



**Politécnico  
de Viseu**

Escola Superior  
de Tecnologia  
e Gestão de Viseu

# **Calibração microscópica do modelo de car-following Intelligent Driver Model (IDM) recorrendo a veículo instrumentado**

Gean Kenid Sifronio Franco

## **Dissertação**

Mestrado em Engenharia de Construção e Reabilitação

Trabalho efetuado sob a orientação de  
Professor Doutor António Luís Pimentel Vasconcelos  
Professor Doutor Fernando Luiz Martinechen Beghetto

Julho de 2022



**Politécnico  
de Viseu**

Escola Superior  
de Tecnologia  
e Gestão de Viseu

# **Calibração microscópica do modelo de car-following Intelligent Driver Model (IDM) recorrendo a veículo instrumentado**

Gean Kenid Sifronio Franco

## **Dissertação**

Mestrado em Engenharia de Construção e Reabilitação

Trabalho efetuado sob a orientação de

Professor Doutor António Luís Pimentel Vasconcelos  
Professor Doutor Fernando Luiz Martinechen Beghetto

Julho de 2022

## AGRADECIMENTOS

Expresso em primeiro, agradecimento a toda minha família, por sempre me apoiar e me dar suporte. Em especial aos meus pais, Marcia e Geovani, por me permitir e me incentivar em minha jornada profissional.

Ao Professor Doutor António Luís Pimentel Vasconcelos, pela orientação nesse trabalho, que desde a definição do tema até às reuniões para explicar, com calma, pontos que eu não compreendia, sempre apresentou resiliência e experiência, que me fizeram aprender muito, não somente sobre engenharia de tráfego, mas também sobre profissionalismo e parceria. Ao Professor Doutor Fernando Luiz Martinechen Beghetto, pela coorientação, que talvez possa dizer que se iniciou no meu primeiro contato com a engenharia de Tráfego no DER-PR, e sempre foi muito atencioso e profissional.

Aos mentores que tive durante a vida e naturalmente nortearam minhas decisões: Professora Nair, ainda no Ensino Básico; Professora Doutora Albéria, no Ensino Médio; Professor Doutor Arthur, na Graduação em Engenharia Civil; Engenheiro Anderson, no estágio no DER-PR; e ao Professor Doutor Vasconcelos, no Mestrado.

As pessoas que passaram pelo meu caminho e pelas quais troquei experiências, sejam risadas, conversar, desabafos e que de alguma forma, me fizeram me sentir bem. Aos jauruenses (Andressa e Deivid), que juntos ao tereré compartilhamos todos os sonhos. Aos do IFMT (Kamila, Lindi, Paulo, Rivaldo, Roberto e Vitória) que me ajudaram a entender quem sou e formar as opiniões que tenho. Aos da UTFPR e Curitiba (André, Gabriele, Karen, Lucas, Nicoli e Sergio), por toda a partilha acadêmica e de vida. Aos do IPV e Portugal (República Watermelon), que compartilharam um momento de intenso aprendizado e me ajudaram a vencer a pandemia da Covid-19. Amigos que levarei para toda vida.

As instituições que tive a sorte de integrar e me fizeram hoje, sentir preparado para o mercado e para a vida: Instituto Federal do Mato Grosso; Universidade Tecnológica Federal do Paraná; e Instituto Politécnico de Viseu.

E agradecimento especial ao Instituto Politécnico de Viseu pelo suporte a este trabalho, através do programa de Apoios Especiais, projeto SAFEWAY – passadeiras seguras e eficientes para cidades sustentáveis.



## RESUMO

São inúmeras as aplicações dos modelos de microsimulação de tráfego, desde a otimização de operações com o objetivo de maximizar a capacidade da infraestrutura existente à procura de soluções que conduzam à redução da sinistralidade rodoviária.

Porém, a utilização dessas análises requer alto nível de especialização, são dispendiosas e o processo de obtenção dos parâmetros pode não ser simples, nem replicável para locais diferentes, uma vez que ainda não há metodologias consolidadas e os parâmetros variam de população para população.

O modelo de *car-following* é um dos principais componentes dos modelos de microsimulação. A calibração dos respetivos parâmetros é essencial para atingir resultados precisos, mas sendo uma tarefa complexa e dispendiosa, os analistas recorrem frequentemente a valores pré-definidos ou a técnicas de calibração simples que oferecem reduzida transferibilidade.

A presente dissertação teve como objeto a calibração microscópica do modelo de *car-following* Intelligent Driver Model (IDM). Para isso, foi realizada uma coleta de dados através de um veículo instrumentado, que permitiu analisar o comportamento de cinco condutores, alunos e professores, do Instituto Politécnico de Viseu, Portugal. O procedimento é relativamente simples e de baixo custo, necessitando apenas de um *datallogger* e uma pistola LIDAR.

O processo de calibração se deu através de duas metodologias. A primeira por estimativa individual dos parâmetros, na qual foram separadas seções da coleta de dados onde cada parâmetro tinha maior influência que os demais, e a segunda, por otimização simultânea dos parâmetros.

Os distintos processos de calibração executados nesse estudo mostraram desempenhos satisfatórios, e passíveis de serem replicados. Um desempenho ligeiramente melhor foi notado na calibração por otimização simultânea.

**Palavras-chave:** calibração microscópica, Intelligent Driver Model, microsimulação de tráfego, veículo instrumentado.



## ABSTRACT

There are numerous applications of traffic microsimulation models, from the optimization of operations with the objective of maximizing the capacity of the existing infrastructure to the search for solutions that lead to the reduction of road accidents.

However, the use of these analyzes requires a high level of specialization, they are expensive and the process of obtaining the parameters may not be simple, nor replicable for different locations, since there are still no consolidated methodologies and the parameters vary from population to population.

The car-following model is one of the main components of microsimulation models. The calibration of the respective parameters is essential to achieve accurate results, but being a complex and expensive task, analysts often resort to pre-defined values or simple calibration techniques that offer little transferability.

The present dissertation had as its object the microscopic calibration of the car-following Intelligent Driver Model (IDM). For this, a data collection was carried out through an instrumented vehicle, which allowed the analysis of the behavior of five drivers, students and teachers, from the Instituto Politécnico de Viseu, Portugal. The procedure is relatively simple and inexpensive, requiring only a datalogger and a LIDAR rangefinder.

The calibration process took place through two methodologies. The first by individual parameter estimation, in which sections of the data collection were separated where each parameter had greater influence than the others, and the second, by simultaneous optimization of the parameters.

The different calibration processes performed in this study showed satisfactory performance, and likely to be replicated. Slightly better performance was noted in the simultaneous optimization calibration.

**Keywords:** microscopic calibration, Intelligent Driver Model, traffic microsimulation, instrumented vehicle.



# ÍNDICE GERAL

<b>1. INTRODUÇÃO .....</b>	<b>1</b>
1.1 Enquadramento geral e justificativo .....	1
1.2 Objetivos e metodologia geral .....	2
1.3 Organização e estrutura do trabalho .....	3
<b>2. MODELOS <i>CAR-FOLLOWING</i> DE SIMULAÇÃO MICROSCÓPICA DE TRÁFEGO .....</b>	<b>5</b>
2.1 Introdução .....	5
2.2 Histórico de modelos .....	7
2.2.1 Pipes .....	7
2.2.2 Gazis, Herman e Rothery e a teoria resposta-estímulo.....	7
2.2.3 Wiedemann e os modelos psicofísicos .....	9
2.2.4 Gipps.....	11
<b>3. INTELLIGENT DRIVER MODEL (IDM) .....</b>	<b>17</b>
3.1 Introdução .....	17
3.2 Premissas .....	18
3.3 Descrição matemática .....	18
3.4 Regime estacionário.....	20
3.5 Aceleração em fluxo livre.....	21
3.6 Estratégia de frenagem autorreguladora .....	22
<b>4. COLETA DE DADOS.....</b>	<b>25</b>
4.1 Objetivos.....	25
4.2 Instrumentação.....	26
4.3 Percurso .....	27
4.4 Seleção dos dados .....	29
4.5 Conclusão.....	31

## ÍNDICE GERAL

<b>5. CALIBRAÇÃO .....</b>	<b>32</b>
5.1 Metodologia.....	32
5.1.1 Aspectos gerais .....	32
5.1.2 Indicadores de desempenho .....	34
5.1.3 Metodologias de otimização .....	36
5.2 Estimativa individual dos parâmetros .....	37
5.2.1 Regime estacionário .....	37
5.2.2 Aceleração a partir do repouso.....	39
5.2.3 Desaceleração até o repouso .....	42
5.2.4 Resultados .....	44
5.3 Otimização simultânea .....	45
5.3.1 Domínio de otimização .....	45
5.3.2 Resultados .....	46
5.4 Validação.....	48
5.4.1 Validação entre trechos distintos .....	48
5.4.2 Validação com valores médios .....	50
<b>6. CONCLUSÕES GERAIS E TRABALHOS FUTUROS.....</b>	<b>52</b>
6.1 Síntese e conclusões gerais.....	52
6.2 Desenvolvimentos futuros.....	54
<b>REFERÊNCIAS.....</b>	<b>55</b>

## ÍNDICE DE FIGURAS

<b>Figura 2.1</b> - Em (a) gráfico velocidade (milhas/hora) - Fluxo (Veículos/hora), em (b) máquina fotográfica em operação e em (c) gráfico Velocidade (milhas/hora) - Densidade (Veículos/hora) adaptado de Greenshields et al. (1935).....	6
<b>Figura 2.2</b> - Variação de velocidade e desaceleração de cinco veículos consecutivos, modeladas por Pipes para $T=1s$ adaptado de Pipes (1953) .....	7
<b>Figura 2.3</b> - Velocidade x Afastamento representativa (Newell, 1961) .....	8
<b>Figura 2.4</b> - Fluxo $q$ (carros/hora) x Densidade $k$ (carros/milha)(Edie, 1961).....	9
<b>Figura 2.5</b> - Representação dos regimes do modelo de Wiedemann.....	10
<b>Figura 2.6</b> - Exemplo de representação 3D da aplicação VISSIM (Barceló, 2010).....	11
<b>Figura 2.7</b> – Fluxo x Velocidade em rodovia simulados por Gipps no MULTSIM (Gipps, 1981) .....	13
<b>Figura 2.8</b> - Tempo (s) x Velocidade (m/s) de sete veículos em seguimento com parâmetro $dn - 1'$ superestimado (Gipps, 1981) .....	14
<b>Figura 2.9</b> - Tempo (s) x Velocidade (m/s) de sete veículos em seguimento com parâmetro $dn - 1'$ subestimado (Gipps, 1981) .....	14
<b>Figura 2.10</b> – Ajustamento das curvas $q-v$ e $q-k$ aos dados de campo (autoestrada A44, Portugal): $v_d = 89$ km/h, $S = 8.5$ m, caso 1: $d = d' = 3$ m/s <sup>2</sup> , $\tau = 1.0$ s; caso 2: $d = 3$ m/s <sup>2</sup> , $d' = 3.6$ m/s <sup>2</sup> , $\tau = 0.6$ s; $\theta = \tau/2$ (L. Vasconcelos et al., 2014).....	15
<b>Figura 2.11</b> - Exemplo de interseção na aplicação AIMSUN (AIMSUN, 2022).....	15
<b>Figura 3.1</b> - Simulação de aceleração em fluxo livre, com $\delta = 4$ para o caso da esquerda e $\delta = 1$ para o caso da direita, demais parâmetros fixados em: $v_0=50$ km/h; $a = 2$ m/s <sup>2</sup> ; $b = 3$ m/s <sup>2</sup> ; $T = 2$ s; $s_0 = 2$ m .....	22
<b>Figura 3.2</b> - Aceleração x Tempo (s) para parada repentina em vermelho semaforico ( $s = 60$ m e $v = 54$ km/h), $b$ variável e demais parâmetros fixos, sendo $s_0 = 0.1$ m, $T = 1$ s, $a = 0,5$ m/s <sup>2</sup> e $\delta =$ .....	23
<b>Figura 4.1</b> - Instrumentalização: em (a) coleta em funcionamento, em (b) <i>datallogger</i> e em (c) LIDAR .....	26
<b>Figura 4.2</b> - Interface da aplicação Race Technology, no canto superior esquerdo mapa com trecho selecionado, na parte inferior gráficos de aceleração e velocidade – tempo (notar a necessidade de pós-processamento para correção das acelerações) .....	27
<b>Figura 4.3</b> - Trajeto da coleta de dados .....	28
<b>Figura 4.4</b> - Vias do trajeto, de cima para baixo, da esquerda para direita: Avenida Regimento de Infantaria N° 14; Avenida 25 de Abril; Avenida Alberto Sampaio; Avenida Monsenhor Cónego António Freire (circunvalação); e Avenida Cidade de Salamanca (Google Maps) ....	29
<b>Figura 4.5</b> - Remoção de "picos" nos dados do LIDAR.....	30
<b>Figura 4.6</b> - Exemplo de dados LIDAR descartados.....	30

## ÍNDICE DE FIGURAS

<b>Figura 5.1</b> - Exemplo de diferentes comportamentos de função objetivos (Treiber & Kesting, 2013) .....	34
<b>Figura 5.2</b> - Exemplo de seleção de trecho em regime estacionário, acima o gráfico de velocidade ( $m/s^2$ ) x tempo (s) e abaixo o gráfico de afastamento (m) x tempo (s).....	37
<b>Figura 5.3</b> - Gráficos de afastamento (m) x tempo (s) em regime estacionário.....	38
<b>Figura 5.4</b> - Gráficos de uma aceleração a partir do repouso .....	39
<b>Figura 5.5</b> - Exemplo de simulação com veículo de transmissão manual (acima) e automática (abaixo) .....	41
<b>Figura 5.6</b> - Gráficos de uma desaceleração até o repouso.....	42
<b>Figura 5.7</b> - Independência dos parâmetros a velocidade (estimativa individual).....	45
<b>Figura 5.8</b> - Gráfico tempo - velocidade de um dos trechos de otimização simultânea dos parâmetros.....	46
<b>Figura 5.9</b> - Independência dos parâmetros a velocidade (otimização simultânea) .....	48
<b>Figura 5.10</b> - Replicabilidade dos parâmetros calibrados para o condutor 2.....	51
<b>Figura 5.11</b> - Replicabilidade dos parâmetros calibrados para o condutor 5.....	51

## ÍNDICE DE TABELAS

<b>Tabela 4.1</b> - Dados coletados.....	31
<b>Tabela 5.1</b> - Regime estacionário .....	38
<b>Tabela 5.2</b> - Estimativa individual dos parâmetros $a$ e $\delta$ .....	40
<b>Tabela 5.3</b> - Resumo da estimativa individual dos parâmetros $a$ e $\delta$ .....	41
<b>Tabela 5.4</b> - Estimativa individual do parâmetro $b$ .....	43
<b>Tabela 5.5</b> - Resumo da estimativa individual do parâmetro $b$ .....	44
<b>Tabela 5.6</b> – Estimativas individuais .....	44
<b>Tabela 5.7</b> - Domínio de otimização .....	46
<b>Tabela 5.8</b> - Otimização simultânea dos parâmetros .....	47
<b>Tabela 5.9</b> - Resumo da otimização simultânea dos parâmetros .....	47
<b>Tabela 5.10</b> - RMSe para replicabilidade dos parâmetros calibrados do condutor 1 em diferentes circuitos.....	49
<b>Tabela 5.11</b> - RMSe para replicabilidade dos parâmetros calibrados do condutor 2 em diferentes circuitos.....	49
<b>Tabela 5.12</b> - RMSe para replicabilidade dos parâmetros calibrados do condutor 3 em diferentes circuitos.....	49
<b>Tabela 5.13</b> - RMSe para replicabilidade dos parâmetros calibrados do condutor 4 em diferentes circuitos.....	49
<b>Tabela 5.14</b> - RMSe para replicabilidade dos parâmetros calibrados do condutor 5 em diferentes circuitos.....	50
<b>Tabela 5.15</b> - Replicabilidade dos parâmetros calibrados .....	50



# 1. Introdução

## 1.1 Enquadramento geral e justificativo

A simulação de tráfego consiste em artificialmente criar um cenário capaz de representar uma determinada realidade, tornando possível analisar diferentes soluções alternativas para problemas de gestão de tráfego, como por exemplo, simular diferentes tempo de verde em semáforos para um determinado fluxo de veículos. Vários aspectos da simulação devem ser levantados previamente para alimentar a simulação. No exemplo, seriam necessários, dentre outros parâmetros, o fluxo de saturação de veículos na via que se pretende analisar, o tempo de reação dos condutores e até mesmo a largura da faixa de rodagem.

Em alguns problemas clássicos, como é caso da avaliação do nível de serviço em interseções, é possível quantificar os parâmetros a partir de tabelas ou modelos analíticos simples. Porém, para modelos de simulação que descrevem aspetos comportamentais dos condutores, individuais pela sua natureza, ainda há uma certa dificuldade na obtenção dos parâmetros.

Há muitas possibilidades de representar o tráfego rodoviário. Os modelos macroscópicos se destinam a análises com valores agregados, como o fluxo de tráfego e a densidade, enquanto os modelos microscópicos permitem análises que consideram a individualidade de cada veículo.

Os modelos microscópicos de simulação são divididos pelos fenômenos que permitem descrever, como a espera e decisão para entrada em uma interseção (*gap-acceptance*), a mudança de faixa (*lane-changing*), e o seguimento de veículos consecutivos (*car-following*), sendo este

último o objeto desta dissertação. Juntos, compõem importantes aplicações informáticas destinadas a análises do gênero, como o AIMSUN, MITSIM e VISSIM.

São inúmeras as aplicações dos modelos de microsimulação de tráfego, desde a otimização de operações com o objetivo de maximizar a capacidade da infraestrutura existente à procura de soluções que conduzam à redução da sinistralidade rodoviária.

Por ano, cerca de 1,3 milhão de mortes evitáveis em acidentes de trânsito ocorrem no mundo, sendo essa a principal causa de morte de crianças e jovens (WHO, 2021). Estudos registram o fator humano como principal causador dessas mortes (Treat et al., 1979; Ansari et al., 2000; Prentkovskis et al., 2010; Touahmia, 2018; Wangdi et al., 2018)

A Organização Mundial da Saúde (WHO, 2021), propõe uma série de recomendações com intuito de reduzir em 50% as mortes e ferimentos causadas por acidentes de trânsito, entre elas: frenagem de emergência avançada em veículos para reduzir colisões e sistemas inteligentes de assistência à velocidade.

