

## CALIBRAÇÃO DE MODELOS FLUXO-VELOCIDADE-DENSIDADE A PARTIR DE BASES DE DADOS MUITO GRANDES

**Juliana Mitsuyama Cardoso**

**Lucas Assirati**

**José Reynaldo Setti**

Universidade de São Paulo

Escola de Engenharia de São Carlos

### RESUMO

Este trabalho apresenta um método para ajuste de modelos de fluxo de tráfego usando bancos de dados de tráfego muito grandes. O método proposto consiste de quatro etapas: (1) um tratamento inicial para eliminação de dados espúrios e uniformização da informação para toda a faixa de densidades; (2) um primeiro ajuste do modelo, baseado na minimização da soma dos erros quadráticos ortogonais; (3) uma segunda filtragem dos dados, para eliminar *outliers* que sobreviveram ao tratamento inicial; e (4) um segundo ajuste do modelo. O método proposto foi testado com cerca de 104 mil observações coletadas por um sensor automático instalado numa autoestrada. Foram testadas duas alternativas para buscar a solução ótima, um algoritmo *hill climbing* e um algoritmo genético. Os resultados obtidos mostram que o processo proposto é eficaz e independente do método de otimização usado.

### ABSTRACT

This paper describes a procedure for fitting traffic flow models using very large traffic databases. The proposed approach consists of four steps: (1) an initial treatment to eliminate inaccurate data and homogenize the information over the density range; (2) a first fitting of the model, based on the sum of squared orthogonal errors; (3) a second filter, to eliminate outliers that survived the initial data treatment; and (4) a second fitting of the model. The proposed approach was tested with 104 thousand observations collected by loop detectors placed in a freeway. Two alternative optimization techniques were tested to search for the best solution: a full hill climbing algorithm and a genetic algorithm. The results demonstrate the effectiveness of the proposed approach, which works well with both optimization techniques.

### 1. INTRODUÇÃO

Em análises de correntes de tráfego, corriqueiramente são utilizados dados coletados por sensores automáticos de tráfego (SAT) que, funcionando continuamente, podem acumular uma enorme quantidade de observações. No entanto, estes dados incluem ruídos que podem enviesar os modelos. Obras, acidentes, intempéries, defeitos nos sensores e incidentes que afetam o comportamento do fluxo de tráfego são condições anômalas que não representam a operação normal da via. Pode-se esperar que, numa base de dados muito grande (VLDB), cobrindo um período de vários anos, uma parcela não desprezível das observações inclui ruído.

Este estudo propõe um processo para calibração de modelos fluxo-velocidade-densidade utilizando uma quantidade muito grande de dados. O método proposto inclui um primeiro tratamento para uniformizar o volume de informações pela gama de densidades da corrente de tráfego e reduzir o ruído. Em seguida, faz-se a calibração do modelo por um processo de otimização em duas etapas, para eliminar o ruído que sobreviveu ao primeiro filtro. O processo proposto foi testado com duas técnicas de otimização: um algoritmo *hill climbing* (AHC) e um algoritmo genético (AG). O modelo escolhido para testar o processo foi o proposto por Van Aerde (Rakha, 2009), por ser um modelo bastante disseminado; qualquer outro modelo poderia ter sido usado.

Este texto está organizado da maneira como se segue: após esta introdução, apresenta-se uma breve revisão da literatura, seguida por uma descrição dos dados usados, do processo proposto e dos resultados obtidos. O trabalho finaliza-se com uma discussão dos resultados.

## 2. REVISÃO DA LITERATURA

Um modelo de tráfego descreve as relações macroscópicas entre fluxo ( $q$ ), velocidade ( $u$ ) e densidade ( $k$ ) (May, 1990), num sistema de equações consistindo de uma equação de continuidade  $\partial q / \partial x + \partial k / \partial t = 0$ , numa equação de estado  $q = u \cdot k$  e numa relação entre a velocidade e a densidade  $u = f(k)$  (Lu et al., 2010). A hipótese fundamental para a definição de um modelo é que, para cada local específico, existe uma relação única entre  $u$ ,  $k$ , e  $q$ , denominada diagrama fundamental, no qual residem todas as soluções para um modelo *steady-state* para essa corrente de tráfego (Kerner, 2004). As relações de tráfego são alvo de constantes estudos dado sua capacidade informacional quanto às características das vias e dos condutores.

