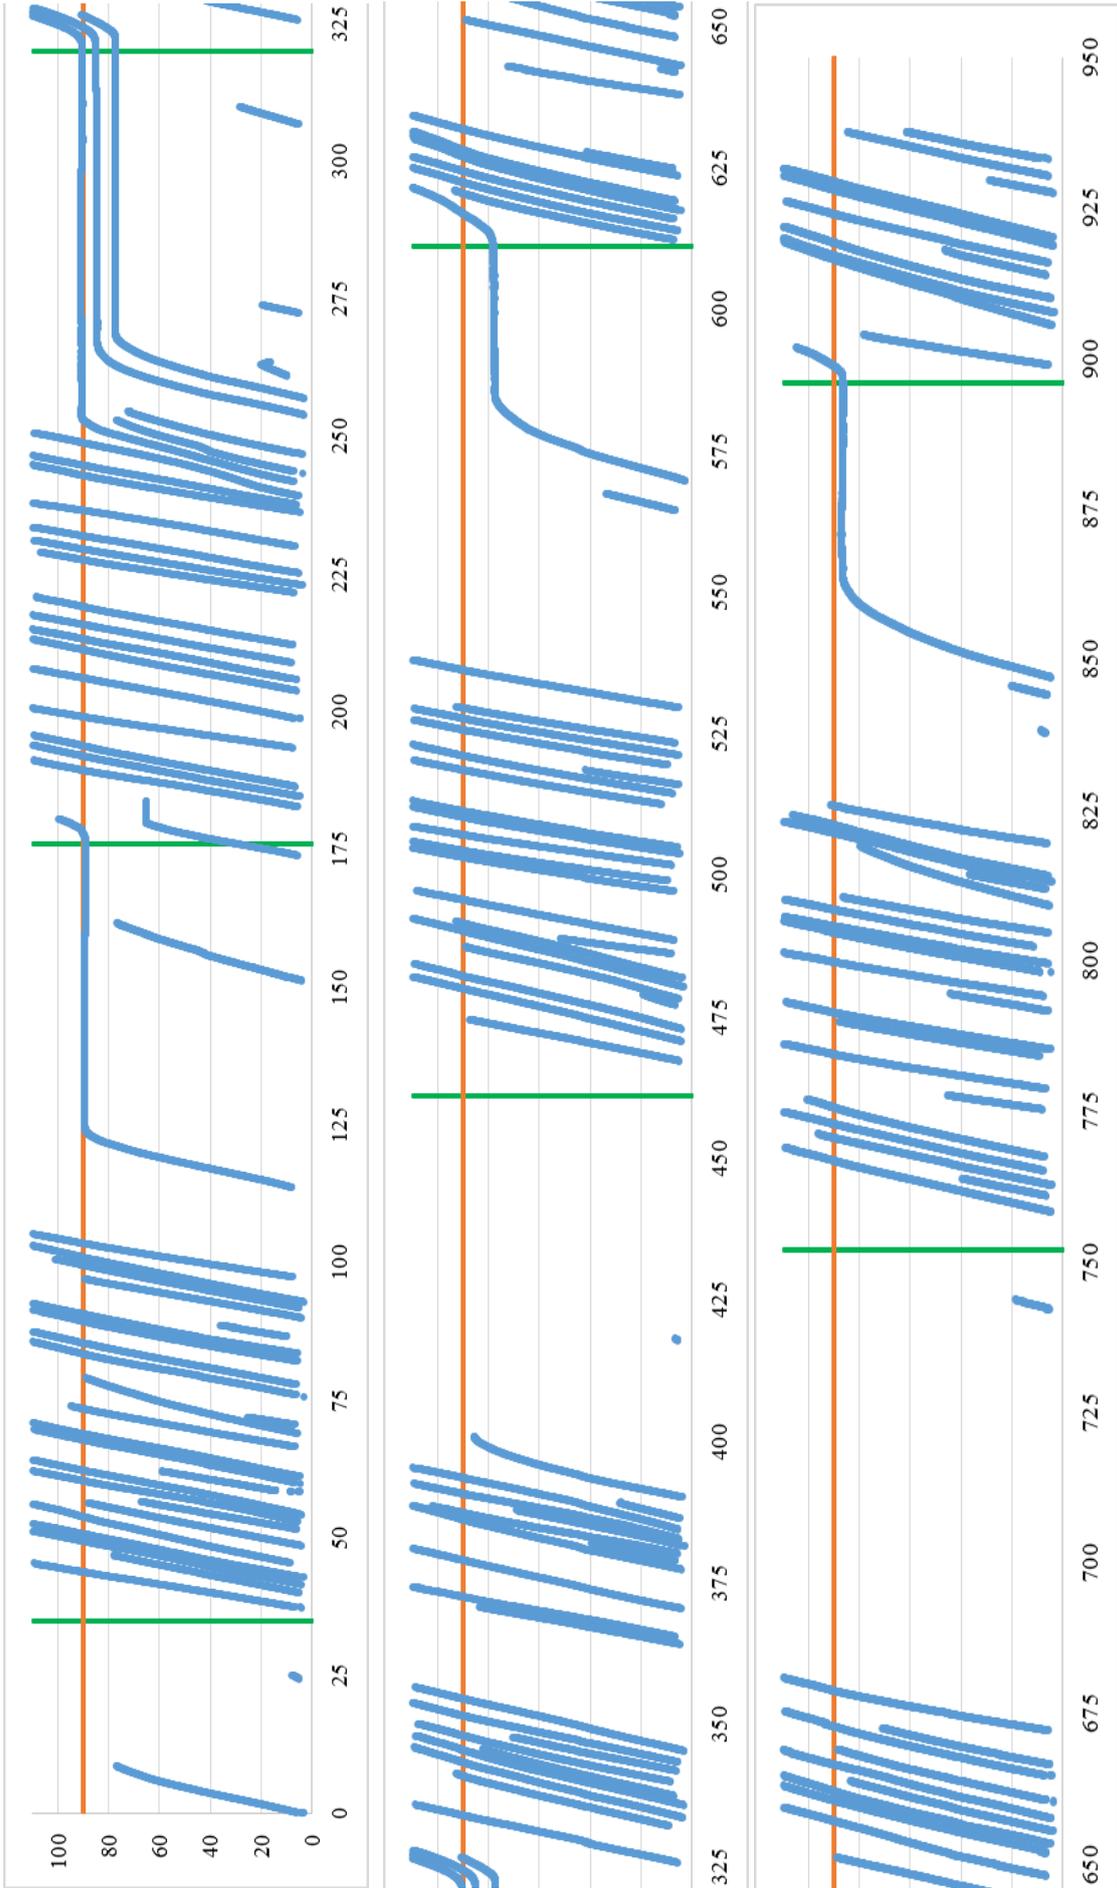


Figura A.5 - Diagrama espaço-tempo do Vídeo 05