Os parâmetros microscópicos de tráfego, e especificamente dos modelos de *car-following*, são dados de entrada na operação de sistemas de assistência, como os programas eletrônicos de estabilidade (ESP) e o *adaptive cruise control* (ACC)(Treiber & Kesting, 2013), que promovem um aumento do conforto e segurança para motoristas (Zhang et al., 2012; Kyriakidis et al., 2015).

## 1.2 Objetivos e metodologia geral

Como referido, os modelos de *car-following* descrevem o movimento longitudinal dos veículos e são uma das principais componentes dos modelos de microsimulação e de assistência à condução. Uma vez que estes modelos procuram replicar o comportamento de condutores individuais, a sua formulação tipicamente inclui um conjunto alargado de parâmetros ajustáveis. A calibração destes parâmetros é essencial para atingir resultados precisos, mas sendo uma tarefa complexa e dispendiosa, os analistas recorrem frequentemente a parâmetros pré-definidos ou a técnicas de calibração simples que oferecem reduzida transferibilidade.

Assim, o objetivo desse trabalho é criar e analisar as alternativas para calibrar e validar um modelo *car-following*, nomeadamente o Intelligent Driver Model (IDM). Sendo mais específico, pretende-se:

- Enquadrar o Intelligent Driver Model (IDM) na família de modelos de seguimento;

- Compreender as propriedades e o funcionamento do IDM;
- Aplicar método de baixo custo para coleta de dados de seguimento de carro;
- Calibrar parâmetros individualmente, levando em consideração suas representações físicas;
- Calibrar parâmetros por otimização global com dados de seguimento;
- Validar calibrações;
- Comparar calibrações e replicabilidade.

### **1.3 Organização e estrutura do trabalho**

O trabalho é organizado em cinco capítulos, sendo:

Capítulo 1: Introdução à temática, apresentação dos objetivos e definição da estrutura geral do trabalho;

Capítulo 2: Revisão sobre modelos *car-following* em um apanhado histórico e evolutivo sobre o assunto e os aspectos relativos à calibração dessa tipologia de modelo.

Capítulo 3: Apresentação e detalhamento sobre o IDM, importantes considerações e todo equacionamento descrito pelos autores do modelo;

Capítulo 4: Trata dos procedimentos adotados para coleta e seleção de dados, realizada através de veículo instrumentado;

Capítulo 5: Calibração em duas metodologias do modelo IDM, em uma primeira etapa uma calibração individual dos parâmetros e posterior calibração por otimização simultânea dos parâmetros. Apresentação dos procedimentos adotados, resultados obtidos e análises acerca do trabalho;

Capítulo 6: Conclusões gerais sobre o trabalho e indicações de trabalhos futuros.



## 2. Modelos *car-following* de simulação microscópica de tráfego

### 2.1 Introdução

O modelagem de fluxo de tráfego teve início na década de 30, o estadunidense Greenshields (1935) foi um dos pioneiros ao descrever a queda de densidade de tráfego com o aumento da velocidade dos veículos, assim como a relação típica de “ferradura” entre velocidade e fluxo de tráfego, através de metodologia fotográfica (Figura 2.1)

Mais tarde, na década de 50, Reuschel (1950), foi um dos primeiros a publicar estudos relativo a modelos *car-following* e apresentar um método de aproximação matemática e gráfica para descrever a trajetória de veículos em seguimento.

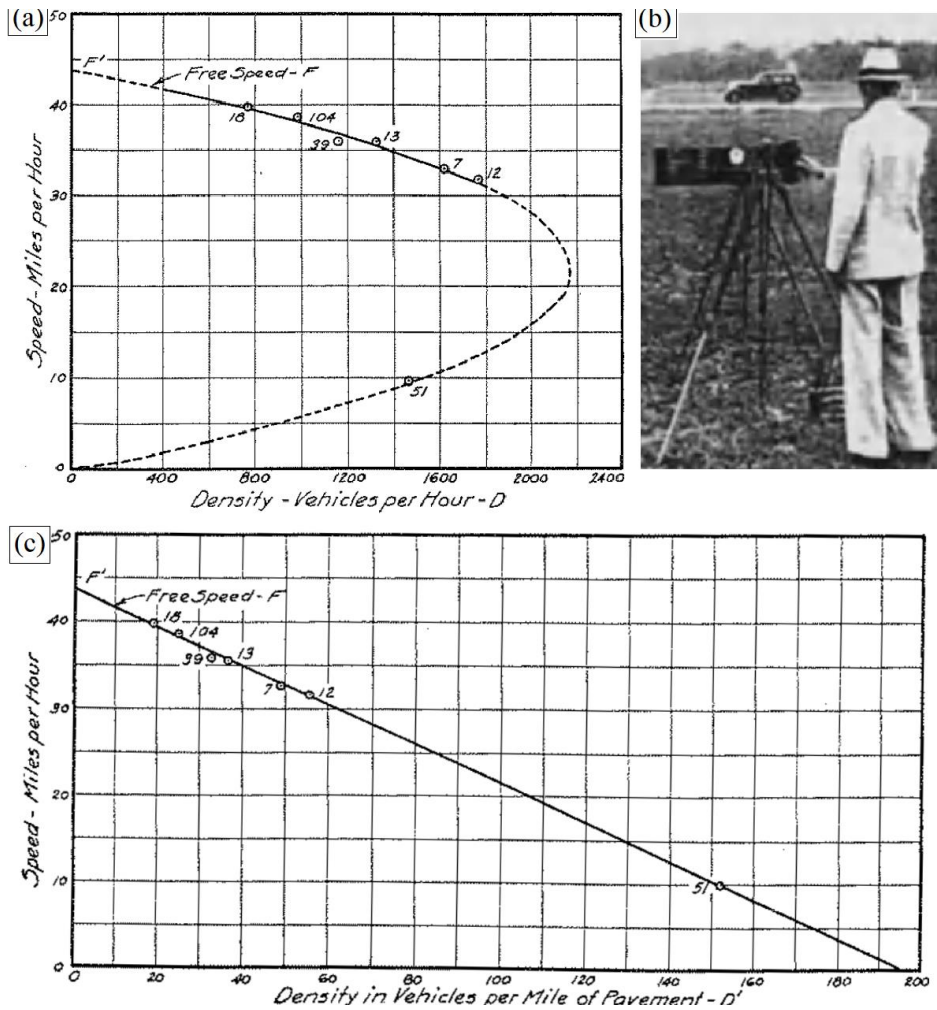
Desde então, muitos modelos *car-following* surgiram (item 2.2), sendo possível classificá-los em três categorias quanto à lógica utilizada como base (Olstam & Tapani, 2004):

- Teoria estímulo-resposta: se utilizam de uma relação proporcional entre um estímulo, ora a diferença de velocidade, ora o afastamento entre veículos, e uma função, denominada por Gazis, Herman e Rothery (1961) como função sensibilidade, para descrever uma reação do veículo seguidor. O item 2.2.2 detalha melhor a lógica.
- Distância segura: baseiam-se em uma distância de segurança entre veículos, proporcional ao acréscimo de velocidade, para evitar a colisão em caso de frenagem

brusca do veículo líder (Vasconcelos, A., 2014). A lógica é base dos modelos descritos nos itens 2.2.1 e 2.2.4.

- Psicofísicos: o condutor seguidor somente reage a estímulos do veículo líder após atingir limites de percepção, aprimorados com a aproximação dos veículos. A lógica é descrita no item 2.2.3.

É consensualmente reconhecida a empregabilidade dos modelos microscópicos na engenharia, porém, certas dificuldades devem ser levadas em conta, a utilização dessas análises requer alto nível de especialização, são dispendiosas e o processo de obtenção dos parâmetros pode não ser simples, nem replicável para locais diferentes, uma vez que ainda não há metodologias consolidadas e os parâmetros variam de população para população (Vasconcelos, A., 2014). O capítulo 5 trata do processo de calibração.



**Figura 2.1** - Em (a) gráfico velocidade (milhas/hora) - Fluxo (Veículos/hora), em (b) máquina fotográfica em operação e em (c) gráfico Velocidade (milhas/hora) - Densidade (Veículos/hora) adaptado de Greenshields et al. (1935)

## 2.2 Histórico de modelos

### 2.2.1 Pipes

Pipes (1953) usou como premissa para as análises o *Califórnia Vehicle Code Summary*, que referia que uma boa distância de segurança a manter do carro da frente era a do comprimento de um carro (quinze pés, ou cerca de, quatro metros e meio) para cada dez milhas por hora (cerca de dezesseis quilômetros por hora), isso porque muitos testes foram realizados e provaram que um segundo era o suficiente para o condutor ver que o veículo da frente freou, tirar o pé direito do acelerador e frear. Essa demora, tratada como fator tempo  $T$ , foi o parâmetro para definir a distância entre veículos e regular do comportamento do seguidor (Figura 2.2).




Figura 2.2 - Variação de velocidade e desaceleração de cinco veículos consecutivos, modeladas por Pipes para  $T=1s$  adaptado de Pipes (1953)

### 2.2.2 Gazis, Herman e Rothery e a teoria resposta-estímulo

Na década de 60, uma outra premissa norteou os estudos ao tratar a condução do veículo seguidor como resposta a um estímulo, ou seja, a aproximação de um veículo a frente, através

de uma função de sensibilidade. A equação (2.1), extraída de Gazis, Herman e Rothery (1961) expressa essa ideia.

$$\text{Resposta} = \text{sensibilidade} \times \text{estimulo} \quad (2.1)$$

Newell (1961) pressupôs a proporcionalidade entre a velocidade (resposta) e a variação do afastamento (estímulo), relacionada a parâmetro pessoais como o espaçamento mínimo e a inclinação da curva velocidade - afastamento quando a velocidade é zero (Figura 2.3).




Figura 2.3 - Velocidade x Afastamento representativa (Newell, 1961)

Gazis, Herman e Rothery (1961) reuniram diversos estudos (Greenshields et al., 1935; Chandler et al., 1958; Herman & Potts, 1959; Gazis et al., 1959; Edie, 1961) e propuseram diferentes funções e parâmetros para cada momento da condução. Como exemplo, a Figura 2.4 mostra um gráfico com diferentes funções sensibilidade para representar o fluxo de veículos no *Lincoln Tunnel* em Nova York. Verifica-se que a função estabelecida para baixa densidade de tráfego não se comporta de forma muito ajustada em situação de congestionamento, uma vez que nesse regime o espaçamento relativo não está muito ligado ao comportamento do condutor.




Figura 2.4 - Fluxo  $q$  (carros/hora) x Densidade  $k$  (carros/milha)(Edie, 1961)

Mais tarde as considerações de Gazis, Herman e Rothery (1961) e os estudos correlatos, foram desenvolvidas para criação do modelo *General Motors*, descrito na equação (2.2), onde surgem as constantes  $m$  e  $l$ , para ajuste das funções velocidade e espaçamento, respectivamente (Li & Sun, 2012; Raslavičius et al., 2015).

$$a_n(t + \tau) = k v_n^m(t) \frac{\Delta v_n(t)}{\Delta x_n^l(t)} \quad (2.2)$$

Onde  $a_n(t + \tau)$  é a aceleração do veículo  $n$  (seguidor),  $k$  a constante de sensibilidade,  $v_n(t)$  é a velocidade do veículo  $n$ ,  $\Delta v_n(t)$  a diferença de velocidade entre o veículo  $n + 1$  (líder) e veículo  $n$ , assim como  $\Delta x_n(t)$  é a diferença de posição entre os veículos,  $\tau$  é o tempo de reação do condutor e  $m$  e  $l$  são constantes de ajuste da velocidade e do tempo, respectivamente.

Lee (1966) também pressupôs uma proporcionalidade entre a velocidade (resposta) e a variação do afastamento (estímulo), dada por funções, chamadas memória  $M$ , que eram aplicadas a depender da geometria do gráfico a se observar em campo.

### 2.2.3 Wiedemann e os modelos psicofísicos

De acordo com novo conceito, introduzido por Michaelis (1965), o motorista reconhece mudanças no tamanho aparente de um veículo líder em menor velocidade, através de mudanças

no ângulo visual, mesmo que mínimas. Experimentos indicam certos limites na diferença de velocidade relativa e distância para os motoristas reagirem. Esse tipo de modelo é chamado de psicofísico, ou modelo de ponto de ação (Barceló, 2010).

Ao aproximar de um veículo mais lento, alguns pontos de ação são reconhecidos conscientemente pelo condutor; outros, são reconhecidos inconscientemente e dependem da diferença de velocidade, afastamento e o comportamento do motorista (Barceló, 2010).

O mais importante dos modelos do tipo, desenvolvido por Wiedemann (1974), descreve os aspectos psicofisiológicos do comportamento do condutor em quatro regimes de condução discretos: *i*) fluxo livre; *ii*) aproximação de veículos mais lentos; *iii*) *car-following* próximo ao equilíbrio de estado estacionário; e *iv*) situações críticas que exijam ações de frenagem mais fortes. Em cada um desses regimes é aplicada uma função aceleração distinta (Treiber & Kesting, 2013). A Figura 2.5 mostra a representação esquemática dos regimes.

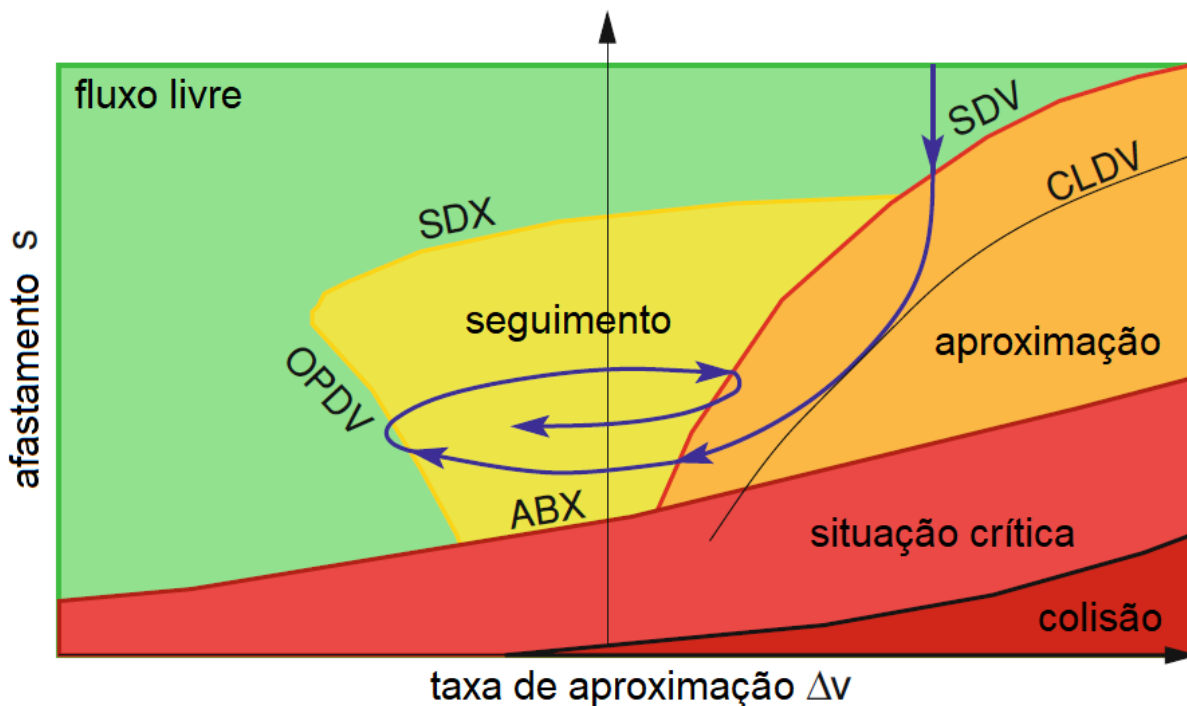


Figura 2.5 - Representação dos regimes do modelo de Wiedemann

A linha azul mostra a trajetória do veículo se aproximando de veículo mais lento. As transições entre regimes são dadas por curvas que descrevem a velocidade relativa (CLDV - aproximação, OPDV - afastamento e SDV - limiar de sensibilidade) e o afastamentos entre veículos (ABX - espaçamento mínimo e SDX - espaçamento máximo).

Na trajetória apresentada na Figura 2.5, inicialmente o veículo trafega em fluxo livre e com a velocidade desejada, isso corresponde a uma aproximação constante. Uma vez ultrapassado o

limiar de percepção de reconhecimento do veículo à frente, o motorista entra no regime de aproximação. O modo de condução neste regime reflete a estratégia de atingir simultaneamente a velocidade do líder e a distância desejada freando de acordo até que entre no regime de seguimento, onde a trajetória oscila em torno do estado ideal ( $\Delta V = 0$  e afastamento constante) (Treiber & Kesting, 2013).

As taxas máximas de aceleração dependem das características técnicas dos veículos que em geral são mais baixas para caminhões do que o desejo pessoal do motorista. O modelo inclui regra para ultrapassar a taxa máxima de desaceleração em caso de emergência, que ocorre quando o limiar ABX é excedido (Barceló, 2010).

O modelo de Wiedemann (1974) e sua atualização (Wiedemann & Reiter, 1992), compõem, com uma série outros submodelos, a aplicação alemã de simulação microscópica VISSIM (Figura 2.6).



**Figura 2.6** - Exemplo de representação 3D da aplicação VISSIM (Barceló, 2010)

#### 2.2.4 Gipps

Retomando a premissa de distância segura, GIPPS (1981) desenvolveu um modelo consistindo em duas componentes de velocidade, uma de aceleração e outra de desaceleração, para descrever o comportamento de veículos em seguimento. Estas componentes são descritas empiricamente pelas equações (2.3) e (2.4), as quais dão a velocidade de cada um dos veículos no instante  $t$ :

$$v_n^A(t + \tau) = v_n(t) + 2,5a_n\tau \left(1 - \frac{v_n(t)}{v_n^d}\right) \sqrt{0,025 + \frac{v_n(t)}{v_n^d}} \quad (2.3)$$

$$v_n^B(t + \tau) = -d_n \left(\frac{\tau}{2} + \theta\right) + \sqrt{d_n^2 \left(\frac{\tau}{2} + \theta\right)^2 + d_n \left\{2[x_{n-1}(t) - x_n(t) - S_{n-1}] - \tau v_n(t) + \frac{v_{n-1}^2(t)}{d_{n-1}'}\right\}} \quad (2.4)$$

Em que  $\tau$  é o tempo de reação,  $\theta$  é uma margem de segurança associada ao tempo de reação,  $v_n(t)$  e  $v_{n-1}(t)$  são, respetivamente, as velocidades dos veículos  $n$  (seguidor) e  $n-1$  (líder) no instante  $t$ ,  $v_n^d$  e  $a_n$  são respetivamente a velocidade desejada e a aceleração máxima do seguidor,  $d_{n-1}$  e  $d_{n-1}'$  são respetivamente a desaceleração mais severa que o seguidor está disposto a aplicar e a estimativa dessa mesma desaceleração, feita pelo condutor seguidor, relativamente ao veículo líder ( $d_{n-1} > 0$  e  $d_{n-1}' > 0$ ),  $x_{n-1}(t)$  e  $x_n(t)$  são respetivamente as posições longitudinais do líder e do seguidor no instante  $t$ ,  $S_{n-1}$  é o “comprimento efetivo” do líder, isto é, o comprimento real do veículo líder  $L_{n-1}$  adicionado ao espaçamento mínimo entre veículos imobilizados  $s_{n-1}$  (para-choques dianteiro – para-choques traseiro).