Tais relações têm sido estudadas desde 1933 (Kühne, 2011), quando Greenshields publicou um artigo na *13th Annual Meeting of the Highway Research Board*, o precursor do TRB. Desde então foram desenvolvidos diversos outros modelos entre os quais os propostos por Greenberg (1959), Underwood (May, 1990), Drake (Lu et al., 2010), Pipes (Rakha e Crowther, 2003), o modelo usado no HCM (TRB, 2016) e, mais recentemente, o modelo de Van Aerde (Van Aerde e Rakha, 1995) e o *intelligent-driver model* (Treiber et al., 2000). O modelo de Greenshields é conhecido por seu caráter pioneiro e o modelo de Pipes é implementado em simuladores de tráfego (Rakha e Crowther, 2003).

O ajuste das funções que compõem o modelo de tráfego é feito a partir de dados coletados por sensores automáticos de tráfego, que fornecem medidas independentes de fluxo, velocidade e ocupância (da qual pode se estimada a densidade), às quais está associado um erro. Sabe-se que a regressão de uma variável dependente  $y$  em função de uma variável independente  $x$  tal que  $y = f_1(x)$  não produz a mesma relação que a regressão de  $x$  em função de  $y$  (Draper e Smith, 1980). Para evitar esse problema, numa regressão, deve-se definir claramente quais as variáveis independentes e quais as variáveis dependentes, uma vez que supõe-se que apenas a variável dependente contém um erro de medida – ou seja, a regressão  $u = f(k)$ , em que se admite que a densidade  $k$  é a variável explanatória (independente) e que a velocidade  $u$  é a variável dependente, a regressão minimiza apenas o erro ligado à estimativa da velocidade. Rakha e Arafteh (2010) demonstram que esse não é o caso dos modelos de tráfego, uma vez que não é possível definir claramente qual a variável independente, já que, dependendo da situação, qualquer uma das três variáveis pode ser o fator determinante para o comportamento do tráfego, e que as três variáveis trazem inerentemente um erro de medida.

Para evitar isso, Rakha e Arafteh (2010) propõem que o ajuste seja baseado numa regressão neutra, na qual se dispensa a determinação da variável dependente e o ajuste procura minimizar o erro quadrático ortogonal normalizado do diagrama fundamental do modelo escolhido, de tal forma que o modelo de otimização pode ser descrito como:

$$\text{minimizar } E = \sum_i \left\{ \left( \frac{u_i - \hat{u}_i}{\tilde{u}} \right)^2 + \left( \frac{q_i - \hat{q}_i}{\tilde{q}} \right)^2 + \left( \frac{k_i - \hat{k}_i}{\tilde{k}} \right)^2 \right\} \quad (1)$$

sujeito à

$$\hat{u}_i = f(\hat{k}_i) \quad \forall i, \quad (2)$$

$$\hat{q}_i = \hat{k}_i \times \hat{u}_i \quad \forall i, \quad (3)$$

$$\hat{q}_i, \hat{k}_i, \hat{u}_i \geq 0 \quad \forall i, \quad (4)$$

em que  $E$  é o erro quadrático ortogonal estimado;  $u_i$ ,  $q_i$  e  $k_i$  valores observados de velocidade,

fluxo e densidade para um evento  $i$ ;  $\hat{u}_i$ ,  $\hat{q}_i$  e  $\hat{k}_i$  são os valores estimados para velocidade, fluxo e densidade para um evento  $i$ ; e  $\tilde{u}$ ,  $\tilde{q}$  e  $\tilde{k}$  são os valores máximos observados para velocidade, fluxo e densidade. O método pode ser aplicado a qualquer modelo de tráfego (Rakha e Arafeh, 2010).