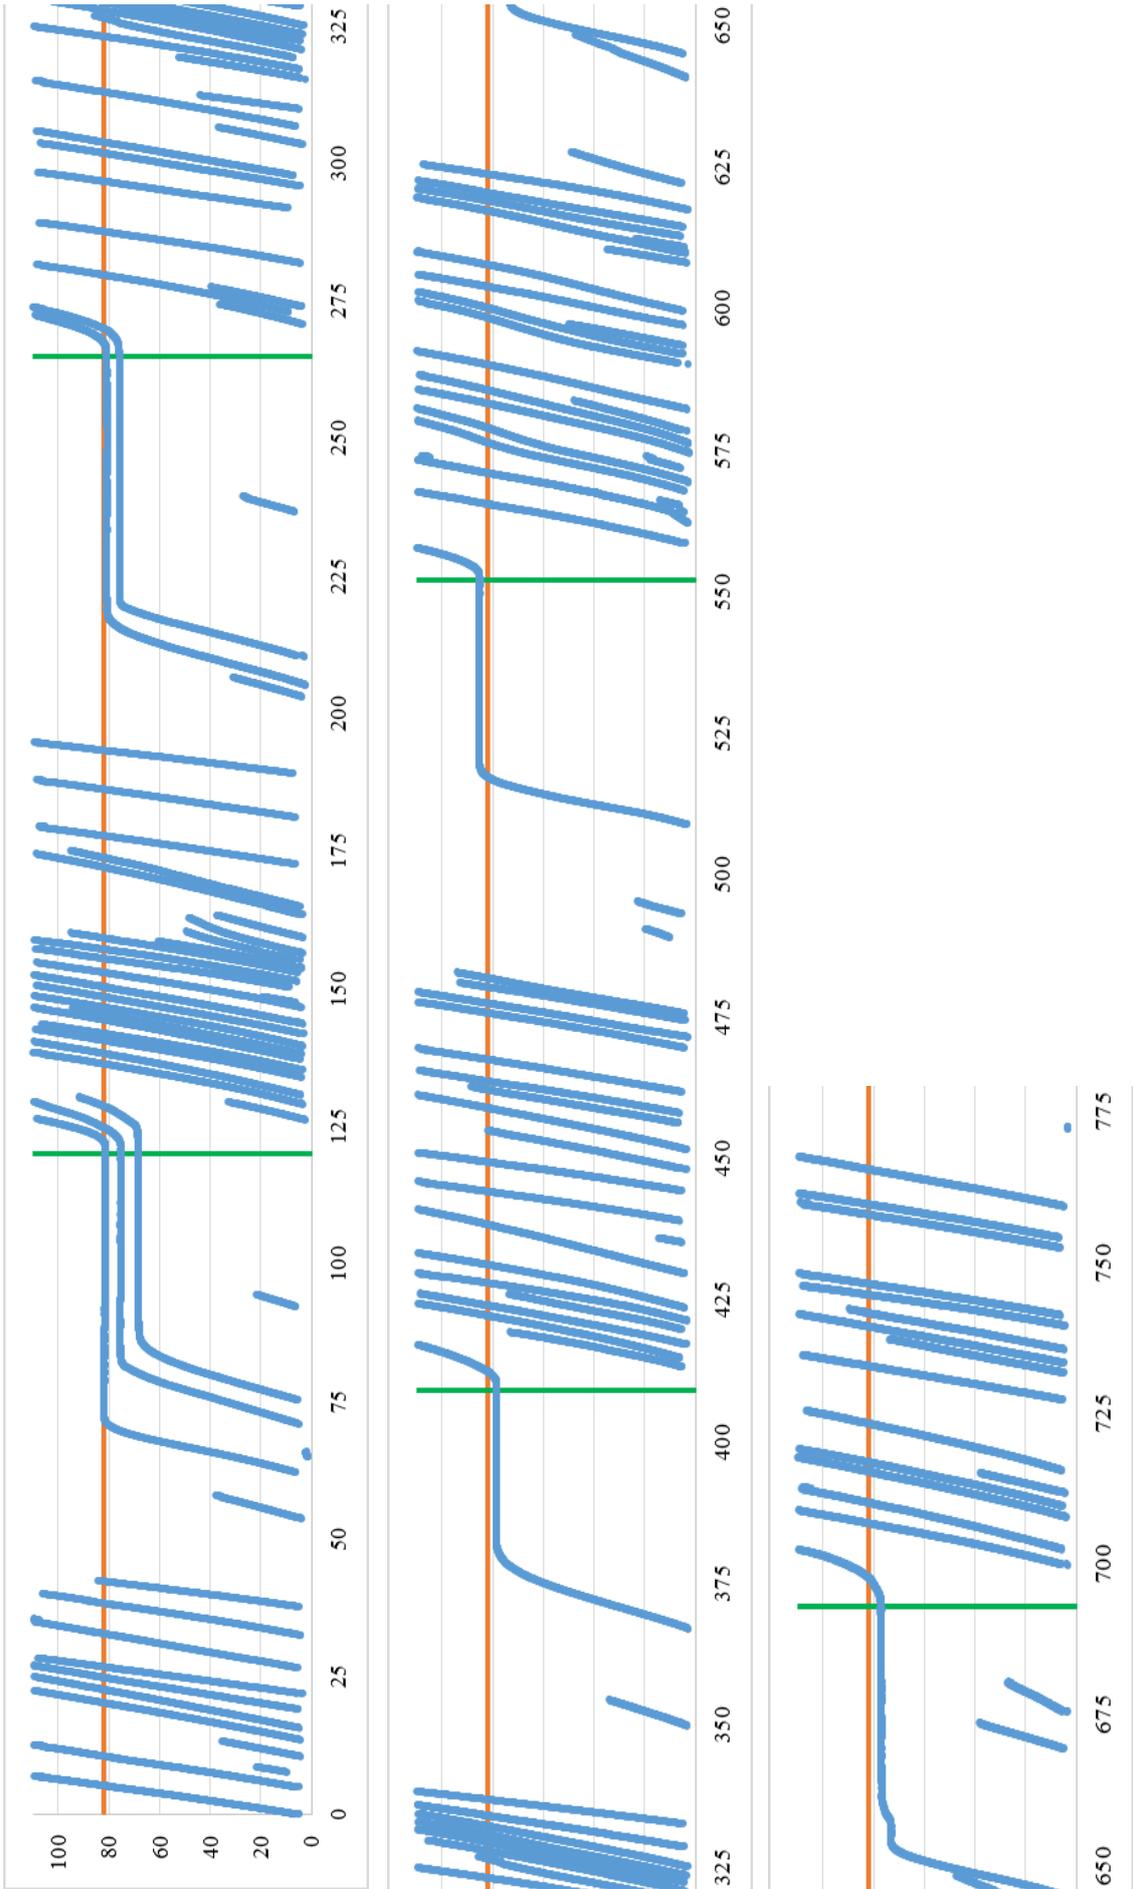


Figura A.6 - Diagrama espaço-tempo do Vídeo 06