A velocidade do veículo  $n$  no instante  $t + \tau$  é dada pelo mínimo de  $v_n^{acc}(t + \tau)$  e  $v_n^{dec}(t + \tau)$ . Quando o intervalo entre veículos é muito grande então a velocidade mínima é dada por (2.3) e o veículo acelera livremente de acordo com uma lei derivada de dados empíricos, tendendo assintoticamente para a velocidade desejada  $v_n^d$ . Caso contrário a velocidade é dada por (2.4), sendo que esta expressão indica a velocidade máxima que permite a imobilização do veículo, recorrendo à sua máxima desaceleração  $d_n$ , tal que no fim da manobra resulte o espaçamento mínimo entre veículos parados  $s_{n-1}$ .

Na dedução da expressão assumiu-se que a desaceleração do líder é  $d_{n-1}'$  e que o seguidor começa a travagem com um atraso de  $\tau$ . É ainda assumido que os condutores têm em consideração uma margem de segurança  $\theta$  para evitar desacelerar sempre à taxa máxima. Gipps fixou o parâmetro através da relação  $\theta = \tau / 2$  numa fase inicial do seu trabalho e normalmente esta igualdade encontra-se subentendida nas equações respeitantes às componentes de aceleração e desaceleração.

A posição dos veículos pode ser atualizada facilmente fixando o intervalo de simulação igual ao tempo de reação  $\tau$ . É assim possível utilizar um método de integração trapezoidal:


$$x_n(t + \tau) = x_n(t) + \frac{\tau}{2} [v_n(t) + v_n(t + \tau)] \quad (2.5)$$

Em simulação em rodovia de três pista, na aplicação MULTISIM (Gipps, 1976), GIPPS (1981) notou aplicabilidade do modelo em termos macroscópicos, ao obter a típica curva tipo ferradura no gráfico fluxo por velocidade (Figura 2.7).




**Figura 2.7** – Fluxo x Velocidade em rodovia simulados por Gipps no MULTISIM (Gipps, 1981)

As experimentações sugeriram uma insensibilidade da curva fluxo - velocidade quanto aos parâmetros  $a_n$ ,  $d_n$  e  $S_n$ , enquanto os parâmetros  $\tau$  e  $d'_{n-1}$  foram responsáveis pela determinação do fluxo máximo (Gipps, 1981). Em partes, explicado pela possível perturbação ocorrente da subestimação do parâmetro  $d'_{n-1}$ , para exemplo, Gipps fixou todos os parâmetros, incluso  $d_n$  em  $-3 \text{ m/s}^2$  e simulou sete veículos em seguimento para  $d'_{n-1}$  iguais a  $-3,5 \text{ m/s}^2$  (Figura 2.8) e  $-2,5 \text{ m/s}^2$  (Figura 2.9), sendo possível notar a clara perturbação para o segundo caso.



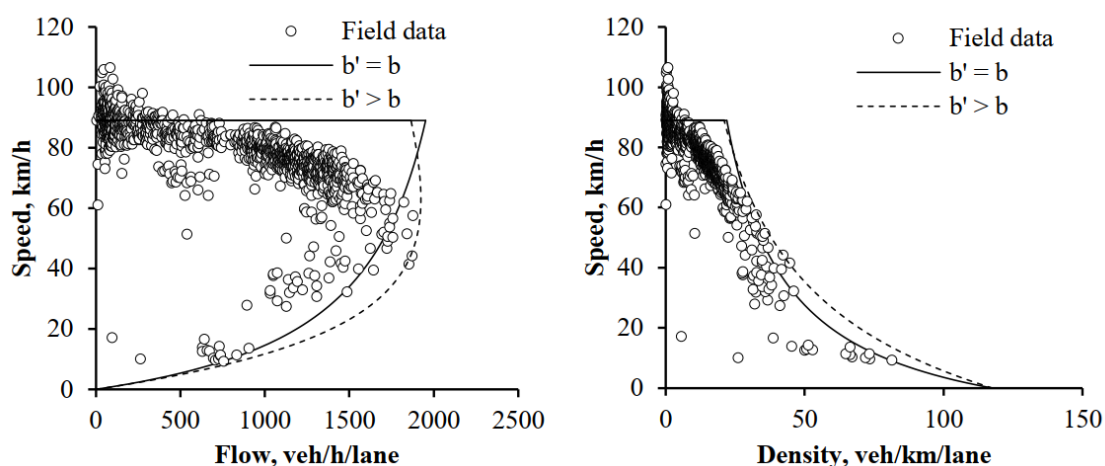
**Figura 2.8** - Tempo (s) x Velocidade (m/s) de sete veículos em seguimento com parâmetro  $d'_{n-1}$  superestimado (Gipps, 1981)



**Figura 2.9** - Tempo (s) x Velocidade (m/s) de sete veículos em seguimento com parâmetro  $d'_{n-1}$  subestimado (Gipps, 1981)

Wilson (2001), demonstrou que quando  $d > d'$  o modelo pode se tornar não-físico e produzir múltiplas soluções para o mesmo conjunto de parâmetros. Logo,  $b$  deve ser definido como  $d'$  ou menos.


Como ilustrado na Figura 2.10, a adoção de  $d = d'$  para calibração com dados reais geralmente resulta em um bom ajuste no regime de congestionamento e um ajuste sub-ótimo no regime não congestionado. Isso ocorre porque a solução do modelo para regime estacionário prevê velocidade constante no regime livre e, para o caso particular de  $d = d'$ , capacidade da seção à velocidade livre (Vasconcelos et al., 2014).



**Figura 2.10** – Ajustamento das curvas  $q-v$  e  $q-k$  aos dados de campo (autoestrada A44, Portugal):  $v_d = 89$  km/h,  $S = 8.5$  m, caso 1:  $d = d' = 3$  m/s<sup>2</sup>,  $\tau = 1.0$  s; caso 2:  $d = 3$  m/s<sup>2</sup>,  $d' = 3.6$  m/s<sup>2</sup>,  $\tau = 0.6$  s;  $\theta = \pi/2$  (L. Vasconcelos et al., 2014)

No entanto, diversos estudos de campo mostram que a velocidade é sensível ao fluxo e a velocidade na capacidade é menor do que a velocidade de fluxo livre. O ajuste pode ser melhorado adotando um valor  $d' > d$ . De fato, essa relação aumenta a curvatura do ramo congestionado e resulta em uma velocidade na capacidade inferior à velocidade de fluxo livre (caso  $d' > d$ ) (Punzo & Tripodi, 2007; Vasconcelos et al., 2014).

O modelo de Gipps é conhecido, principalmente, por compor, com outros submodelos, a aplicação AIMSUN (Figura 2.11).



**Figura 2.11** - Exemplo de interseção na aplicação AIMSUN (AIMSUN, 2022)



## 3. Intelligent Driver Model (IDM)

### 3.1 Introdução

Dentre os vários modelos *car-following* existentes, o Intelligent Driver Model (IDM) tem ganhado notoriedade por utilizar parâmetros de relativamente simples compreensão e obtenção. Adicionalmente, sua estrutura permite integrar sistema de condução semiautomática por *cruise control* adaptativo (ACC), contando com a estratégia de frenagem autorreguladora, capaz de forçar grandes taxas de frenagem para garantir a não colisão (vide item 3.6).

O Intelligent Driver Model (IDM) é um modelo que se baseia na lógica de distância segura, portanto, livre de acidente. É provavelmente um dos modelos mais completos e simples a produzir perfis realísticos de aceleração e comportamento plausível em todas as situações de seguimento de carro.

Este capítulo descreve o modelo IDM e suas características através da revisão de Treiber e Kesting (2013) e Treiber et al (2000).

## 3.2 Premissas

O modelo se baseia em premissas básicas, sendo essas:

1. Condições gerais de resposta:
  - a. A aceleração é uma função decrescente da velocidade, sendo que o veículo acelera até a velocidade desejada se não for restringido por outros veículos ou obstáculos;
  - b. A aceleração é uma função crescente do espaçamento com o veículo à frente;
  - c. A aceleração é uma função crescente da velocidade do veículo à frente;
  - d. É garantido um espaçamento mínimo em relação ao veículo à frente, no entanto não há movimento de ré mesmo que tal decorra de condições prévias.
2. O afastamento (distância entre pára-choques de veículos em seguimento) não é menor que a distância segura;
3. Uma estratégia de frenagem inteligente controla a aproximação de veículos mais lentos:
  - a. Em condições normais, a manobra de frenagem é suave, ou seja, aumenta gradativamente até o valor confortável;
  - b. Em situação crítica, a desaceleração excede o valor confortável, até que o perigo seja evitado.
4. As transições entre modos de condução são suaves;

Cada parâmetro deve descrever apenas um aspecto do comportamento de condução.

## 3.3 Descrição matemática

Baseado nas premissas supracitadas, o modelo é representado pela equação da aceleração (3.1), consistindo em duas partes, uma se destina a comparar a velocidade  $v$  com a velocidade desejada  $v_0$  e outra, o espaçamento  $s$  com o espaçamento desejado  $s^*$  (3.2).

$$\dot{v} = a \left[ 1 - \left( \frac{v}{v_0} \right)^\delta - \left( \frac{s^*(v, \Delta v)}{s} \right)^2 \right] \quad (3.1)$$

$$s^*(v, \Delta v) = s_0 + \max \left( 0, vT + \frac{v\Delta v}{2\sqrt{ab}} \right) \quad (3.2)$$

Sendo:

- $\dot{v}$  : aceleração
- $a$  : aceleração máxima
- $b$  : desaceleração
- $v$  : velocidade
- $v_0$  : velocidade desejada
- $\delta$  : constante de ajuste da suavidade de aceleração
- $s^*$  : espaçamento desejado, ou seja, seguro
- $s$  : espaçamento
- $s_0$  : espaçamento mínimo
- $T$  : intervalo tempo até o veículo líder

Ao acelerar em fluxo livre ou a partir do repouso, o arranque se dará em aceleração máxima  $a$ , que tenderá para zero até que se atinja a velocidade desejada  $v_0$ . O expoente  $\delta$  controla essa redução, quanto mais alto seu valor, mais tardia será a redução (vide item 3.5).

Cada parâmetro descreve um aspecto comportamental, constante e intrínseco ao condutor. Ou seja, em mudanças de cenários, permanecerão os mesmos, exceto a velocidade desejada  $v_0$ . Por exemplo, em uma mudança de ambiente rodoviário para urbano, é expectável que a simulação possa seguir com os mesmos parâmetros, alterando somente a velocidade desejada  $v_0$ .

A aceleração do veículo num dado instante depende assim da sua própria velocidade  $v$ , da diferença de velocidade relativamente ao veículo líder  $\Delta v$  e da distância ao veículo líder  $s$ . Esta resposta é ajustada através dos parâmetros  $a$ ,  $b$ ,  $\delta$ ,  $v_0$  e  $T$ . Para isso, define-se um intervalo de tempo de atualização numérico finito  $\Delta t$ , e integra-se ao longo deste passo de tempo assumindo acelerações constantes. Este chamado método balístico, lê a nova velocidade e posição, como descritos nas equações (3.3) e (3.4), respetivamente.

$$v(t + \Delta t) = v(t) + \dot{v}\Delta t \quad (3.3)$$

$$x(t + \Delta t) = x(t) + v(t)\Delta t + \frac{1}{2}\dot{v}(\Delta t)^2 \quad (3.4)$$

A rigor, o modelo só fica bem definido se houver um veículo à frente e nenhum outro objeto que impeça a condução. No entanto, as generalizações são simples:

- Se não houver nenhum veículo à frente e nenhum outro objeto obstruindo (fluxo livre), define-se o afastamento para um valor muito grande, como 1000 m;
- Se o próximo objeto obstrutivo não for um veículo à frente, mas um semáforo vermelho ou uma interseção com sinal de parada, a simulação da luz vermelha ou o sinal de parada se dá por um veículo virtual parado onde se deseja. Ao simular uma transição para uma luz verde, basta eliminar o veículo virtual.

### 3.4 Regime estacionário

Em regime estacionário, veículos consecutivos seguem em igual velocidade sem variações, ou seja,  $\dot{v} = \Delta v = 0$ , logo o espaçamento pode ser traduzido como na equação (3.5).

$$s = \frac{s_0 + vT}{\sqrt{1 - \left(\frac{v}{v_0}\right)^\delta}} \quad (3.5)$$

Quando o líder circula em velocidade significativamente mais baixa que a velocidade desejada pelo seguidor ( $v \ll v_0$ ), a distância varia linearmente com a velocidade e depende principalmente dos parâmetros  $s_0$  e  $T$ , isso porque o denominador da equação (3.5) é muito próximo de um. Logo a equação (3.6) é uma simplificação válida para regime estacionário.

$$s \gtrsim s_0 + vT \quad (3.6)$$

O parâmetro  $T$ , se refere ao intervalo temporal em que o veículo seguidor demora para alcançar a posição do veículo líder, quanto menor, menor a distância de segurança resguardada pelo seguidor, ou seja, mais agressiva é a condução, e vice-versa. Diferente de outros modelos, como o modelos de Gipps (1981) discutido no item 2.2.4, o IDM não tem um parâmetro explícito para tempo de reação.

### 3.5 Aceleração em fluxo livre

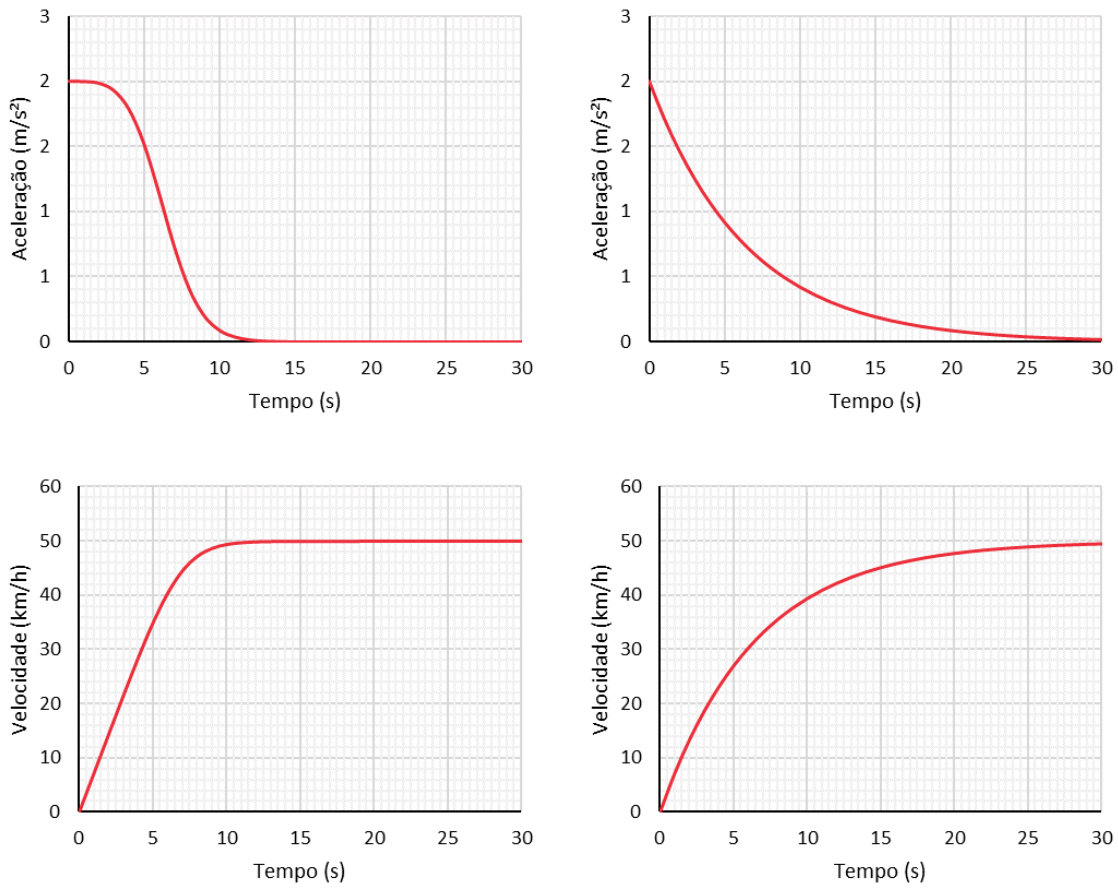
Quando o veículo circula isolado ou se encontra a uma grande distância do líder ( $s \rightarrow \infty$ ), o segundo termo da equação (3.1) é nulo e a aceleração pode ser reescrita de forma a desconsiderar os efeitos da parcela, e clarificar a maior influência de  $a$  e  $\delta$  (3.7).

$$\dot{v} = a \left[ 1 - \left( \frac{v}{v_0} \right)^\delta \right] \quad (3.7)$$

De acordo com esta expressão, a aceleração do veículo toma o valor máximo quando inicia o movimento ( $v = 0 \rightarrow \dot{v} = a$ ) e tende para zero à medida que a velocidade se aproxima da velocidade desejada ( $v = v_0 \rightarrow \dot{v} = 0$ ).

O parâmetro  $\delta$  controla a suavidade da variação da aceleração: um valor elevado conduz à convergência abrupta com a velocidade desejada (típico de uma condução agressiva), enquanto um valor baixo está associado a uma diminuição suave da aceleração e à convergência suave da velocidade para a velocidade desejada (típica de uma condução confortável).

A Figura 3.1, exemplifica a influência do parâmetro  $\delta$ , fixando os demais parâmetros e variando  $\delta$  em 4 e 1 para aceleração em fluxo livre. É possível notar no primeiro caso, um estilo de condução mais agressiva se comparado ao segundo caso, que diminui a velocidade de maneira mais suave, com um perfil curvo de velocidade.