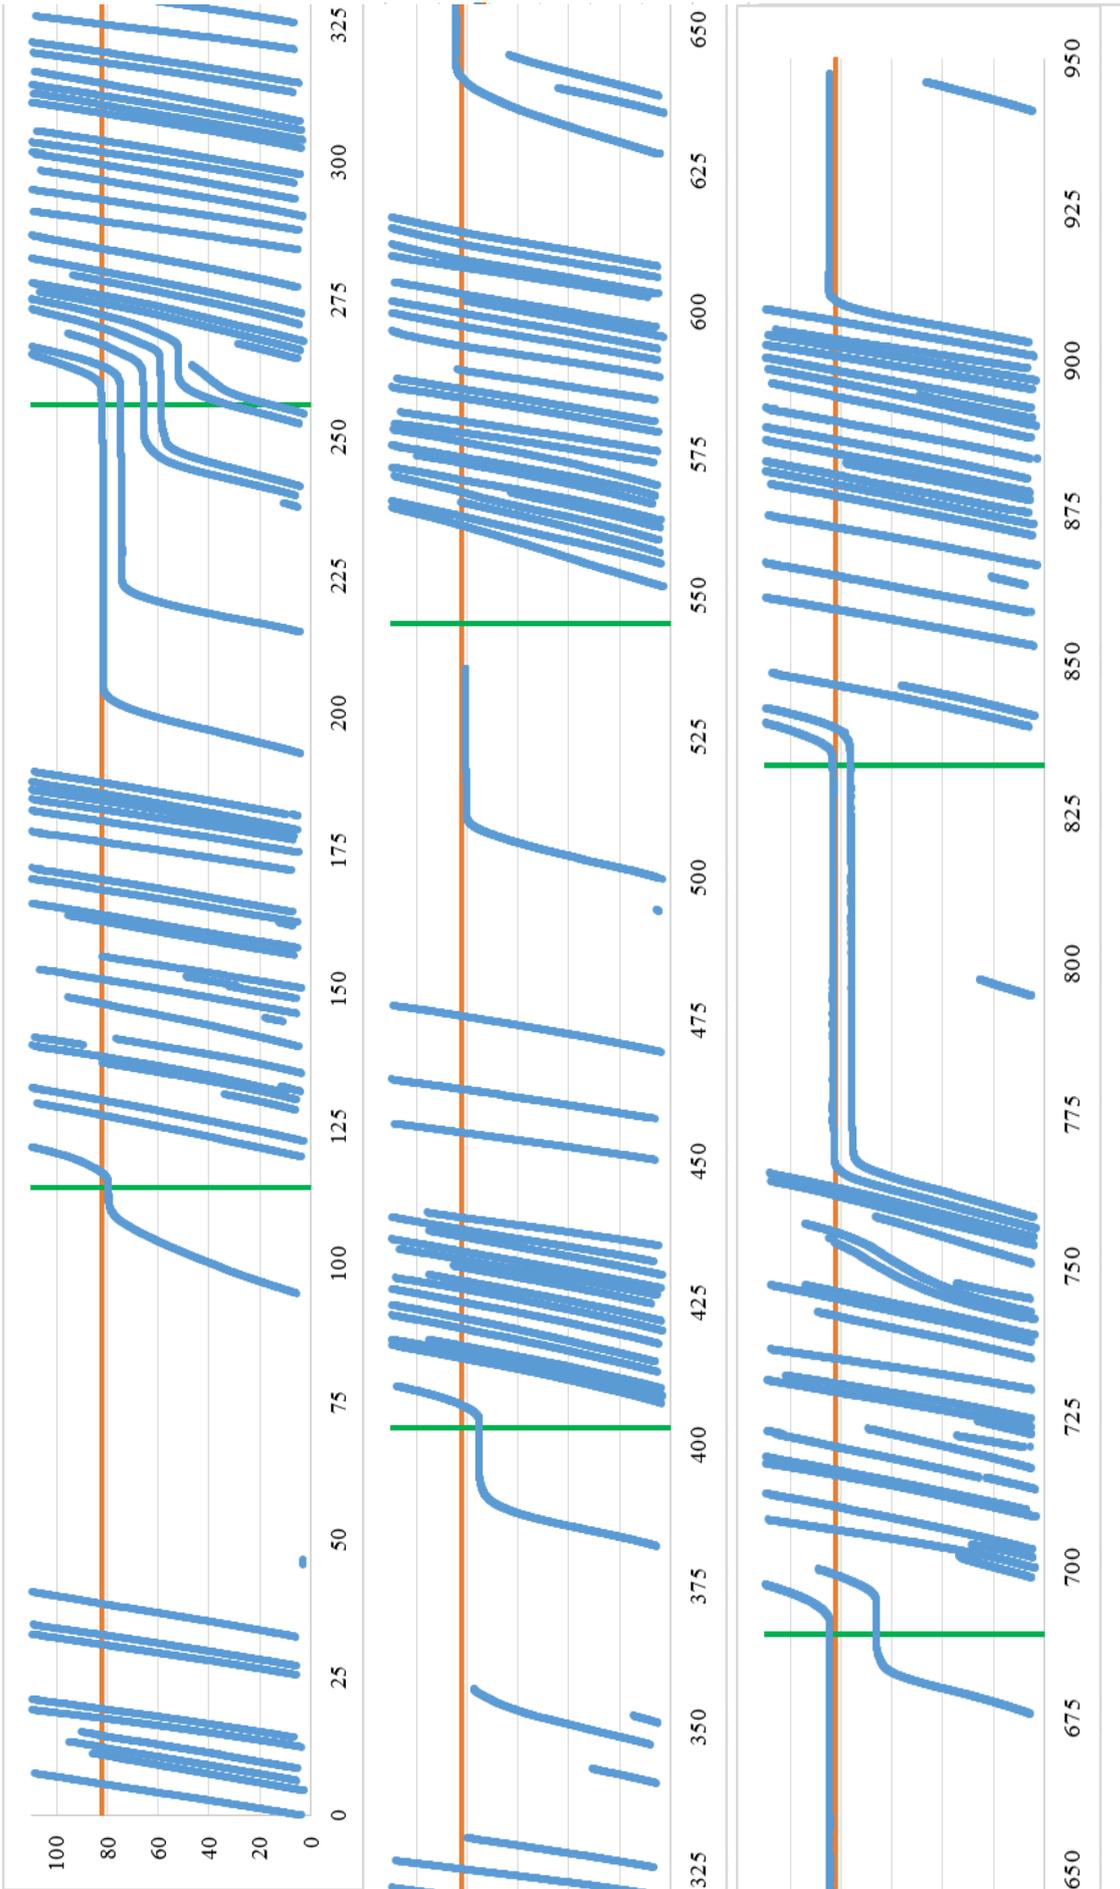


Figura A.7 - Diagrama espaço-tempo do Vídeo 07

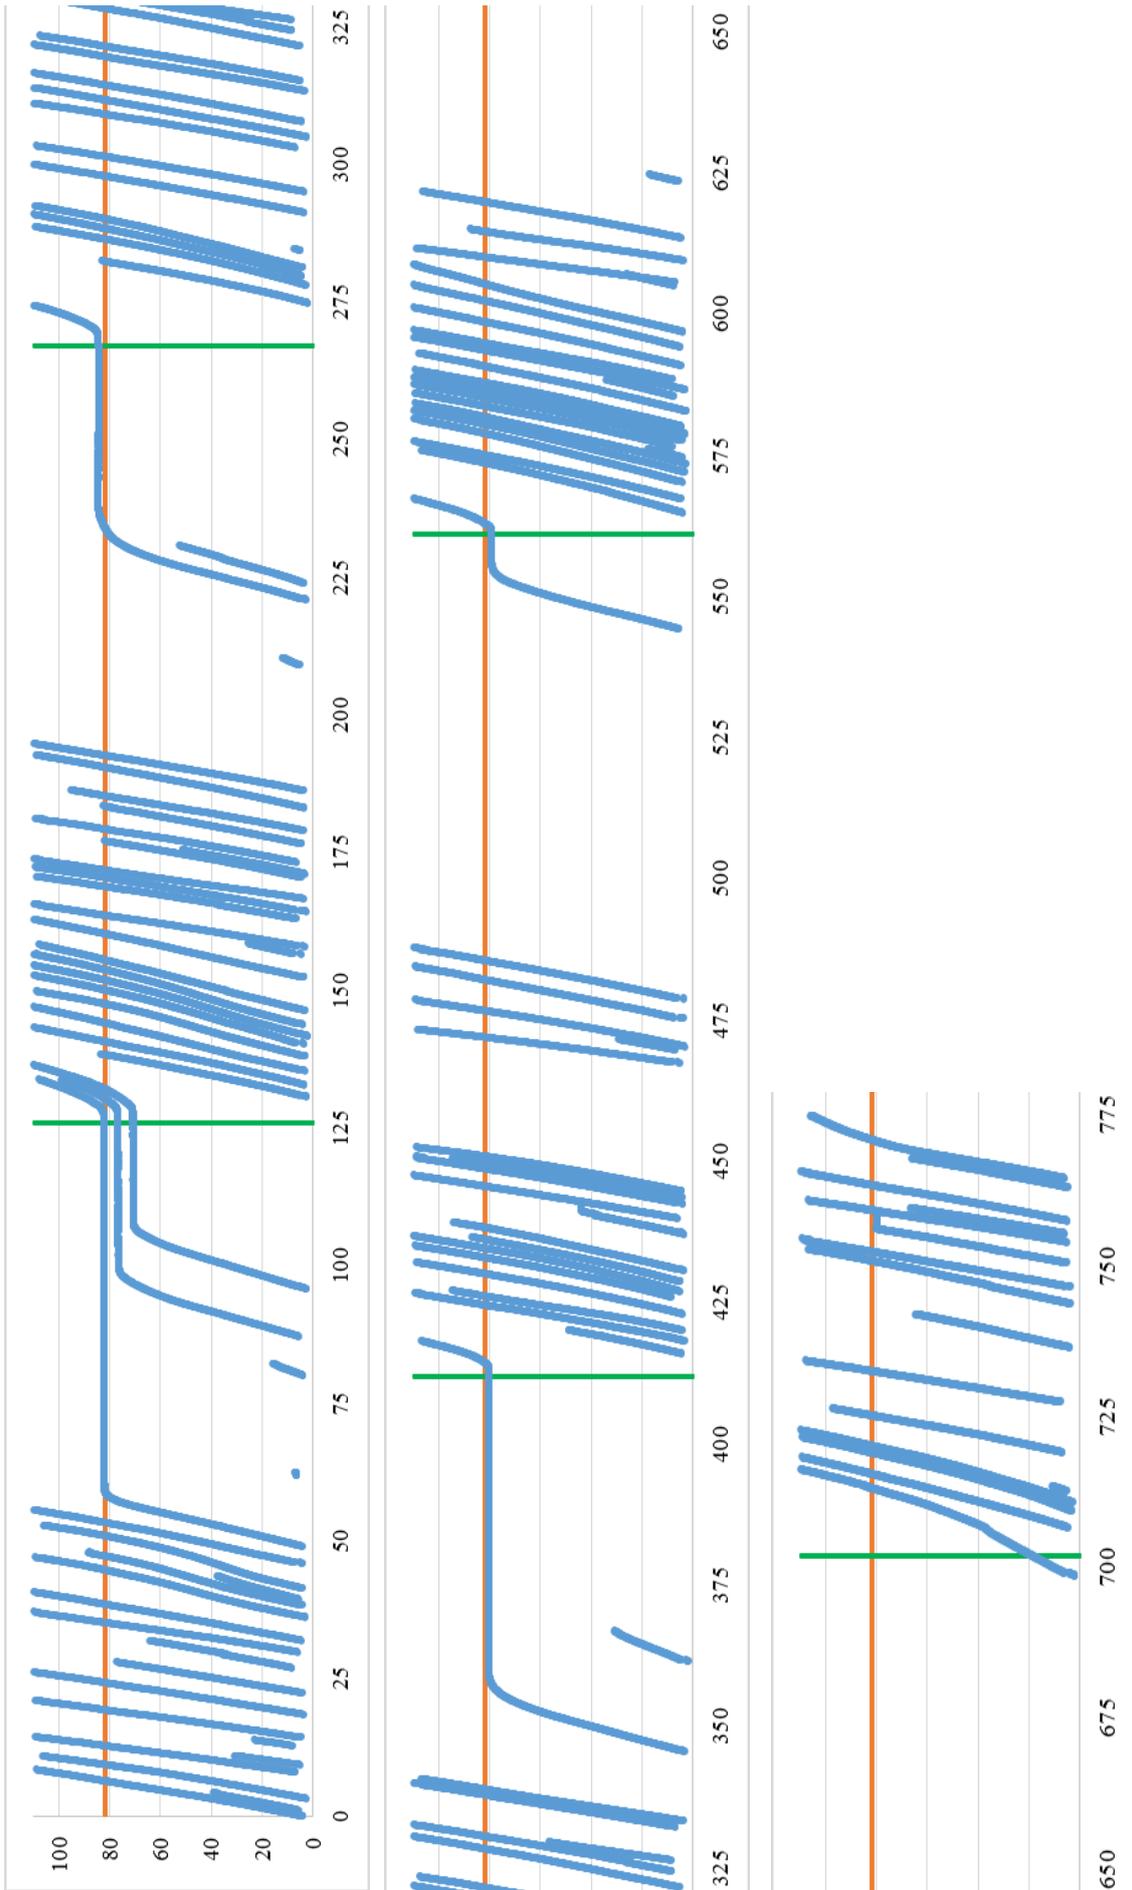


Figura A.8 - Diagrama espaço-tempo do Vídeo 08