**Figura 3.1** - Simulação de aceleração em fluxo livre, com  $\delta = 4$  para o caso da esquerda e  $\delta = 1$  para o caso da direita, demais parâmetros fixados em:  $v_0=50$  km/h;  $a = 2$  m/s²;  $b = 3$  m/s²;  $T = 2$  s;  $s_0 = 2$  m

### 3.6 Estratégia de frenagem autorreguladora

O termo  $v\Delta v/2\sqrt{ab}$  é responsável pela estratégia inteligente de frenagem. Para mostrar o efeito causado na aceleração, a equação (3.8) anula os demais termos  $s_0 + vT$  (espaçamento em regime estacionário) e  $[1 - (v/v_0)^\delta]$  (aceleração em fluxo livre) da equação (3.1) e simula uma situação de aproximação de um veículo parado ou obstáculo ( $\Delta v = v$ ).

$$\dot{v} = -a \left( \frac{v^2(\Delta v)^2}{4abs^2} \right) = - \left( \frac{v^2}{2s} \right)^2 \frac{1}{b} \quad (3.8)$$

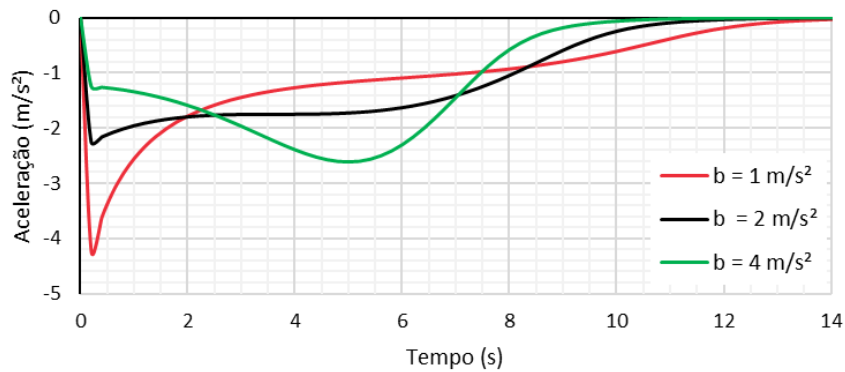
Por definição, a desaceleração cinética pode ser escrita como na equação (3.9), logo a equação (3.8) pode ser reescrita como na equação (3.10), a seguir.

$$b_{cin} = \frac{v^2}{2s} \quad (3.9)$$

$$\dot{v} = -\frac{b_{cin}^2}{b} \quad (3.10)$$

Em caso de situação crítica, em que o espaçamento é muito curto e/ou a velocidade muito alta para garantir o espaçamento adequado entre veículos consecutivos, o termo  $b_{cin}$  será maior que a desaceleração confortável  $b$ , forçando a aceleração resultante ter taxas maiores que as confortáveis até que se recupere o controle para uma situação não crítica, ou seja, quando  $b_{cin}$  for menor que a desaceleração confortável  $b$ , onde as taxas de aceleração estarão em limites confortáveis.

Para exemplificar, a Figura 3.2 mostra os efeitos da estratégia de frenagem autorreguladora numa simulação onde três veículos são forçados a parar repentinamente em um sinal semafórico vermelho. Para o condutor com  $b = 1\text{m/s}^2$  a situação é dada como crítica, pois  $b_{cin} = v^2/2s = 1,9\text{m/s}^2$ , e por isso, a taxa de desaceleração cai para limites além do confortável, enquanto os demais condutores apresentam frenagem em limites confortáveis.



**Figura 3.2** - Aceleração x Tempo (s) para parada repentina em vermelho semafórico ( $s = 60$  m e  $v = 54$  km/h),  $b$  variável e demais parâmetros fixos, sendo  $s_0 = 0.1$  m,  $T = 1$  s,  $a = 0,5$  m/s² e  $\delta =$



## 4. Coleta de dados

### 4.1 Objetivos

A coleta de dados teve por objetivo obter informação cinemática de veículos em condução para sustentar as tarefas de calibração e validação do Intelligent Driver Model, essencialmente: posição (distância percorrida); velocidade; aceleração; e afastamento entre veículos.

As sessões se deram com veículos instrumentados e os modos de condução pelos quais os condutores passaram foram:

- Manobras: trechos de fluxo livre, sem influência de outros veículos, onde os condutores aceleram até a velocidade desejada, a partir do repouso, depois, desaceleram até o repouso. O processo foi realizado adotando diferentes estilos de condução: suave, normal e agressivo (três vezes cada).
- Condução em fluxo urbano: o veículo equipado segue e é condicionado por um veículo líder em trajeto urbano. Este conjunto de observações foi realizado adotando um estilo de condução normal.

As manobras isoladas permitirão, mais adiante, obter as taxas de aceleração  $a$ , bem como seu fator de ajuste  $\delta$ , e desaceleração  $b$ . A condução em fluxo urbano permitirá observar o comportamento do condutor ao seguir um líder, sobretudo quando em regime estacionário, e obter os parâmetros  $s_0$  e  $T$ .

Os experimentos foram realizados com cinco condutores diferentes, alunos e professores do Instituto Politécnico de Viseu, Portugal, de ambos os sexos, com idades compreendidas entre os 23 e 53 anos, todos com experiência de condução.

## 4.2 Instrumentação

Os veículos utilizados para a coleta foram um Hyundai Bayon de 2021 com transmissão manual, um Mercedes C220 de 2015 com transmissão automática e um Corsa Opel de 2005 com transmissão manual, sendo o último utilizado somente na condição de veículo líder. Foi garantido que todos os dados de um referido condutor foram colhidos na condução de um mesmo veículo.

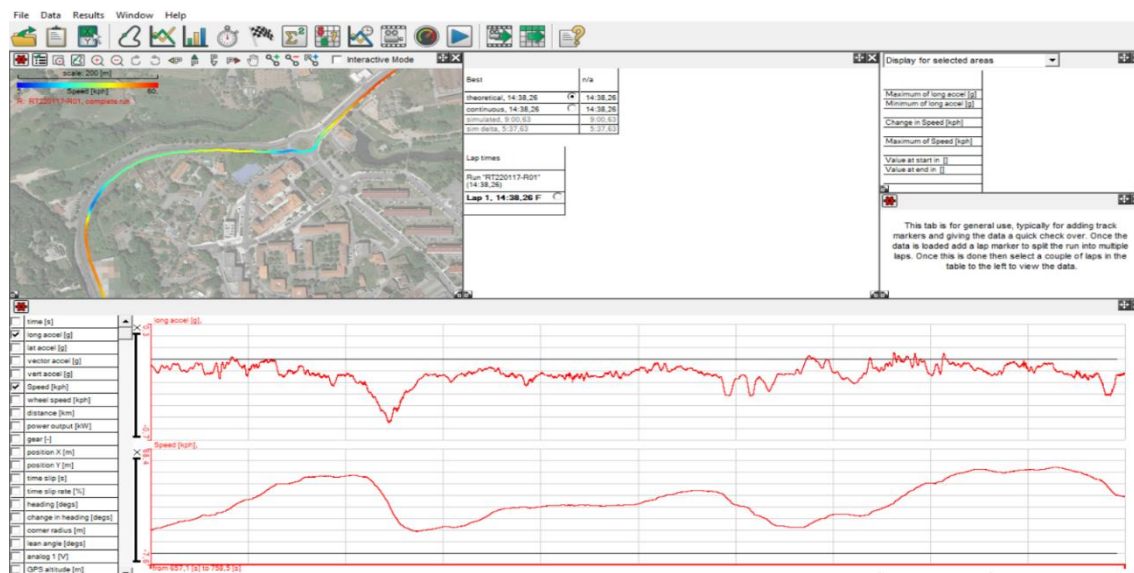
Quando em modo manobras, o veículo utilizado para análise esteve equipado com um *datalogger* (DL1 MK3 da Race Technology Ltd) que associa um GPS de 20 Hz a acelerómetros internos que permitem precisão posicional de 3 m (probabilidade de erro circular) e medições de velocidade com erro inferior a 0.1 km/h (Figura 4.1). Nesse momento não foi coletada a informação de afastamento, pois não havia outros veículos exercendo influência sobre a condução.

Quando em fluxo urbano, além do *datalogger*, foi utilizado um LIDAR (ULS, da Laser Technology Inc.), que apontado para o veículo líder, a partir do banco do passageiro do seguidor, obteve os dados de afastamento com precisão de  $\pm 2$  cm (Figura 4.1).



**Figura 4.1** - Instrumentação: em (a) coleta em funcionamento, em (b) *datalogger* e em (c) LIDAR

As séries temporais relevantes (posição, velocidade, aceleração e distância ao líder) foram inicialmente selecionadas e processadas através do software Race Technology (Figura 4.2) e posteriormente exportadas em formato “.mat” para análise em Matlab.



**Figura 4.2** - Interface da aplicação Race Technology, no canto superior esquerdo mapa com trecho selecionado, na parte inferior gráficos de aceleração e velocidade – tempo (notar a necessidade de pós-processamento para correção das acelerações)

### 4.3 Percurso

Os procedimentos ocorreram no município de Viseu, em Portugal, como destacado na Figura 4.3. A condução em fluxo urbano passou por vias arteriais (trechos 1-2 e 4-5 da Figura 4.3) e distribuidores (trecho 2-4 da Figura 4.3), no intuito de coletar diferentes velocidades desejadas. Na figura, o trajeto se inicia em 1 e termina em 5, sendo o trecho entre 5 e 6, destinado as manobras. Os trechos incluem os seguintes arruamentos: 1-2, a Avenida Regimento de Infantaria Nº 14; 2-3, a Avenida 25 de Abril; 3-4, a Avenida Alberto Sampaio e Rua Almirante Afonso Cerqueira; 4-5, a Circunvalação; 5-6, Avenida Cidade de Salamanca

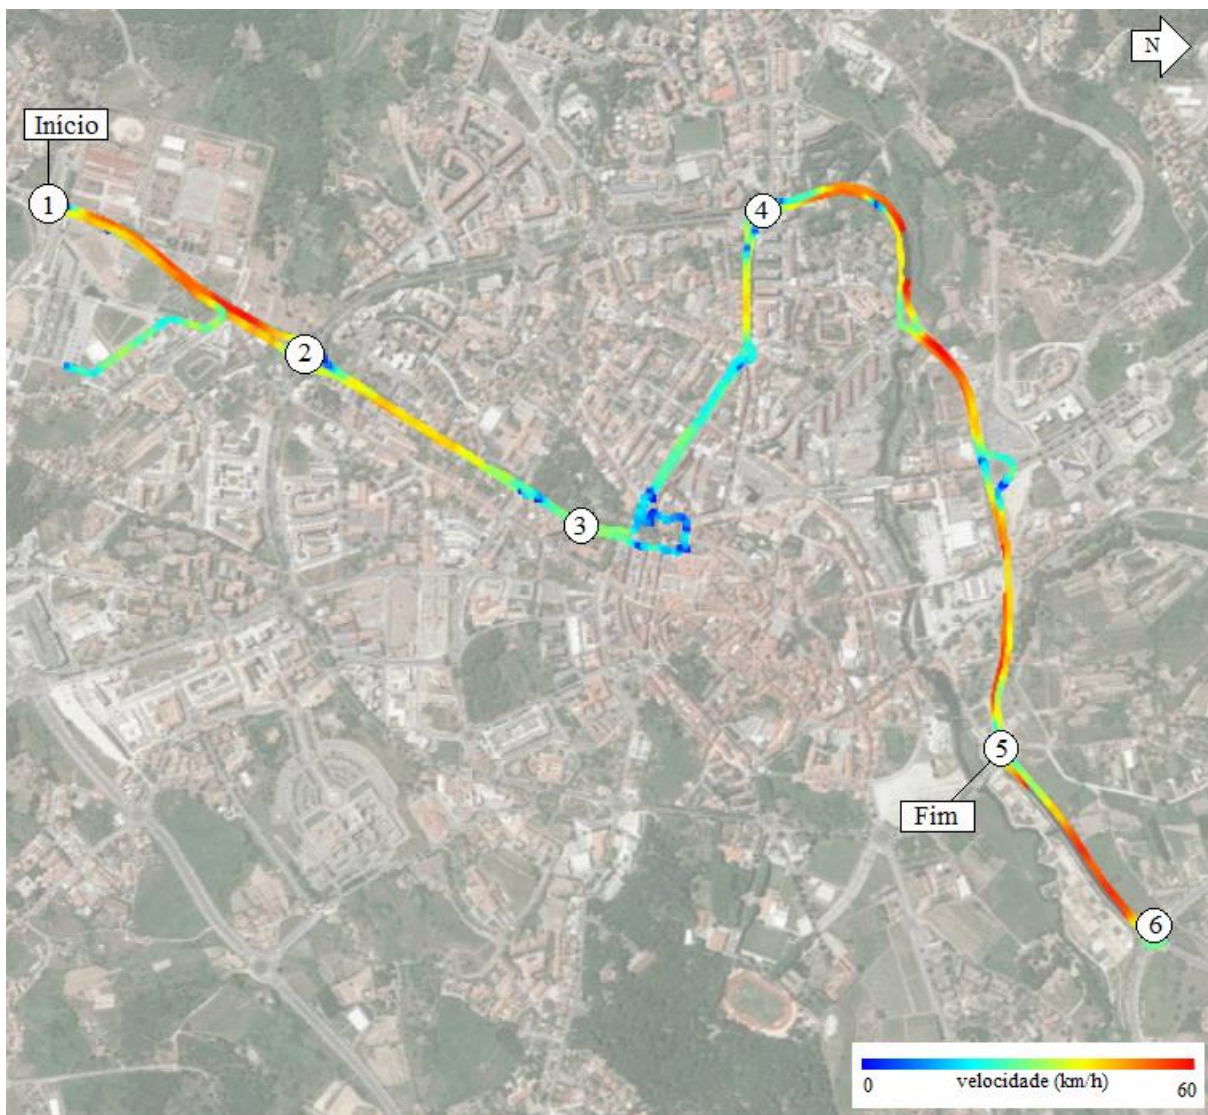


Figura 4.3 - Trajeto da coleta de dados

O trajeto foi percorrido em ida e volta, em um primeiro momento somente os dados de ida foram utilizados para realização da calibração, sendo os dados de volta, percorrido em trajeto idêntico, reservados para validação dos dados.

As vias arteriais percorridas continham duas faixas de rolamento por sentido, com canteiro central e parcialmente com estacionamento lateral. As vias distribuidoras, uma faixa por sentido, estacionamento lateral e parcialmente pavimentada com paralelepípedos, alternativa ao tradicional asfalto (Figura 4.4).



**Figura 4.4** - Vias do trajeto, de cima para baixo, da esquerda para direita: Avenida Regimento de Infantaria Nº 14; Avenida 25 de Abril; Avenida Alberto Sampaio; Avenida Monsenhor Cónego António Freire (circunvalação); e Avenida Cidade de Salamanca (Google Maps)

## 4.4 Seleção dos dados

Antes das análises, foram examinados os dados para selecionar os utilizáveis e em certos casos, descartar trechos não utilizáveis. Os dados do LIDAR, apresentaram “picos”, que indicam uma leitura incorreta, ora pelo desvio do ponto mirado, ora por dificuldades com iluminação. Para os “picos” foi realizada uma varredura visual em todos os dados a fim de selecionar os pontos em que se destoavam da curva, vide Figura 4.5.




Figura 4.5 - Remoção de "picos" nos dados do LIDAR

A leitura do LIDAR não é feita em períodos fixos, a distância temporal entre dados coletados varia, sobretudo pela iluminação do ponto mirado. Trechos onde houve dispersão dos dados em mais de dois dados seguidos, ou dados consecutivos com diferença maior de 1,5 segundos foram descartados. Exemplo de trecho descartado é apresentado na Figura 4.6.




Figura 4.6 - Exemplo de dados LIDAR descartados

Com dados apurados, foi realizada a aglutinação entre informações do *datallogger* e LIDAR, verificada a sincronicidade e ajustada quando necessário. A frequência dos dados foi configurada a 10 Hz.

Em dados de trajeto, foram retirados trechos referentes a situações que provocam perturbações e incertezas, que dentre outros, eram: curvas fechadas, principalmente em rotatória; parada em vermelho semaforico; parada em travessia de pedestre; desvinculação do veículo líder definido.

## 4.5 Conclusão

A seleção de dados do *datallogger* se fez somente para excluir momentos dos percursos que não traduzissem o objeto de estudo, enquanto os dados obtidos no LIDAR necessitaram de um tratamento específico, para que fossem utilizados.

Contudo, a aglutinação dos dados obtidos com os dois equipamentos forneceu dados suficientes para calibração, com custo total de instrumentação inferior a 2500€. A Tabela 4.1 contém um balanço das dados colhidos e eventos selecionados para as calibrações. Ao final da coleta e seleção dos dados, procedeu as calibrações propriamente ditas, descritas no próximo capítulo.

**Tabela 4.1** - Dados coletados

Condutor	Tempo de coleta (s)	Distância percorrida (km)	Eventos		
			Regime estacionário	Manobras - acelerações	Manobras - desacelerações
1	1707	12,2	13	9	9
2	2512	19,5	13	20	20
3	2025	14,0	13	9	9
4	1578	11,6	7	4	4
5	1364	9,8	7	4	4
Total	9186	67,1	53	46	46

# 5. Calibração

## 5.1 Metodologia

### 5.1.1 Aspectos gerais

Condutores apresentam estilos diferentes de condução, em diferentes tipos de veículos e ambientes rodoviários. Vasconcelos et al (2013), num estudo sobre estimação de parâmetros para modelos de *gap-acceptance*, concluiu que os condutores portugueses e espanhóis são mais agressivos que os condutores dos países do norte e este da Europa, o que sugere a necessidade de usar parâmetros calibrados localmente para cada região. Outros aspectos de influência são a hora do dia e as condições atmosféricas – à noite, com chuva ou nevoeiro, a condução pode ser menos agressiva, ou em dias e locais onde não são permitidos veículos pesados (Treiber & Kesting, 2013).

Por isso, é necessário a adaptação dos modelos a condição a qual vai ser aplicado, isso significa calibrar os parâmetros no intuito da simulação representar da forma mais realística possível o que se pretende. Além disso, é necessário também verificar a replicabilidade do procedimento, através de validação.

---

Para Treiber e Kesting (2013), a calibração

“é a estimativa de parâmetros para maximizar o poder descritivo do modelo para reproduzir o comportamento do motorista local e/ou características de fluxo de tráfego coletivo. O poder descritivo é especificado por uma função objetivo a ser aplicada aos dados de teste.”