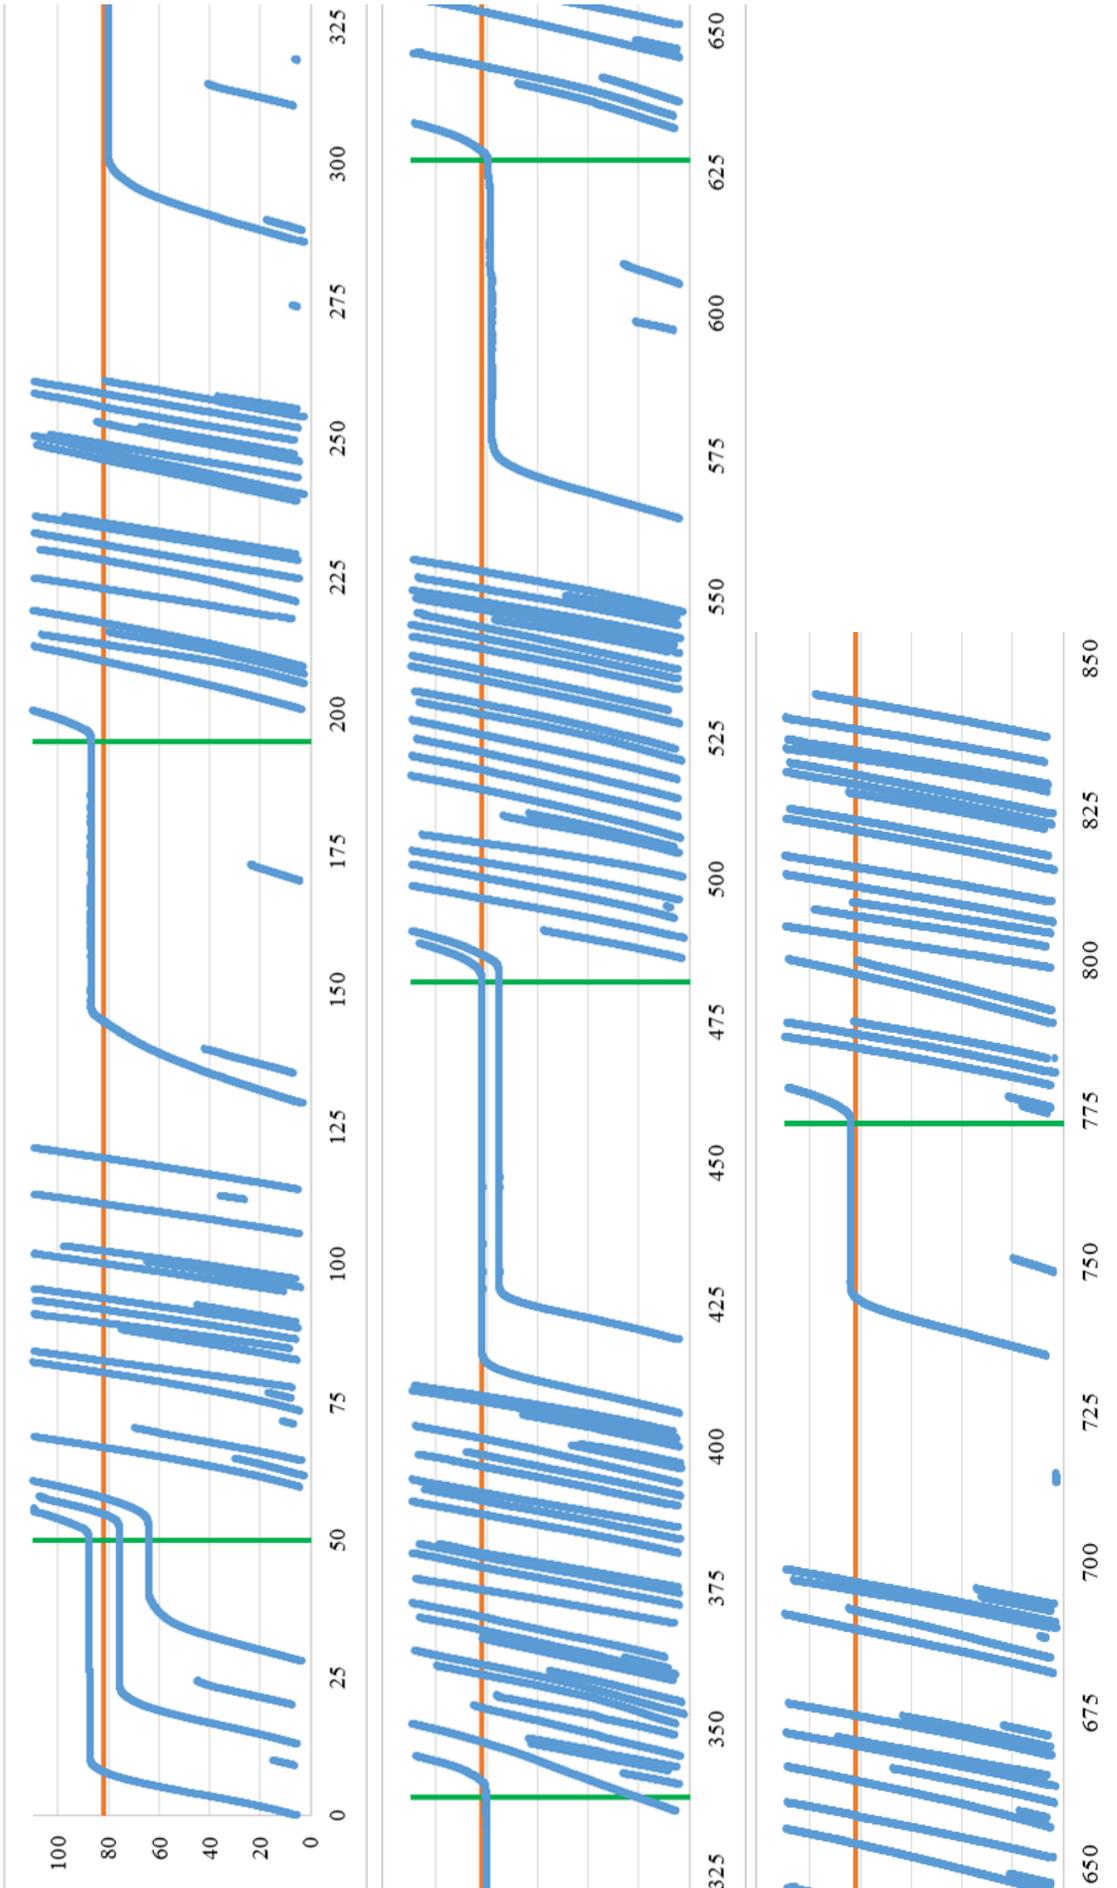


Figura A.9 - Diagrama espaço-tempo do Vídeo 09

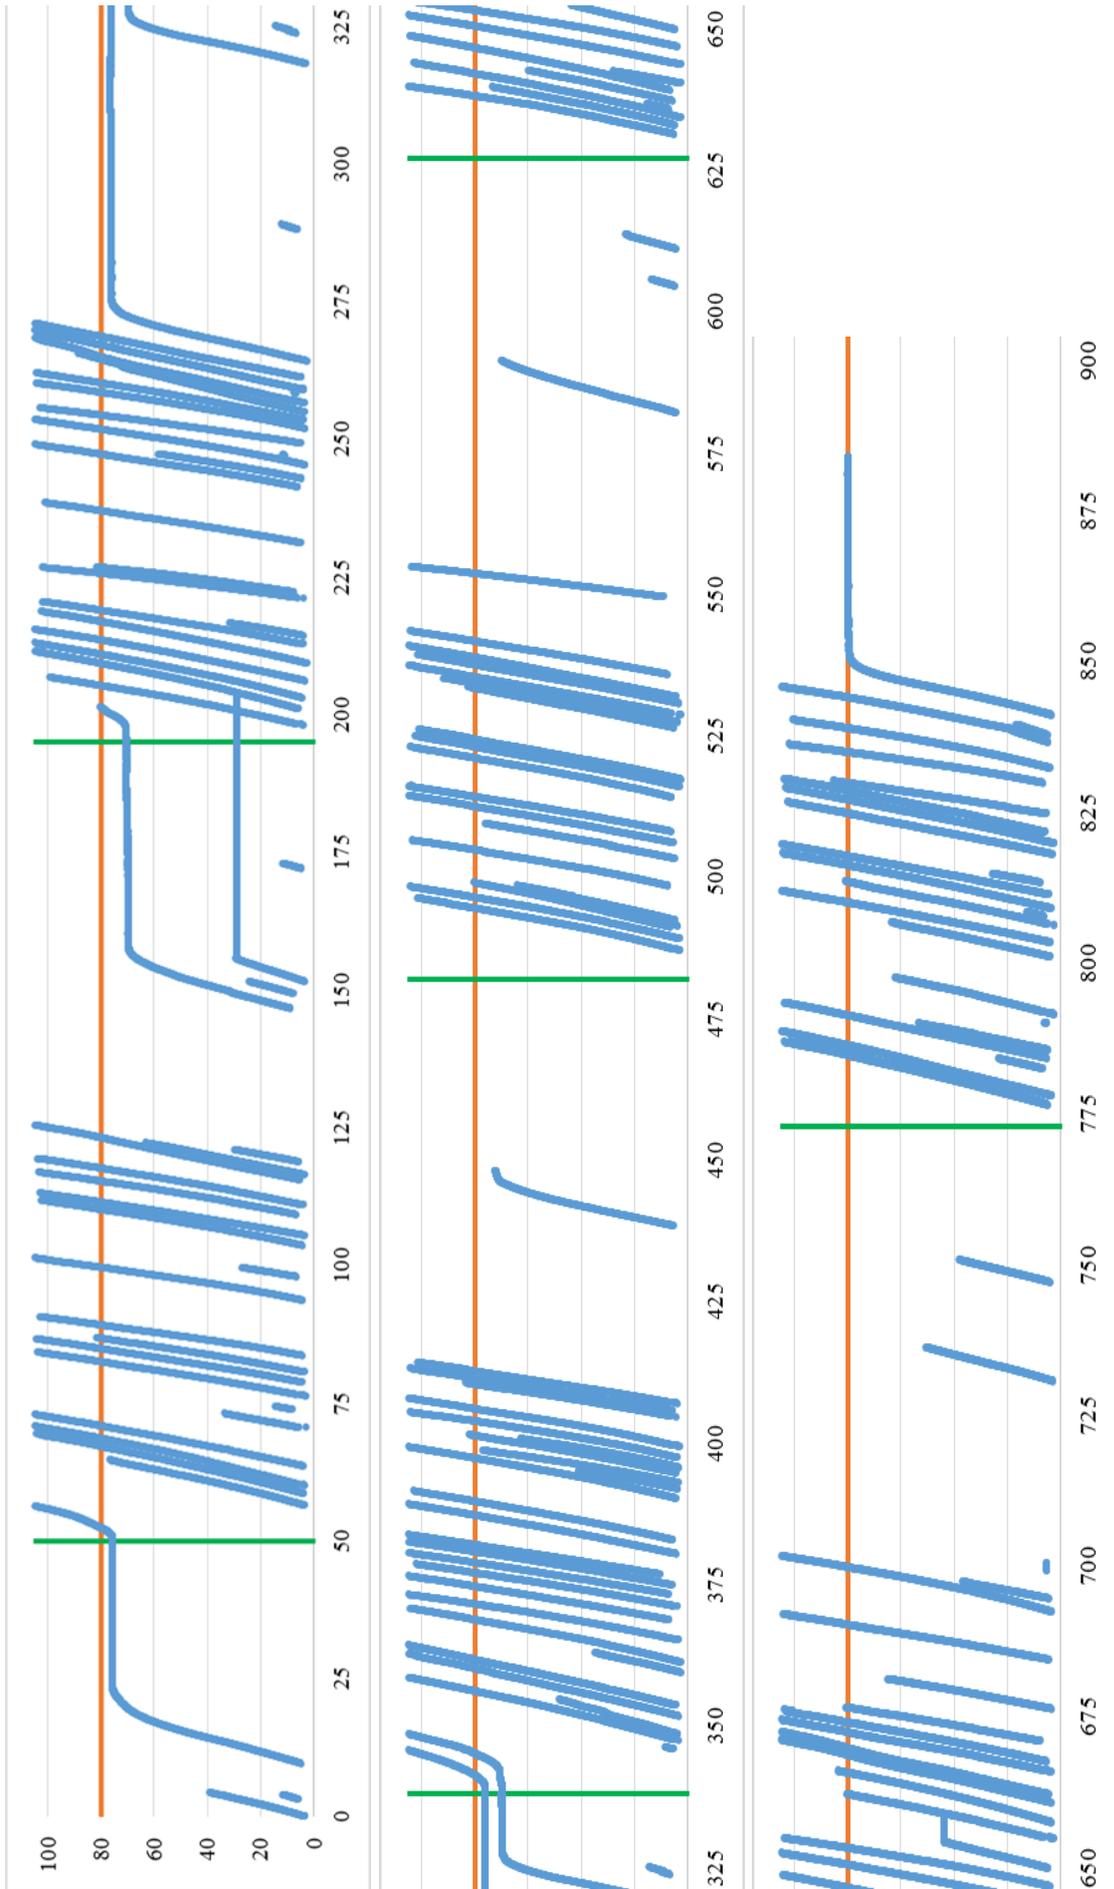


Figura A.10 - Diagrama espaço-tempo do Vídeo 10