Como os modelos *car-following* procuram replicar o comportamento individuais de motoristas, sua formulação matemática geralmente inclui um grande conjunto de parâmetros ajustáveis. Algumas abordagens de calibração dependem do uso de dados macroscópicos de tráfego, como contagens e velocidades nos detectores, e procuram os valores dos parâmetros que melhor replicam as relações medidas de velocidade, vazão e densidade.

No entanto, muitos autores defendem que o procedimento mais exato para calibrar modelos *car-following* requer dados de trajetória, ou seja, velocidades e distâncias relativas entre pares de veículos líder-seguidor. Dados de trajetória podem ser obtidos usando simuladores de direção (Berghaus et al., 2021), veículos instrumentados (Brackstone et al., 2002; Ranjitkar et al., 2005); ou de imagens aéreas, coletadas de prédios altos (Coifman & Li, 2017), helicópteros (Ossen & Hoogendoorn, 2005) ou drones (Krajewski et al., 2018).

Esses tipos de experimentos são caros e complexos, o que pode explicar por que apenas uma pequena fração (9%) dos trabalhos recentes relacionados a “*car-following*” e/ou “controle de cruzeiro adaptativo” tentaram calibrar os modelos *car-following* (Punzo et al., 2021).

Em geral, a calibração se utiliza de otimização não linear para minimizar uma função objetivo em relação a parâmetros do modelo em análise. Uma tarefa difícil, pois não existe um só método de solução, sendo estes também, muito trabalhosos, tendo que se recorrer a programação computadorizada.

O desempenho da calibração depende dos dados analisados e de como se comportam na função objetivo. O problema de otimização busca, diante da gama de dados, minimizar os indicadores, ou seja, aproximar a modelagem de dados de campo, porém, as funções podem se comportar de maneira a apresentar resultados enganosos ou uma variabilidade de possíveis resultados não correspondente a realidade.

Na Figura 5.1 são apresentados gráficos de três tipos de função, na primeira (a) é possível notar um mínimo para a função, já a segunda (b), apresenta mínimos secundários em uma direção, e por último, a terceira (c) há uma gama de possíveis mínimos secundários.

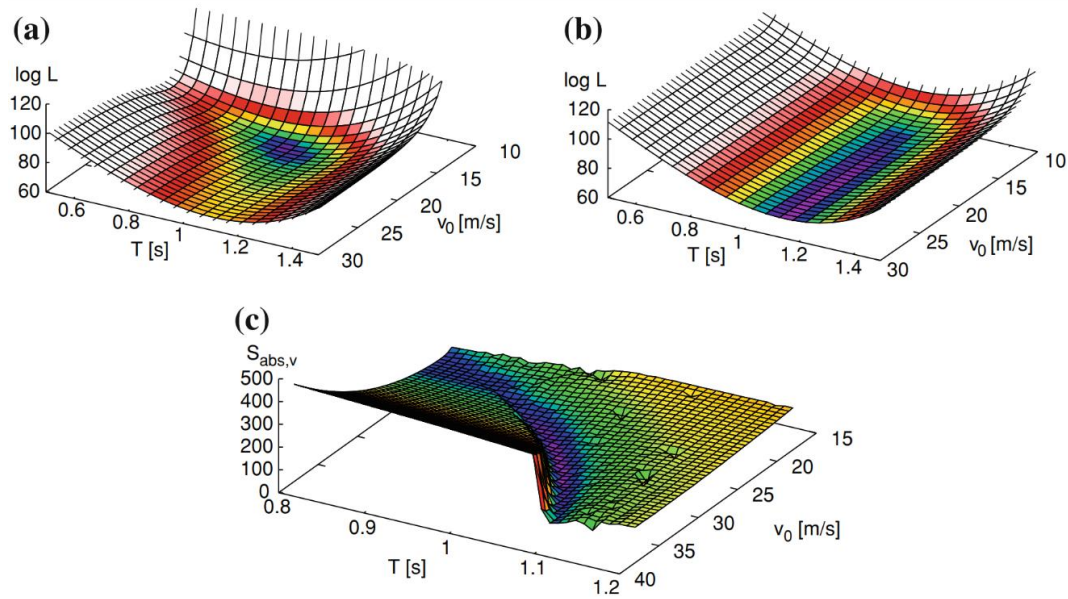


Figura 5.1 - Exemplo de diferentes comportamentos de função objetivos (Treiber & Kesting, 2013)

### 5.1.2 Indicadores de desempenho

Os indicadores de desempenho são medidas estatísticas que permitem comparar os dados de campo com os valores representados pelos modelos, sendo fundamentais nos processos de calibração.

Possivelmente a mais comum das comparações é feita com o *root mean squared error* (RMSe), ou erro quadrático médio em português, definido pela (5.1), é uma medida que compara dados em termos absolutos.

$$RMSe = \sqrt{\frac{1}{N} \sum_{i=1}^N (O_i - M_i)^2} \quad (5.1)$$

Onde:

- $N$  : número de dados
- $O_i$  : valor do dado observado
- $M_i$  : valor do dado medido

Há também o *root mean square percentage error* (RMSPe), ou erro quadrático percentual médio, que difere do RMSe, na medida em que compara os dados em análise em termos relativos (5.2).

$$RMSPe = \sqrt{\frac{1}{N} \sum_{i=1}^N \left( \frac{O_i - M_i}{O_i} \right)^2} \quad (5.2)$$

Em um grande agrupamento de dados haverá casos em que o RMSe se apresentará mais sensível a comparações e, em outros, o RMSPe será um indicador mais relevante. Por exemplo, a comparação com os pares (10, 11) ou (100, 101) resulta em RMSe de uma unidade, o que demonstra a insensibilidade deste indicador a diferenças percentuais. Da mesma forma, a comparação com os pares (10, 11) ou (100, 110) resulta em ambos os casos em RMSPe de 10%, o que revela a insensibilidade a diferenças absolutas (Vasconcelos, A., 2004)

O GEH é uma medida para compatibilização entre medidas relativas e absolutas baseado na medida Chi-quadrado, sugerido pelo *Traffic Appraisal Manual* (UK DOT, 1996) para comparação de fluxos observados e modelados, dado pela Equação (5.3). Van Vliet (1997), identifica as vantagens de utilizar a média dos dois valores no denominador, evitando divisões por zero e a de independência da ordem dos valores. O interesse na utilização desta medida reside no respeito pelas expectativas dos analistas. Por exemplo, será defensável admitir que um erro de 30 veículos/hora quando os fluxos são da ordem dos 100 veículos (30%) é tão grave como um erro de 100 sobre 1000 (10%), e nos dois casos o GEH é aproximadamente igual a 3.

$$GEH = \frac{1}{N} \sum_{i=1}^N \sqrt{\frac{(O_i - M_i)^2}{0,5(O_i + M_i)}} \quad (5.3)$$

O presente estudo se utilizou do RMSe para as análises por se tratar do indicador mais utilizado por trabalhos de calibração de modelos microscópicos (Sharma et al., 2019; Punzo et al., 2021) e também porque as séries de dados coletados, e conseqüentemente os modelados, formam pares com velocidade baixas, que ocorrem por vezes em longos períodos, podendo interferir negativamente no indicador caso seja este dependente de medidas relativas, sendo o RMSe mais sensível a pequenos valores (Ciuffo et al., 2012).

### 5.1.3 Metodologias de otimização

Existem várias metodologias numéricas para encontrar mínimos de uma função objetivo. Dentre os quais pode-se destacar:

1. Método de Newton: é um método determinístico de convergência local quadrática, duas vezes diferenciável e não muito distante da estimativa inicial. Rápido, porém pode não convergir, mesmo para casos simples como o caso (a) da Figura 5.1 (Treiber & Kesting, 2013).
2. Algoritmo Gauss-Newton: uma modificação do método de Newton, usado para minimizar soma dos valores quadrados de uma função. Mais simples que o método anterior.
3. Método de gradiente descendente: também conhecido como método do declive máximo, a procura prossegue sempre por um gradiente obtido na última interação, o mínimo se torna a nova direção de interação.
4. Algoritmo Levenberg-Marquardt: Esse método faz suaves transições entre os métodos gradiente descendente e Gauss-Newton, regidas por zonas de confianças adaptativas.
5. Algoritmos genéticos: São algoritmos inspirados nos princípios de evolução das espécies e na genética. Baseia-se na sobrevivência de um grupo (limitado pela probabilidade de sucesso), para uma nova geração (interação). É um método estocástico e por isso necessita de limites de interação bem definidos.
6. Método de entropia cruzada baseado em Kernel: Um método estocástico, cujo as interações apresentam flutuações na intenção é afastar a estimativa de mínimos secundários.

O método mais adequado para otimização depende, sobretudo, da função objetivo, porém é crucial para o sucesso da otimização que a estimativa inicial esteja próxima do ótimo esperado. A estimativa individual dos parâmetros (Item 5.2) buscou encontrar valores na observância de cada parâmetro separadamente e a calibração por otimização simultânea (Item 5.3), se utilizou dos parâmetros calibrados na estimativa individual para iniciar as iterações e balizar a gama de resultados admissíveis.

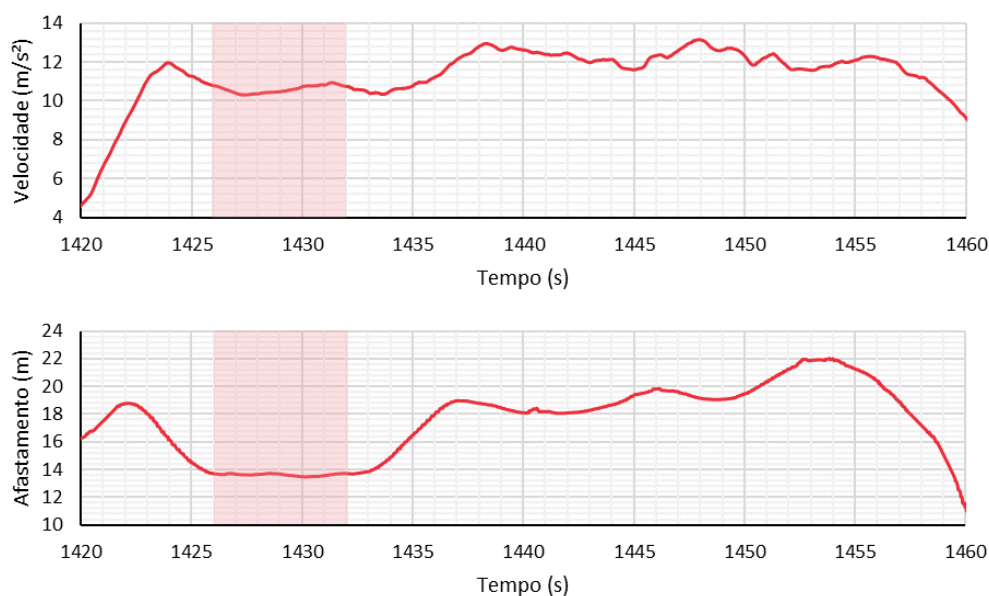
Por isso, os procedimentos de calibração foram implementados em Matlab recorrendo a função *fmincon* (encontrar o mínimo de uma função multivariável não linear restringida), baseado no método de gradiente descendente. A metodologia permitiu obter soluções precisas muito rapidamente.

## 5.2 Estimativa individual dos parâmetros

A fase de estimativa individual dos parâmetros do modelo busca obter os parâmetros relativos a cada condutor na observância de momentos de condução onde os mesmos são mais significantes e a influência dos demais parâmetros é diminuta ou pode mesmo ser descartada. Os próximos tópicos selecionam tais momentos na coleta de dados e mostram os resultados das análises.

### 5.2.1 Regime estacionário

Para analisar os dados em regime estacionário, foram selecionados trechos manualmente, nos gráficos de tempo-afastamento e tempo-velocidade (Figura 5.2), onde se evidenciava o regime estacionário (velocidade e afastamento constantes). Estes trechos continham entre 4 e 40 segundos de dados.



**Figura 5.2** - Exemplo de seleção de trecho em regime estacionário, acima o gráfico de velocidade (m/s<sup>2</sup>) x tempo (s) e abaixo o gráfico de afastamento (m) x tempo (s)

A análise dos dados selecionados possibilitou notar a relação linear de proporcionalidade entre a velocidade e o afastamento para esse modo de condução. Esta relação é consistente com o IDM no pressuposto de que a velocidade praticada pelo veículo seguidor é consideravelmente mais baixa do que a sua própria velocidade desejada, o que se pode considerar razoável já que o líder seguia a velocidades relativamente baixas. Assim, a distância entre veículos é aproximadamente a distância segura, dada nesse caso pela equação (3.6) (Figura 5.3).

Antes de tudo, as diferenças nas amplitudes dos gráficos demonstram variabilidade nos estilos de condução. Os dados foram colhidos em um mesmo trajeto e há um condutor que alcançou 19 m/s (68,5 km/h) enquanto outro alcançou no máximo 10 m/s (36 km/h) em regime estacionário. A relativamente baixa velocidade desejada pelos condutores 3 e 4 limitou a respectiva gama de pontos  $v$ - $s$  úteis.

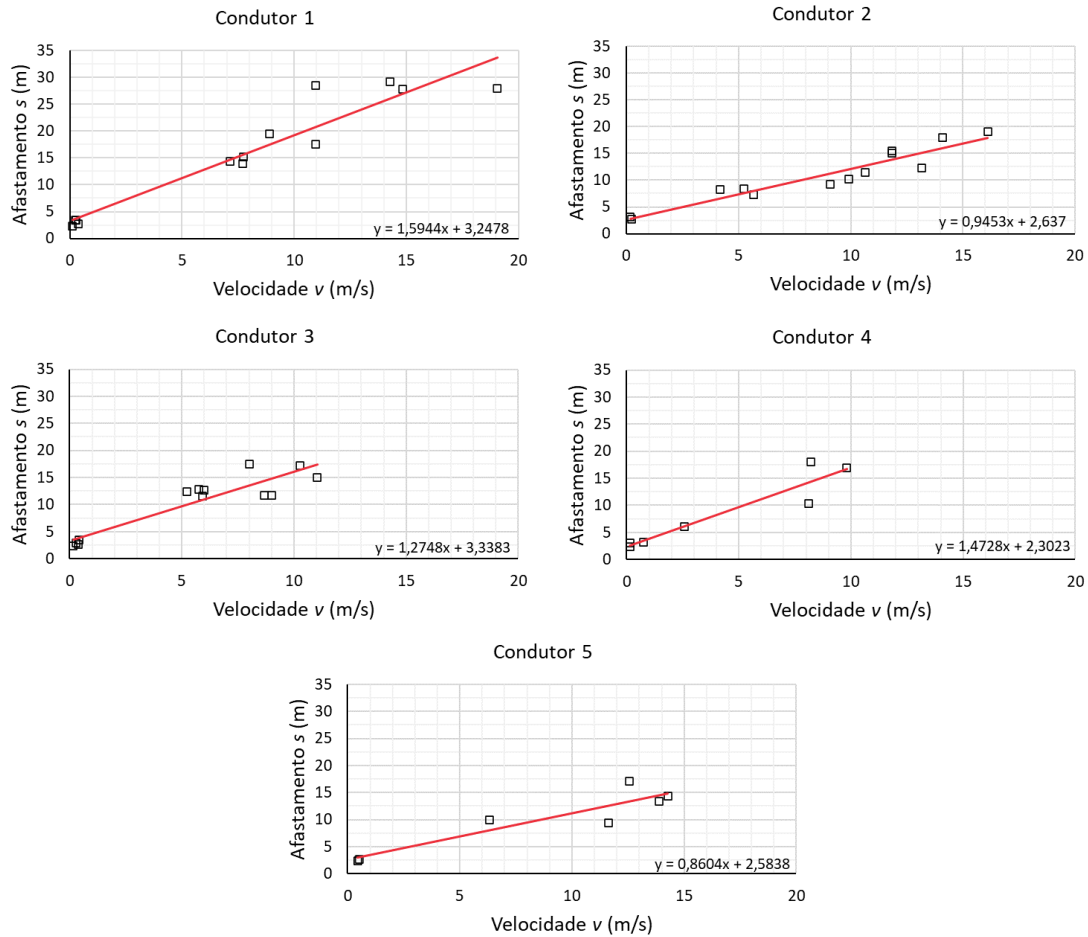


Figura 5.3 - Gráficos de afastamento (m) x tempo (s) em regime estacionário

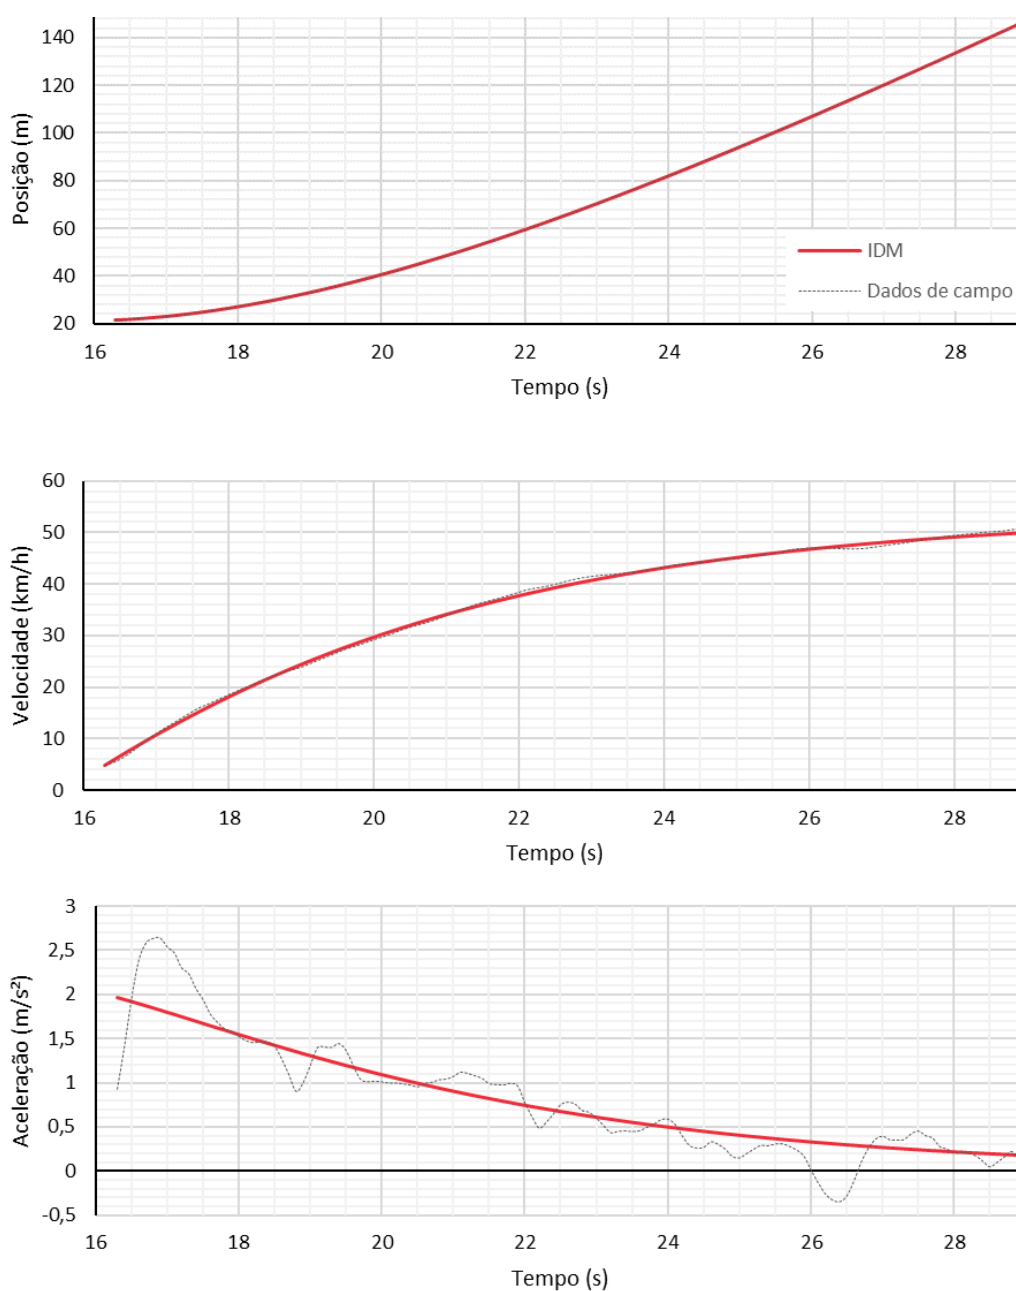
A regressão linear, ou linha de tendência, equivale a interpretação do afastamento seguro dado pela equação (3.6), sendo a intersecção com o eixo y, o afastamento mínimo,  $s_0$  e a inclinação da reta o parâmetro tempo  $T$ . Os dados obtidos são relacionados na Tabela 5.1.