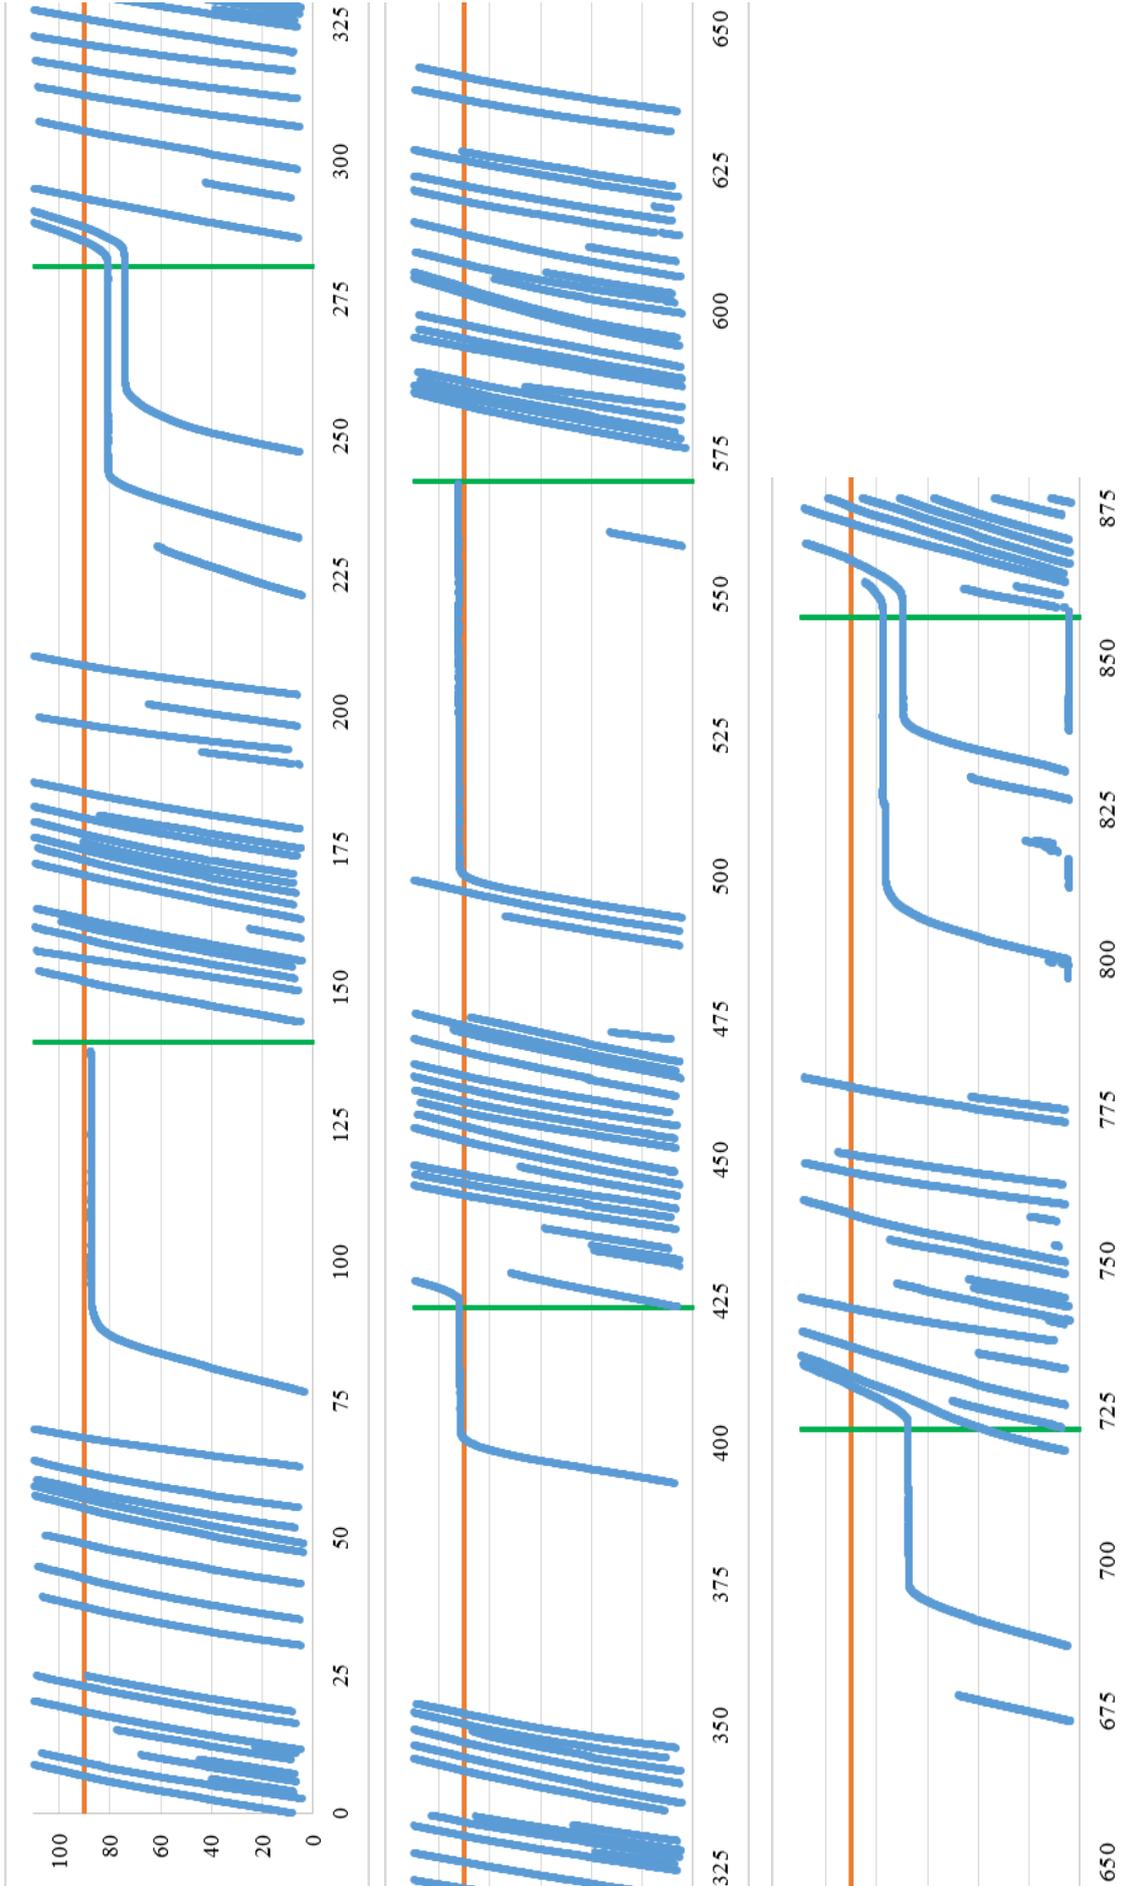


Figura A.11 - Diagrama espaço-tempo do Vídeo 11