Tabela 5.1 - Regime estacionário

Condutor	$s_0$ (m)	$T$ (s)	$R^2$
1	3,25	1,59	0,91
2	2,64	0,95	0,90
3	3,34	1,27	0,85
4	2,30	1,47	0,89
5	2,58	0,86	0,85

### 5.2.2 Aceleração a partir do repouso

A fim de estimar os parâmetros  $a$  e  $\delta$  foram selecionadas as acelerações a partir do repouso até a velocidade desejada  $v_0$  em fluxo livre, da coleta “manobras”. Foi aplicada a função `fmincon` do Matlab, para minimizar o RMSe entre a velocidade observada e a estimada, com  $s_0$  e  $T$  em valores fixos conforme a Tabela 5.1 e  $b$ , sem influência na análise em questão, em  $1 \text{ m/s}^2$ . A Figura 5.4 apresenta gráficos de uma das análises, a Tabela 5.2, todos os eventos de calibração e a Tabela 5.3 um resumo dos dados estimados.



**Figura 5.4** - Gráficos de uma aceleração a partir do repouso


**Tabela 5.2** - Estimativa individual dos parâmetros  $a$  e  $\delta$

Identificação		Parâmetros				Indicadores		
Condutor	Duração (s)	$s_0$ (m)	$T$ (s)	$a$ (m/s <sup>2</sup> )	$\delta$	RMSe	RMSPe	GEH
1	8,3	3,25	1,59	2,43	1,03	0,3372	15%	0,1310
1	5,9	3,25	1,59	2,08	1,07	0,3330	15%	0,1544
1	13,7	3,25	1,59	1,42	5,65	0,3212	16%	0,1110
1	1,9	3,25	1,59	1,85	8,00	0,1798	29%	0,1436
1	8,5	3,25	1,59	2,22	2,99	0,4067	14%	0,1455
1	10,6	3,25	1,59	1,97	5,31	0,3040	11%	0,0987
1	11,4	3,25	1,59	2,14	3,64	0,3610	19%	0,1205
1	13,3	3,25	1,59	1,00	1,08	0,3350	12%	0,1827
1	13,2	3,25	1,59	1,30	1,99	0,2608	20%	0,1110
2	12,7	2,64	0,95	2,52	1,28	0,1255	2%	0,0372
2	15,5	2,64	0,95	2,38	3,35	0,1598	5%	0,0457
2	10,4	2,64	0,95	2,87	1,61	0,1329	4%	0,0368
2	11,9	2,64	0,95	2,17	2,11	0,1631	4%	0,0528
2	14,5	2,64	0,95	1,99	2,50	0,1350	4%	0,0406
2	12,6	2,64	0,95	2,33	1,82	0,1099	3%	0,0286
2	10,8	2,64	0,95	2,18	3,01	0,1950	6%	0,0605
2	12,8	2,64	0,95	2,27	3,93	0,1950	6%	0,0567
2	12,4	2,64	0,95	2,71	3,15	0,2568	10%	0,0712
2	10,5	2,64	0,95	3,79	1,61	0,1155	2%	0,0278
2	9,2	2,64	0,95	2,75	2,70	0,1368	5%	0,0434
2	20,3	2,64	0,95	1,27	2,25	0,3221	6%	0,1013
2	21,7	2,64	0,95	1,12	2,28	0,1151	5%	0,0404
2	15,0	2,64	0,95	1,34	1,29	0,1269	4%	0,0381
2	15,6	2,64	0,95	1,25	2,87	0,1163	8%	0,0459
2	23,2	2,64	0,95	0,94	3,75	0,2189	13%	0,0840
2	37,7	2,64	0,95	1,85	1,48	0,1827	8%	0,0511
2	37,7	2,64	0,95	1,85	1,48	0,1827	8%	0,0511
2	22,7	2,64	0,95	1,68	1,82	0,2165	5%	0,0629
2	14,6	2,64	0,95	1,07	3,76	0,1020	2%	0,0289
3	16,0	3,34	1,27	1,41	1,23	0,2588	8%	0,0841
3	15,5	3,34	1,27	2,09	1,22	0,4101	12%	0,1396
3	16,2	3,34	1,27	1,82	1,00	0,5769	9%	0,1787
3	10,1	3,34	1,27	3,56	1,00	0,5255	8%	0,1430
3	9,8	3,34	1,27	3,29	1,45	0,4261	8%	0,1156
3	8,8	3,34	1,27	2,51	1,25	0,4988	13%	0,1567
3	14,4	3,34	1,27	1,47	1,00	0,2699	13%	0,0989
3	24,0	3,34	1,27	1,02	1,00	0,3016	21%	0,1125
3	15,7	3,34	1,27	1,32	1,00	0,4017	12%	0,1487
4	30,0	2,30	1,47	0,84	4,78	0,5440	5%	0,2344
4	14,0	2,30	1,47	0,93	4,65	0,3727	13%	0,2837
4	16,0	2,30	1,47	1,67	3,68	0,3567	5%	0,1999
4	12,0	2,30	1,47	1,80	6,00	0,5722	4%	0,2250
5	5,0	2,58	0,86	2,22	5,80	0,2908	8%	0,2301
5	14,0	2,58	0,86	1,86	5,00	0,3905	3%	0,1698
5	8,0	2,58	0,86	1,90	6,00	0,5281	4%	0,2423
5	10,0	2,58	0,86	2,17	6,42	0,3747	16%	0,3005

**Tabela 5.3** - Resumo da estimativa individual dos parâmetros  $a$  e  $\delta$

Conductor	$a$ (m/s <sup>2</sup> )	$\delta$	RMS <sub>e</sub>	RMS <sub>P<sub>e</sub></sub>	GEH
1	1,86	3,61	0,32	16%	0,13
2	1,72	1,84	0,18	6%	0,05
3	1,77	1,15	0,42	10%	0,13
4	1,21	4,72	0,47	6%	0,23
5	2,00	5,71	0,40	7%	0,23

A troca de marcha em veículo com transmissão automática é um fator que interfere no funcionamento contínuo na mudança de velocidade, no ato de trocar a marcha o gráfico de tempo – velocidade apresenta “plataformas” descontínuadoras da aceleração. A Figura 5.5 mostra um exemplo do efeito.



**Figura 5.5** - Exemplo de simulação com veículo de transmissão manual (acima) e automática (abaixo)

### 5.2.3 Desaceleração até o repouso

Similar a tópico anterior, foram selecionados os trechos de frenagem até o repouso da coleta “manobras”. A desaceleração  $b$  foi estimada através da minimização do RMSe, entre a velocidade observada e estimada, através da função `fmincon` do Matlab, ao variar somente o parâmetro  $b$  e fixar todos os demais conforme Tabela 5.1 ( $s_0$  e  $T$ ) e Tabela 5.3 ( $a$  e  $\delta$ ). A Figura 5.6 apresenta gráficos representativo de uma das análises, a Tabela 5.4, todos os eventos de calibração e a Tabela 5.5 um resumo dos dados estimados.

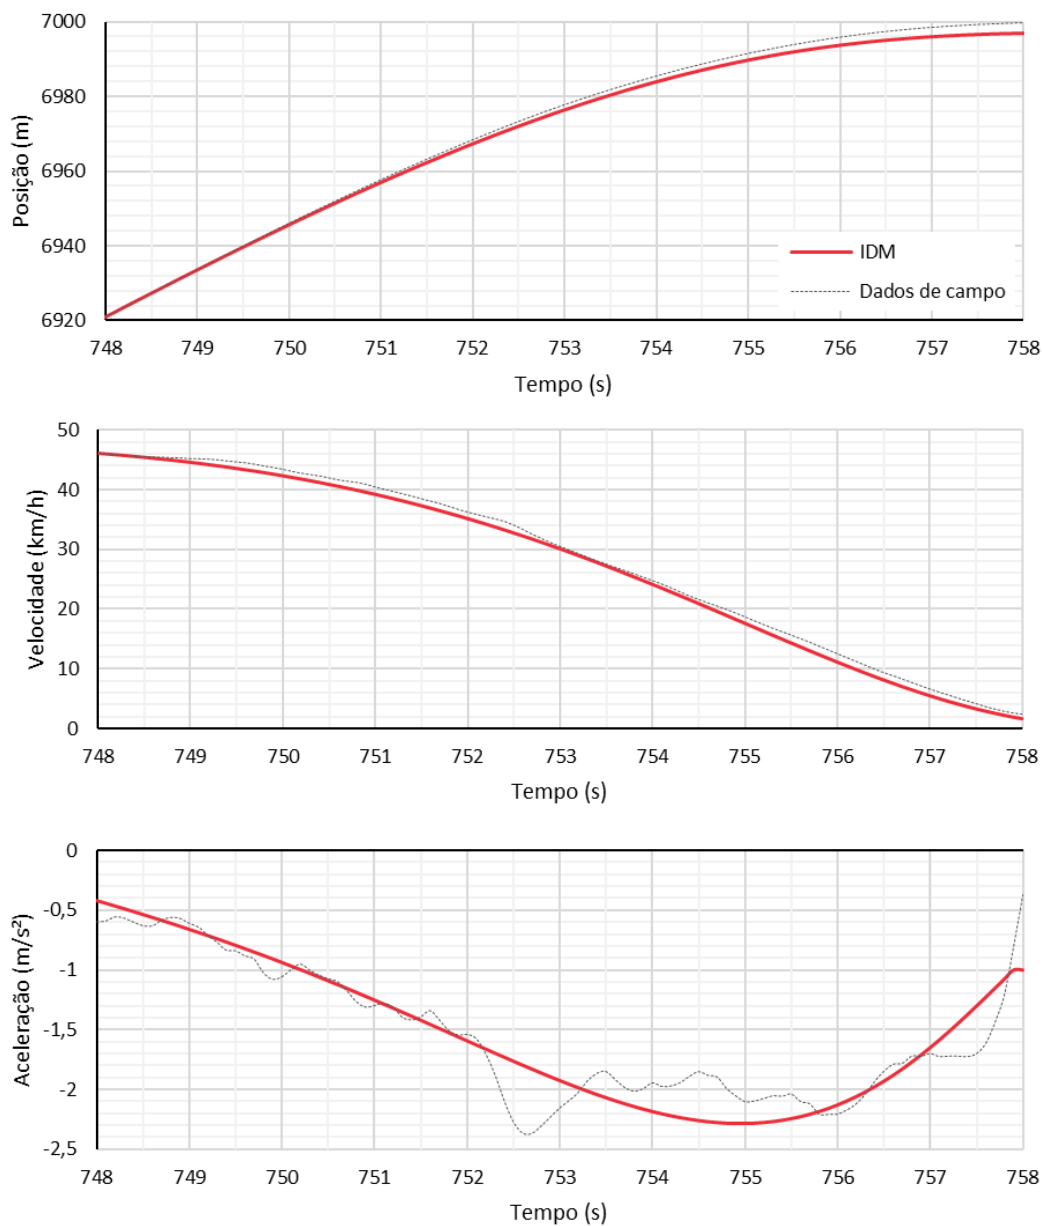


Figura 5.6 - Gráficos de uma desaceleração até o repouso

**Tabela 5.4** - Estimativa individual do parâmetro  $b$

Identificação		Parâmetros					Indicadores		
Condutor	Duração (s)	$s_0$ (m)	$T$ (s)	$a$ (m/s <sup>2</sup> )	$\delta$	$b$ (m/s <sup>2</sup> )	RMSe	RMSPe	GEH
1	6,9	3,25	1,59	1,86	3,61	7,01	0,5678	15%	0,2292
1	9,0	3,25	1,59	1,86	3,61	5,59	0,4484	29%	0,2277
1	7,6	3,25	1,59	1,86	3,61	8,45	0,4749	23%	0,2634
1	5,2	3,25	1,59	1,86	3,61	15,00	0,7295	36%	0,3643
1	3,0	3,25	1,59	1,86	3,61	15,00	1,4600	30%	0,5047
1	7,2	3,25	1,59	1,86	3,61	4,41	0,5290	35%	0,2970
1	8,0	3,25	1,59	1,86	3,61	4,17	0,5278	18%	0,2423
2	7,0	2,64	0,95	1,72	1,84	4,01	0,4535	18%	0,1864
2	9,0	2,64	0,95	1,72	1,84	3,69	0,2982	34%	0,2106
2	5,0	2,64	0,95	1,72	1,84	3,15	0,5823	19%	0,2836
2	9,0	2,64	0,95	1,72	1,84	3,10	0,3854	21%	0,1756
2	10,5	2,64	0,95	1,72	1,84	2,36	0,3313	22%	0,1494
2	10,0	2,64	0,95	1,72	1,84	2,78	0,2797	8%	0,1061
2	10,5	2,64	0,95	1,72	1,84	1,93	0,3992	11%	0,1356
2	10,0	2,64	0,95	1,72	1,84	2,55	0,2646	27%	0,1436
2	12,0	2,64	0,95	1,72	1,84	1,22	0,2536	9%	0,1078
2	7,0	2,64	0,95	1,72	1,84	15,00	0,6749	28%	0,2125
2	7,0	2,64	0,95	1,72	1,84	9,60	0,5547	22%	0,2119
2	6,5	2,64	0,95	1,72	1,84	12,95	0,4052	31%	0,1769
2	10,0	2,64	0,95	1,72	1,84	1,06	0,2764	13%	0,1442
2	15,0	2,64	0,95	1,72	1,84	1,36	0,2052	8%	0,0791
2	10,0	2,64	0,95	1,72	1,84	1,99	0,2818	9%	0,1196
2	16,0	2,64	0,95	1,72	1,84	1,70	0,2169	9%	0,0740
2	17,0	2,64	0,95	1,72	1,84	0,70	0,1787	19%	0,0923
3	10,0	3,34	1,27	1,77	1,15	5,21	0,4462	10%	0,1538
3	9,9	3,34	1,27	1,77	1,15	4,19	0,3553	23%	0,1955
3	5,7	3,34	1,27	1,77	1,15	13,17	0,5287	33%	0,3259
3	6,8	3,34	1,27	1,77	1,15	13,54	0,4737	27%	0,2387
3	18,0	3,34	1,27	1,77	1,15	1,12	0,4895	30%	0,1658
3	14,0	3,34	1,27	1,77	1,15	1,95	0,3025	21%	0,1443
4	18,0	2,30	1,47	1,21	4,72	0,96	0,5694	24%	0,1917
4	13,0	2,30	1,47	1,21	4,72	0,89	0,3580	6%	0,1095
4	12,5	2,30	1,47	1,21	4,72	0,38	0,4644	6%	0,1219
4	10,0	2,30	1,47	1,21	4,72	2,00	0,7413	18%	0,1855
5	10,5	2,58	0,86	2,00	5,71	1,28	0,6135	7%	0,1648
5	12,0	2,58	0,86	2,00	5,71	2,90	0,7104	13%	0,2300
5	30,0	2,58	0,86	2,00	5,71	1,00	0,5651	10%	0,1594
5	6,0	2,58	0,86	2,00	5,71	2,30	1,4165	19%	0,4193

**Tabela 5.5** - Resumo da estimativa individual do parâmetro  $b$

Condutor	$b$ (m/s <sup>2</sup> )	RMSe	RMSPe	GEH
1	6,93	0,49	23%	0,24
2	2,62	0,34	18%	0,16
3	4,70	0,40	17%	0,17
4	1,00	0,53	14%	0,15
5	1,57	0,69	11%	0,20

## 5.2.4 Resultados

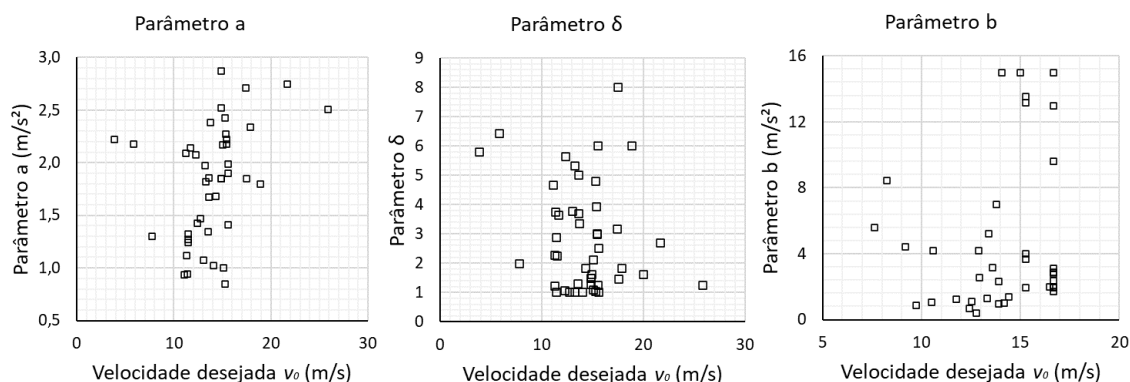
A Tabela 5.6 compila a calibração individual e sequencial de parâmetros dos cinco condutores observados.