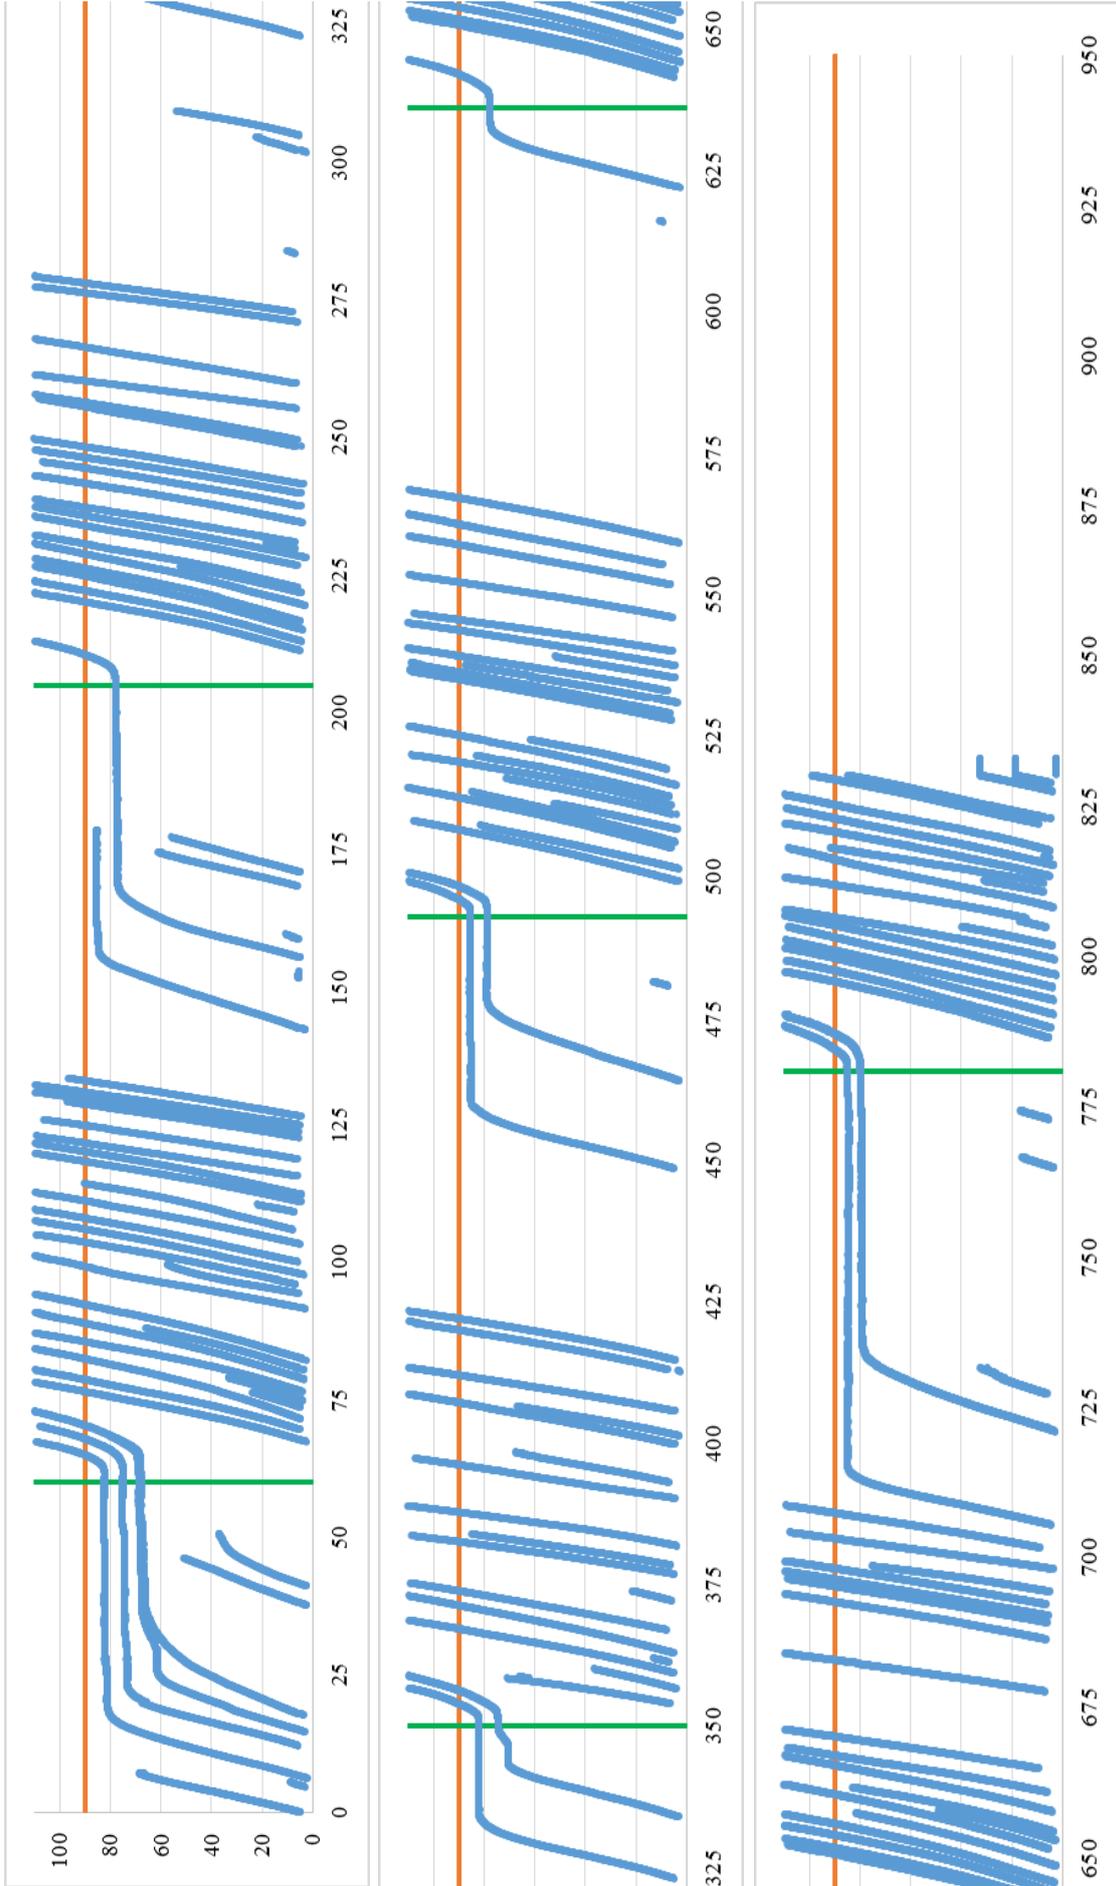


Figura A.12 - Diagrama espaço-tempo do Vídeo 12