**Tabela 5.6** – Estimativas individuais

Condutor	$s_0$ (m)	$T$ (s)	$a$ (m/s <sup>2</sup> )	$\delta$	$b$ (m/s <sup>2</sup> )
1	3,248	1,594	1,860	3,605	6,93
2	2,637	0,945	1,716	1,844	2,62
3	3,338	1,275	1,769	1,150	4,70
4	2,302	1,473	1,205	4,717	1,00
5	2,584	0,860	2,001	5,707	1,57

As calibrações em regime estacionário apresentaram piores índices de desempenho em detrimento das demais calibrações, em parte pelo fato dos dados reportarem a fluxo urbano e não fluxo livre. Com efeito, as manobras de aceleração e desaceleração foram efetuadas numa via arterial na periferia da cidade em ambiente controlado, não perturbadas por outros veículos ou pedestres.

Como premissa do modelo, os parâmetros representam aspectos comportamentais da condução e não variam com o cenário, seja conduzindo em via arterial, ou via local. No trajeto em análise há trechos em vias arteriais e vias locais e por isso os dados possuem variadas velocidades desejadas, o que possibilitou verificar a independência dos parâmetros relativamente à velocidade (Figura 5.7).



**Figura 5.7** - Independência dos parâmetros a velocidade (estimativa individual)

### 5.3 Otimização simultânea

A calibração individual e sequencial descrita na secção anterior permitiu identificar estimativas para os diversos parâmetros do IDM em situações de condução relativamente controladas, no pressuposto de que os parâmetros comportamentais dos condutores são constantes e generalizáveis. Contudo, é reconhecido que o processo de condução real em meio urbano é especialmente complexo, pelo que é expectável que existam combinações de parâmetros que repliquem com mais precisão o comportamento dos condutores neste tipo de ambiente rodoviário. Assim, nesta secção procura-se calibrar o modelo para as condições reais de condução em meio urbano, tendo por base os resultados obtidos na secção anterior.

Para calibração por otimização simultânea dos parâmetros foram seleccionados 20 trechos, 4 de cada condutor, contendo entre 14 e 72 segundos, do trajeto da coleta de dados em fluxo urbano, que correspondessem a condução dos veículos em sequência.

#### 5.3.1 Domínio de otimização

Para que os parâmetros não sejam calibrados em valores não realísticos é necessário definir qual o domínio aceitável para que a função faça a otimização.

Os limites de cada parâmetros foram seleccionados com base em suas estimativas individuais, constantes na Tabela 5.7. Ao parâmetro  $b$  foi imposto um limite máximo de  $8 \text{ m/s}^2$ , pois na calibração individual os máximos alcançaram valores irrealistas que poderiam comprometer a otimização simultânea.

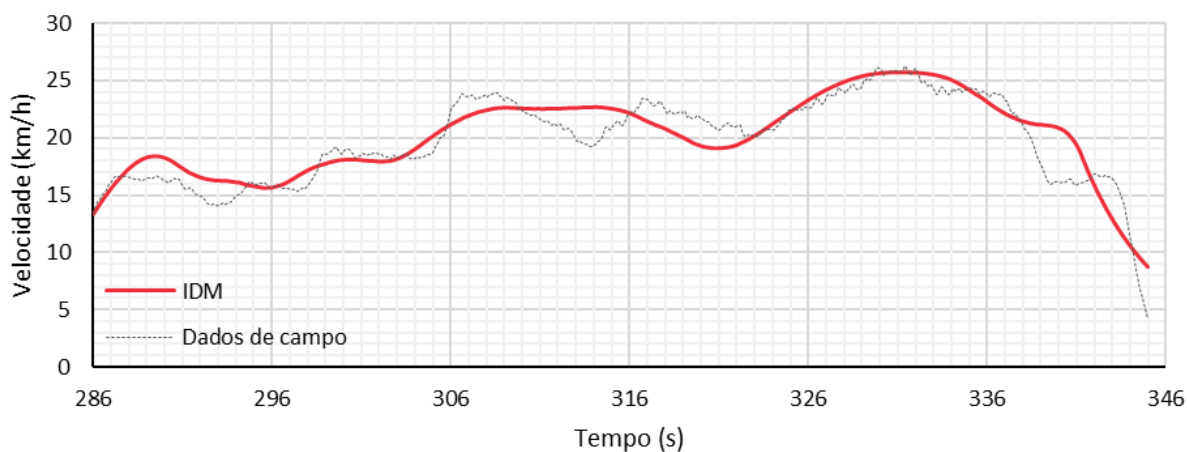
**Tabela 5.7** - Domínio de otimização

Condutor	$s_0$ (m)		$T$ (s)		$a$ (m/s <sup>2</sup> )		$\delta$		$b$ (m/s <sup>2</sup> )	
	Mín.	Máx.	Mín.	Máx.	Mín.	Máx.	Mín.	Máx.	Mín.	Máx.
1	2,30	4,70	1,20	2,20	1,15	2,10	1,03	8,00	4,28	8,00
2	2,50	4,00	0,70	1,10	1,17	2,51	1,28	3,93	1,32	8,00
3	2,20	4,20	1,10	1,60	1,23	3,14	1,00	1,45	1,48	8,00
4	1,00	2,90	1,20	1,90	0,84	2,40	1,00	6,00	0,38	8,00
5	1,30	3,70	0,60	1,30	1,21	2,40	1,00	6,42	1,00	8,00

A estimativa inicial da calibração, fator importante para o bom funcionamento da otimização, foi definida com os parâmetros obtidos na estimativa individual (Tabela 5.6).

### 5.3.2 Resultados

Com limites e estimativas iniciais definidas, a otimização simultânea foi executada pela função `fmincon` em MATLAB. A Figura 5.8 apresenta gráfico tempo-velocidade de um dos trechos em análise. A Tabela 5.8 apresenta todos os eventos de simulação e a Tabela 5.9 resume os parâmetros obtidos na calibração.



**Figura 5.8** - Gráfico tempo - velocidade de um dos trechos de otimização simultânea dos parâmetros

**Tabela 5.8** - Otimização simultânea dos parâmetros

Identificação		Parâmetros					Indicadores de desempenho		
Condutor	Duração (s)	$a$ (m/s <sup>2</sup> )	$b$ (m/s <sup>2</sup> )	$\delta$	$T$ (s)	$s_0$ (m)	RMSE	RMSPE	GEH
1	48,0	2,06	6,26	7,33	1,70	4,69	1,0463	10%	0,2439
1	14,0	1,87	5,79	8,00	1,75	2,30	0,1754	2%	0,0402
1	21,0	1,15	6,28	3,70	1,69	2,30	0,7685	7%	0,1866
1	37,0	2,06	6,14	4,12	1,70	3,43	1,3002	11%	0,2701
2	52,0	1,94	3,05	1,28	0,90	4,00	0,6027	6%	0,1404
2	34,0	2,45	3,67	1,28	0,90	4,00	0,8438	7%	0,2078
2	23,0	1,30	3,36	3,93	0,90	4,00	0,7842	9%	0,2259
2	34,0	2,51	4,66	3,93	0,90	4,00	1,1985	9%	0,2541
3	43,0	3,12	4,74	1,44	1,35	4,05	1,2575	12%	0,2452
3	47,0	2,26	4,71	1,45	1,33	3,06	0,5745	7%	0,1681
3	72,0	3,14	8,00	1,00	1,60	4,20	0,3820	6%	0,1222
3	63,0	1,91	5,76	1,08	1,57	4,10	1,0890	16%	0,3088
4	53,0	1,32	3,68	1,51	1,55	1,07	0,6218	6%	0,1668
4	30,0	1,16	8,00	4,87	1,90	2,90	0,5877	10%	0,1683
4	42,0	2,40	4,64	3,65	1,79	2,87	2,0830	18%	0,5274
4	31,0	2,40	4,03	1,77	1,55	2,88	1,1268	8%	0,2548
5	59,0	1,91	2,95	1,16	0,83	3,70	0,4467	11%	0,1517
5	47,0	2,40	3,43	2,33	0,94	1,31	1,4007	14%	0,3076
5	31,0	2,04	4,50	4,19	0,95	3,59	0,7528	9%	0,1961
5	31,0	2,40	3,93	2,74	0,95	3,70	0,9524	6%	0,2031

**Tabela 5.9** - Resumo da otimização simultânea dos parâmetros

Condutor	$a$ (m/s <sup>2</sup> )	$b$ (m/s <sup>2</sup> )	$\delta$	$T$ (s)	$s_0$ (m)	RMSe	RMSPe	GEH
1	1,88	6,17	5,78	1,70	3,61	0,97	9%	0,22
2	2,09	3,63	2,34	0,90	4,00	0,83	7%	0,20
3	2,61	6,06	1,20	1,49	3,90	0,79	11%	0,21
4	1,79	4,84	2,78	1,68	2,27	1,11	11%	0,28
5	2,16	3,55	2,34	0,91	3,01	0,86	11%	0,21

Um bom cenário de calibração, se comparado a calibrações realizadas por outros autores em modelos *car-following*, onde, utilizando o mesmo indicador (RMSe), atingiram valores entre 0,2 e 2,09 m/s (Gunter et al., 2020; Huang et al., 2018; van Hinsbergen et al., 2015; Vieira da Rocha et al., 2015; Montanino et al., 2012).

Foi possível notar, tal como na estimativa individual, a independência dos parâmetros relativamente à velocidade. A Figura 5.9, mostra a dispersão dos parâmetros em relação à velocidade desejada  $v_0$ .




Figura 5.9 - Independência dos parâmetros a velocidade (otimização simultânea)

## 5.4 Validação

Para validação, foram utilizados dados de campo em trajeto idêntico aos utilizados na calibração, os trechos de “volta” na coleta em fluxo urbano. Foram selecionados 20 trechos, 4 de cada condutor, entre 18 e 105 segundos, para avaliar o desempenho do modelo com a utilização dos parâmetros calibrados.

A validação se deu através de duas etapas, num primeiro momento avaliando a replicabilidade de entre trechos distintos e no segundo, utilizando valores médios obtidos na calibração.

### 5.4.1 Validação entre trechos distintos

A fim de avaliar a transferibilidade dos parâmetros calibrados, foi assumido um conjunto de cenários (baseado nos trechos definidos na coleta de dados, vide item (4.3) em que os parâmetros ótimos da estimativa individual (Tabela 5.6) e os da otimização simultânea de cada circuito na ida (Tabela 5.8), foram utilizados para modelar os circuitos volta (por exemplo, a simulação do trecho 3-4 usando os parâmetros ótimos da otimização simultânea do trecho 4-5

resultaram em um valor RMSe de 1,92 e valor 0,79, quando utilizados os parâmetros da estimativa individual). As Tabela 5.10 a Tabela 5.14 apresentam os dados obtidos no procedimento para cada condutor.

**Tabela 5.10** - RMSe para replicabilidade dos parâmetros calibrados do condutor 1 em diferentes circuitos

Trecho	RMSe				
	Estimativa individual	Otimização Simultânea			
		1-2	2-3	3-4	4-5
1-2	0,78	0,79	0,85	0,86	1,26
2-3	1,39	1,40	1,53	1,38	1,96
3-4	0,79	1,15	1,55	1,05	1,92
4-5	2,23	2,02	1,85	2,10	2,71

**Tabela 5.11** - RMSe para replicabilidade dos parâmetros calibrados do condutor 2 em diferentes circuitos

Trecho	RMSe				
	Estimativa individual	Otimização Simultânea			
		1-2	2-3	3-4	4-5
1-2	0,70	0,73	0,73	0,65	0,87
2-3	1,66	1,49	1,23	2,04	2,09
3-4	0,72	0,65	0,92	1,44	1,84
4-5	1,66	1,95	1,21	2,54	1,21

**Tabela 5.12** - RMSe para replicabilidade dos parâmetros calibrados do condutor 3 em diferentes circuitos

Trecho	RMSe				
	Estimativa individual	Otimização Simultânea			
		1-2	2-3	3-4	4-5
1-2	1,53	0,77	0,75	0,73	2,69
2-3	0,38	0,60	0,65	1,00	0,34
3-4	-	-	-	-	-
4-5	1,47	1,05	0,98	1,12	1,31

**Tabela 5.13** - RMSe para replicabilidade dos parâmetros calibrados do condutor 4 em diferentes circuitos

Trecho	RMSe				
	Estimativa individual	Otimização Simultânea			
		1-2	2-3	3-4	4-5
1-2	1,46	1,38	1,33	1,46	1,35
2-3	0,73	0,90	0,97	0,69	1,16
3-4	1,06	0,59	1,28	1,16	0,75
4-5	3,09	1,90	3,24	2,90	2,01

**Tabela 5.14** - RMSe para replicabilidade dos parâmetros calibrados do condutor 5 em diferentes circuitos

Trecho	RMSe				
	Estimativa individual	Otimização Simultânea			
		1-2	2-3	3-4	4-5
1-2	0,87	0,81	-	1,12	0,97
2-3	0,77	1,00	-	0,84	0,80
3-4	1,43	1,41	-	1,06	0,84
4-5	1,48	1,49	-	1,62	1,49

Apesar dos indicadores mostrarem uma calibração adequada em todos os circuitos, não se pode admitir que uma metodologia é melhor que outra para replicabilidade dos dados em outros circuitos.

Por várias vezes a estimativa individual obteve melhor desempenho que a otimização simultânea, tanto quando na aplicação de otimização simultânea em trecho idêntico de volta, quanto para trechos distintos, como nas verificações dos trechos 3-4 do condutor 1 e 2-3 do condutor 5, onde a estimativa individual apresentou RMSe 0,72 e 0,77, respectivamente. O inverso aconteceu com a otimização simultânea, nos trechos 4-5 do condutor 3 e 3-4 do condutor 5.

### 5.4.2 Validação com valores médios

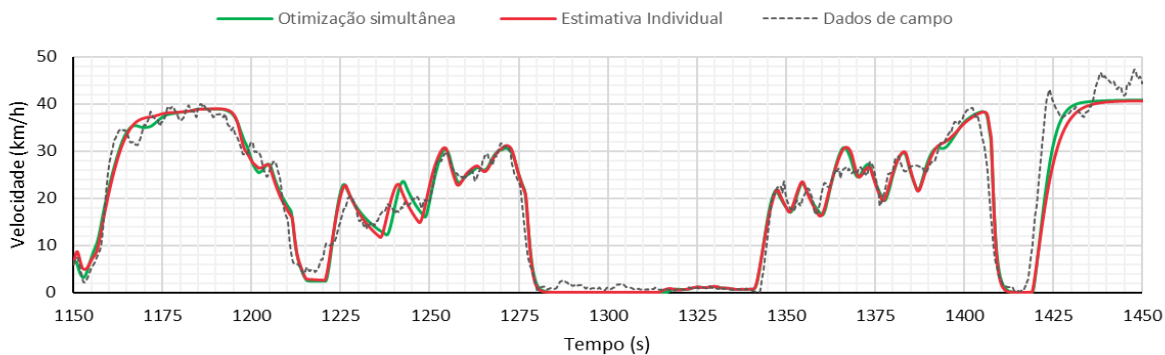
A Tabela 5.15 contém as medidas de desempenho obtidas na validação para as duas metodologias de calibração, através dos dados agregados obtidos nos tópicos anteriores (Tabela 5.6 e Tabela 5.9).

**Tabela 5.15** - Replicabilidade dos parâmetros calibrados

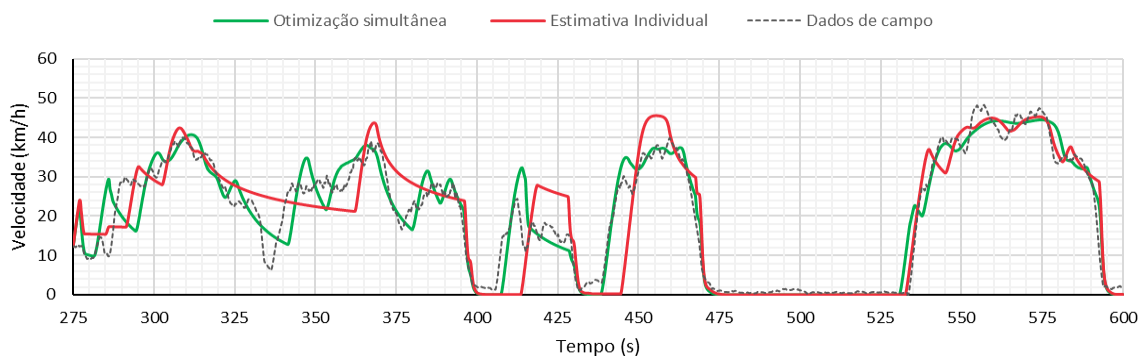
Calibração	Condutor	RMSE	RMSPE	GEH
Estimativa individual dos parâmetros	1	1,34	17%	0,35
	2	1,46	24%	0,41
	3	1,85	17%	0,39
	4	1,36	17%	0,30
	5	1,19	22%	0,31
Otimização simultânea dos parâmetros	1	1,31	17%	0,34
	2	1,00	20%	0,29
	3	1,04	10%	0,23
	4	1,42	14%	0,35
	5	0,94	14%	0,24

Novamente, as duas metodologias se mostraram satisfatórias, com um desempenho ligeiramente melhor para a calibração por otimização simultânea. Pouco percebida para o

condutor 2 (Figura 5.10), porém, mais visível no condutor 5 (Figura 5.11). As figuras a seguir mostram o percurso dos dois condutores entre os pontos 2 e 4 da coleta de dados, e não correspondem, em sua totalidade, o trecho utilizado para calibração, mas sim a aplicação dos parâmetros calibrados, com os dados de percurso do veículo líder.



**Figura 5.10** - Replicabilidade dos parâmetros calibrados para o condutor 2



**Figura 5.11** - Replicabilidade dos parâmetros calibrados para o condutor 5

## 6. Conclusões gerais e trabalhos futuros

### 6.1 Síntese e conclusões gerais

Esta dissertação teve por objetivo criar e analisar as alternativas para calibrar e validar um modelo *car-following*, nomeadamente o Intelligent Driver Model (IDM). Nos pontos seguintes sumariza-se o trabalho desenvolvido e apresentam-se as conclusões mais específicas de cada capítulo.

#### Capítulo 2

Efetua-se uma pesquisa bibliográfica sobre os modelos *car-following*, desde o surgimento até a formulação de modelos completos e muito utilizados em aplicações de microsimulação, como o modelo de Wiedemann, utilizado no VISSIM, e o de GIPPS, utilizado no AIMSUN. Sendo possível, notar a evolução ao longo do tempo.

Atualmente, existe uma grande variedade de modelos *car-following*. Porém, a lógica utilizada por estes, sempre é igual a alguma utilizada nos modelos apresentados.

#### Capítulo 3

Este capítulo se dedica a explicar o Intelligent Driver Model, a premissas e a descrição de estratégias empregadas. O modelo mostra-se completo, sendo possível descrever todas as situações em *car-following*.

#### Capítulo 4

Apresentada a metodologia de coleta de dados através de veículo instrumentado e o tratamento realizado para utilização adequada das informações.

Comprovou-se a eficiência da metodologia para coleta de dados, simples e de baixo custo, necessitando apenas de um *datallogger* e uma pistola LIDAR (custos <2500€), se revelando prático e muito preciso, o que constitui uma vantagem relativamente a outros métodos frequentemente referidos na literatura.

#### Capítulo 5

No início do capítulo, foi apresentada uma revisão bibliográfica acerca de calibração de modelos *car-following*, onde também foram definidos: *i*) o RMSe, como indicador de desempenho para as análises, por se tratar do indicador mais utilizado por trabalhos de calibração de modelos microscópicos e ser mais sensível a pares de pequenos valores; *ii*) a função *fmincon* do Matlab para execução das otimizações, que permitiu soluções precisas muito rapidamente.

Posteriormente efetuou-se a calibração através de duas metodologias: *i*) estimativa individual dos parâmetros, que busca obter os parâmetros relativos a cada condutor na observância de momentos de condução onde os mesmos são mais significantes e a influência dos demais parâmetros é diminuta ou pode mesmo ser descartada; *ii*) otimização simultânea dos parâmetros, que busca, através de dados de condução em meio urbano, calibrar todos os parâmetros ao mesmo tempo.

As duas metodologias de calibração se mostraram satisfatórias, sendo que a calibração por otimização simultânea obteve desempenho ligeiramente melhor na replicabilidade em percurso desconhecido.

A independência dos parâmetros dos condutores ao ambiente rodoviário foi comprovada, confirmando a premissa do modelo, e indicando a facilidade de emprego dos parâmetros em cenários distintos do calibrado.

Os resultados mostram a eficácia das metodologias utilizadas e representam diferentes estilos de condutores de Portugal. No entanto, é necessário salientar que não são representativos de uma população específica de condutores, de Viseu ou de Portugal, já que para tal seria necessário estratificar devidamente a amostra de condutores e veículos para essa população.

## 6.2 Desenvolvimentos futuros

Há muitas dúvidas sobre o processo de calibração de modelos *car-following* e um número razoável de trabalhos se dedicam a estudar e verificar distintas metodologias empregadas em variados modelos. Durante a execução desse trabalho uma serie das alternativas foram levantadas para execução da calibração, como:

- Testar o processo de calibração com outras medidas de desempenho, para avaliar o comportamento dos parâmetros, precisão e replicabilidade;
- Testar o funcionamento da calibração com anexação das medidas de desempenho a outros parâmetros, por exemplo, o espaçamento;
- Avaliar metodologias alternativas para a determinação dos limites de otimização para calibração;
- Desenvolvimento de aplicação para facilitar a calibração com dados de campo;
- Avaliar a efetiva independência dos parâmetros, comparando ambientes rodoviários muito distintos (urbano vs interurbano);

Outro aspecto importante é que os condutores sabiam que estavam sendo monitorados, o que afeta o comportamento. Seria de grande valor a estruturação de uma coleta de dados com condutores desavisados (estudo naturalístico), para notar possíveis alterações no comportamento.

# REFERÊNCIAS

- AIMSUN. (2022). *Simulating Pedestrians—Aimsun Next Users Manual*. [https://docs.aimsun.com/next/22.0.1/Tutorials/5\\_Pedestrian/5\\_Pedestrian.html](https://docs.aimsun.com/next/22.0.1/Tutorials/5_Pedestrian/5_Pedestrian.html)
- Ansari, S., Akhdar, F., Mandoorah, M., & Moutaery, K. (2000). **Causes and effects of road traffic accidents in Saudi Arabia**. *Public Health*, 114(1), 37–39. <https://doi.org/10.1038/sj.ph.1900610>
- Barceló, J. (2010). **Models, Traffic Models, Simulation, and Traffic Simulation**. Em J. Barceló (Org.), *Fundamentals of Traffic Simulation* (Vol. 145, p. 1–62). Springer New York. [https://doi.org/10.1007/978-1-4419-6142-6\\_1](https://doi.org/10.1007/978-1-4419-6142-6_1)
- Berghaus, M., Kallo, E., & Oeser, M. (2021). **Car-Following Model Calibration Based on Driving Simulator Data to Study Driver Characteristics and to Investigate Model Validity in Extreme Traffic Situations**. *Transportation Research Record*, 2675(12), 1214–1232. <https://doi.org/10.1177/03611981211032650>
- Brackstone, M., Sultan, B., & McDonald, M. (2002). **Motorway driver behaviour: Studies on car following**. *Transportation Research Part F: Traffic Psychology and Behaviour*, 5(1), 31–46. [https://doi.org/10.1016/S1369-8478\(02\)00004-9](https://doi.org/10.1016/S1369-8478(02)00004-9)
- Chandler, R. E., Herman, R., & Montroll, E. W. (1958). **Traffic Dynamics: Studies in Car Following**. *Operations Research*, 6(2), 165–184. <https://doi.org/10.1287/opre.6.2.165>
- Ciuffo, B., Punzo, V., & Montanino, M. (2012, abril 4). *The Calibration of Traffic Simulation Models: Report on the assessment of different Goodness of Fit measures and Optimization Algorithms MULTITUDE Project – COST Action TU0903*. JRC Publications Repository. <https://doi.org/10.2788/7975>
- Coifman, B., & Li, L. (2017). **A critical evaluation of the Next Generation Simulation (NGSIM) vehicle trajectory dataset**. *Transportation Research Part B: Methodological*, 105, 362–377. <https://doi.org/10.1016/j.trb.2017.09.018>
- Edie, L. C. (1961). **Car-Following and Steady-State Theory for Noncongested Traffic**. *Operations Research*, 9(1), 66–76. <https://doi.org/10.1287/opre.9.1.66>

- Gazis, D. C., Herman, R., & Potts, R. B. (1959). **Car-Following Theory of Steady-State Traffic Flow.** *Operations Research*, 7(4), 499–505. <https://doi.org/10.1287/opre.7.4.499>
- Gazis, D. C., Herman, R., & Rothery, R. W. (1961). **Nonlinear Follow-the-Leader Models of Traffic Flow.** *Operations Research*, 9(4), 545–567. <https://doi.org/10.1287/opre.9.4.545>
- Gipps, P. G. (1976). **COMPUTER PROGRAM MULTSIM FOR SIMULATING OUTPUT FROM VEHICLE DETECTORS ON A MULTI-LANE SIGNAL-CONTROLLED ROAD.** *Publication of: Newcastle-Upon-Tyne University, England*, 20, Article Monograph. <https://trid.trb.org/view/59591>
- Gipps, P. G. (1981). **A behavioural car-following model for computer simulation.** *Transportation Research Part B: Methodological*, 15(2), 105–111. [https://doi.org/10.1016/0191-2615\(81\)90037-0](https://doi.org/10.1016/0191-2615(81)90037-0)
- Greenshields, B. D., Bibbins, J. R., Channing, W. S., & Miller, H. H. (1935). **A STUDY OF TRAFFIC CAPACITY.** *Highway Research Board Proceedings*, 14. <https://trid.trb.org/view/120649>
- Gunter, G., Janssen, C., Barbour, W., Stern, R. E., & Work, D. B. (2020). **Model-Based String Stability of Adaptive Cruise Control Systems Using Field Data.** *IEEE Transactions on Intelligent Vehicles*, 5(1), 90–99. <https://doi.org/10.1109/TIV.2019.2955368>
- Herman, R., & Potts, R. B. (1959). **SINGLE LANE TRAFFIC THEORY AND EXPERIMENT.** *Symposium on Theory of Traffic Flow*, 120–146.
- Huang, X., Sun, J., & Sun, J. (2018). **A car-following model considering asymmetric driving behavior based on long short-term memory neural networks.** *Transportation Research Part C: Emerging Technologies*, 95, 346–362. <https://doi.org/10.1016/j.trc.2018.07.022>
- Krajewski, R., Bock, J., Kloeker, L., & Eckstein, L. (2018). **The highD Dataset: A Drone Dataset of Naturalistic Vehicle Trajectories on German Highways for Validation of Highly Automated Driving Systems** (arXiv:1810.05642). arXiv. <https://doi.org/10.48550/arXiv.1810.05642>
- Kyriakidis, M., Happee, R., & de Winter, J. C. F. (2015). **Public opinion on automated driving: Results of an international questionnaire among 5000 respondents.** *Transportation Research Part F: Traffic Psychology and Behaviour*, 32, 127–140. <https://doi.org/10.1016/j.trf.2015.04.014>

- 
- Lee, G. (1966). **A Generalization of Linear Car-Following Theory**. *Operations Research*, 14(4), 595–606. <https://doi.org/10.1287/opre.14.4.595>
- Li, Y., & Sun, D. (2012). **Microscopic car-following model for the traffic flow: The state of the art**. *Journal of Control Theory and Applications*, 10. <https://doi.org/10.1007/s11768-012-9221-z>
- Michaels, R. M. (1965). **Perceptual factors in car following**. *Proceedings of the Second International Symposium on the Theory of Traffic Flow, London 1963.*, 44–59.
- Montanino, M., Ciuffo, B., & Punzo, V. (2012). **Calibration of microscopic traffic flow models against time-series data**. *2012 15th International IEEE Conference on Intelligent Transportation Systems*, 108–114. <https://doi.org/10.1109/ITSC.2012.6338686>
- Newell, G. F. (1961). **Nonlinear Effects in the Dynamics of Car Following**. *Operations Research*, 9(2), 209–229. <https://doi.org/10.1287/opre.9.2.209>
- Olstam, J. J., & Tapani, A. (2004). **COMPARISON OF CAR-FOLLOWING MODELS**. *Publication of: Swedish National Road and Transport Research Institute*, Article VTI report 960A. <https://trid.trb.org/view/705391>
- Ossen, S., & Hoogendoorn, S. P. (2005). **Car-Following Behavior Analysis from Microscopic Trajectory Data**. *Transportation Research Record: Journal of the Transportation Research Board*, 1934(1), 13–21. <https://doi.org/10.1177/0361198105193400102>
- Pipes, L. A. (1953). **An Operational Analysis of Traffic Dynamics**. *Journal of Applied Physics*, 24(3), 274–281. <https://doi.org/10.1063/1.1721265>
- Prentkovskis, O., Sokolovskij, E., & Bartulis, V. (2010). **Investigating traffic accidents: A collision of two motor vehicles**. *Transport*, 25(2), 105–115. <https://doi.org/10.3846/transport.2010.14>
- Punzo, V., & Tripodi, A. (2007). **Steady-State Solutions and Multiclass Calibration of Gipps Microscopic Traffic Flow Model**. *Transportation Research Record: Journal of the Transportation Research Board*, 1999(1), 104–114. <https://doi.org/10.3141/1999-12>
- Punzo, V., Zheng, Z., & Montanino, M. (2021). **About calibration of car-following dynamics of automated and human-driven vehicles: Methodology, guidelines and codes**.
-

- Transportation Research Part C: Emerging Technologies*, 128, 103165.  
<https://doi.org/10.1016/j.trc.2021.103165>
- Ranjitkar, P., Nakatsuji, T., & Kawamura, A. (2005). **Experimental Analysis of Car-Following Dynamics and Traffic Stability**. *Transportation Research Record: Journal of the Transportation Research Board*, 1934(1), 22–32.  
<https://doi.org/10.1177/0361198105193400103>
- Raslavičius, L., Keršys, A., Pukalskas, S., Bazaras, J., Jablonskytė, J., Ilgakojoytė-Bazarienė, J., & Makaras, R. (2015). **City transport analysis using the General Motors (GM) microscopic model**. *Public Transport*, 7(2), 159–183. <https://doi.org/10.1007/s12469-014-0094-z>
- Reuschel, A. (1950). **Fahrzeugbewegungen in der Kolonne**. *Österreichisches Ingenieur-Archiv*, 4, 193–215.
- Sharma, A., Zheng, Z., & Bhaskar, A. (2019). **Is more always better? The impact of vehicular trajectory completeness on car-following model calibration and validation**. *Transportation Research Part B: Methodological*, 120, 49–75.  
<https://doi.org/10.1016/j.trb.2018.12.016>
- Touahmia, M. (2018). **Identification of Risk Factors Influencing Road Traffic Accidents**. *Engineering, Technology & Applied Science Research*, 8(1), 2417–2421.  
<https://doi.org/10.48084/etasr.1615>
- Treat, J. R., Tumbas, N. S., McDonald, S. T., Shinar, D., Hume, R. D., Mayer, R. E., Stansifer, R. L., & Castellan, N. J. (1979). *Tri-level study of the causes of traffic accidents: Final report. Executive summary*. [Technical Report]. Indiana University, Bloomington, Institute for Research in Public Safety.  
<http://deepblue.lib.umich.edu/handle/2027.42/64993>
- Treiber, M., Hennecke, A., & Helbing, D. (2000). **Congested Traffic States in Empirical Observations and Microscopic Simulations**. *Physical Review E*, 62(2), 1805–1824.  
<https://doi.org/10.1103/PhysRevE.62.1805>
- Treiber, M., & Kesting, A. (2013). *Traffic Flow Dynamics*. Springer.  
<https://link.springer.com/book/10.1007/978-3-642-32460-4>
- UK DOT. (1996). *Traffic appraisal in urban areas: Vol. Volume 12*. Department of Transport.  
<https://assets.highwaysengland.co.uk/roads/road-projects/a2-bean-ebbsfleet-junction-improvements/Orders/I.8+DMRB+Part+1+Traffic+Appraisal.pdf>

- 
- van Hinsbergen, C. P. I. J., Schakel, W. J., Knoop, V. L., van Lint, J. W. C., & Hoogendoorn, S. P. (2015). **A general framework for calibrating and comparing car-following models.** *Transportmetrica A: Transport Science*, 11(5), 420–440. <https://doi.org/10.1080/23249935.2015.1006157>
- Vasconcelos, A. (2004). **MODELOS DE ATRIBUIÇÃO/SIMULAÇÃO DE TRÁFEGO: O IMPACTO NA QUALIDADE DOS RESULTADOS DE ERROS NO PROCESSO DE MODELAÇÃO.** Dissertação de mestrado apresentada ao Departamento de Engenharia Civil da Faculdade de Ciências e Tecnologia da Universidade de Coimbra, Coimbra, Portugal.
- Vasconcelos, A. (2014). **Avaliação do desempenho operacional de rotundas: Modelos e aplicações.** Tese de Doutorado apresentada ao Departamento de Engenharia Civil da Faculdade de Ciências e Tecnologia da Universidade de Coimbra, Coimbra, Portugal.
- Vasconcelos, A. L. P., Seco, Á. J. M., & Silva, A. M. C. B. (2013). **Comparison of Procedures to Estimate Critical Headways at Roundabouts.** *Promet - Traffic & Transportation*, 25(1), 43–53. <https://doi.org/10.7307/ptt.v25i1.1246>
- Vasconcelos, L., Seco, Á., & Silva, A. B. (2014). **Hybrid Calibration of Microscopic Simulation Models.** Em J. F. de Sousa & R. Rossi (Orgs.), *Computer-based Modelling and Optimization in Transportation* (Vol. 262, p. 307–320). Springer International Publishing. [https://doi.org/10.1007/978-3-319-04630-3\\_23](https://doi.org/10.1007/978-3-319-04630-3_23)
- Vieira da Rocha, T., Leclercq, L., Montanino, M., Parzani, C., Punzo, V., Ciuffo, B., & Villegas, D. (2015). **Does traffic-related calibration of car-following models provide accurate estimations of vehicle emissions?** *Transportation Research Part D: Transport and Environment*, 34, 267–280. <https://doi.org/10.1016/j.trd.2014.11.006>
- Wangdi, C., Gurung, M. S., Duba, T., Wilkinson, E., Tun, Z. M., & Tripathy, J. P. (2018). **Burden, pattern and causes of road traffic accidents in Bhutan, 2013–2014: A police record review.** *International Journal of Injury Control and Safety Promotion*, 25(1), 65–69. <https://doi.org/10.1080/17457300.2017.1341930>
- WHO, W. H. O. (2021). **Global Plan: Decade of action for road safety 2021-2030.** [https://cdn.who.int/media/docs/default-source/documents/health-topics/road-traffic-injuries/global-plan-for-road-safety.pdf?sfvrsn=65cf34c8\\_33&download=true](https://cdn.who.int/media/docs/default-source/documents/health-topics/road-traffic-injuries/global-plan-for-road-safety.pdf?sfvrsn=65cf34c8_33&download=true)
- Wiedemann, R. (1974). **SIMULATION DES STRASSENVERKEHRSFLUSSES.** <https://trid.trb.org/view/596235>
-

- Wiedemann, R., & Reiter, U. (1992). **Microscopic traffic simulation: The simulation system MISSION, background and actual state.** *CEC project ICARUS (VI052) final report*, 2.
- Wilson, R. E. (2001). **An analysis of Gipps's car-following model of highway traffic.** *IMA Journal of Applied Mathematics*, 66(5), 509–537. <https://doi.org/10.1093/imamat/66.5.509>
- Zhang, D., Li, K., & Wang, J. (2012). **A curving ACC system with coordination control of longitudinal car-following and lateral stability.** *Vehicle System Dynamics*, 50(7), 1085–1102. <https://doi.org/10.1080/00423114.2012.656654>