Em 1995, Van Aerde (Van Aerde e Rakha, 1995) propôs um modelo que combina os modelos de Pipes e Greenberg (Lu et al., 2010) e é capaz de representar os fluxos livre e congestionado através de uma única função matemática, sem que seja necessário estabelecer *breakpoints* que separem esses dois regimes (Rakha, 2009). Em função da sua estrutura matemática, foi demonstrado que esse modelo é capaz de representar adequadamente o comportamento da corrente de tráfego tanto em *freeways* como em rodovias de pista dupla ou mesmo em arteriais urbanas (Rakha e Crowther, 2003). Por sua versatilidade, o modelo de Van Aerde foi adotado pelo manual de capacidade alemão HBS – *Handbuch für die Bemessung von Straßenverkehrsanlagen* (FGSV, 2015).

O modelo para as relações entre fluxo ( $q$ ), velocidade ( $u$ ) e densidade ( $k$ ) de Van Aerde é baseado em quatro parâmetros: a velocidade de fluxo livre  $u_f$ , a velocidade na capacidade  $u_c$ , a capacidade  $q_c$ , e a densidade de congestionamento  $k_j$  (Rakha, 2009). Matematicamente, o modelo é expresso por:

$$q = u \cdot k \quad (5)$$

$$k = \frac{1}{c_1 + \frac{c_2}{u_f - u} + c_3 u} \quad (6)$$

em que  $c_1$  (km);  $c_2$  (km<sup>2</sup>/h); e  $c_3$  (h) são constantes calculadas por (Demarchi, 2003):

$$c_1 = \frac{u_f}{k_j u_c^2} (2u_c - u_f) \quad (7)$$

$$c_2 = \frac{u_f}{k_j u_c^2} (u_f - u_c)^2 \quad (8)$$

$$c_3 = \frac{1}{q_j} - \frac{u_f}{k_j u_c^2} \quad (9)$$

Van Aerde e Rakha (1995) propuseram que a calibração do modelo fosse feita através da minimização dos erros quadráticos ortogonais utilizando um algoritmo *hill climbing* (AHC) (uma técnica de otimização matemática que envolve um processo iterativo) para ajustar os parâmetros do modelo:  $u_f$ ,  $u_c$ ,  $k_j$ , e  $q_c$ . Rakha e Arafeh (2010) revisaram a abordagem de Van Aerde e Rakha (1995), propondo um ajuste multiestágio, não mais baseado num AHC.

Usualmente os modelos utilizam dados coletados automaticamente nas estações de monitoramento de tráfego (Hall et al., 1992). Contudo, o uso de dados coletados por sensores automáticos para a calibração desses modelos está ligado a uma série de problemas (Knoop e Daamen, 2017): (a) corrente de tráfego pode não estar em equilíbrio durante o período de observação; (b) o tráfego é heterogêneo; (c) os detectores não são capazes de detectar veículos parados; (d) o número de veículos medido durante um intervalo é sempre inteiro; e (e) a velocidade média registrada pelo sensor é a velocidade média no tempo, e não a velocidade média no espaço.

A calibração desses modelos com bases de dados muito grandes (VLDBs), que contém dados coletados durante vários meses ou anos, está associada a um outro problema, que é o ruído nos

dados. Durante a operação das rodovias podem ocorrer diversos incidentes (obras, interdições da via, acidentes, intempéries, defeitos nos sensores, etc.) que fazem com que os dados coletados apresentem ruídos (dados espúrios) que podem viciar o ajuste dos modelos. Na falta de informações confiáveis sobre esses incidentes, é indispensável definir um método capaz de lidar com os ruídos para modelar de maneira satisfatória a corrente de tráfego de uma rodovia, de modo semelhante ao usado para detectar incidentes em *freeways*, que integram lógica *fuzzy*, *wavelets* e redes neurais para melhorar a confiabilidade do método e eliminar ruídos e dados espúrios (Karim e Adeli, 2002). Estes trabalhos, especialmente os que lidam com VLDBs, mostram as dificuldades em filtrar os dados brutos para que as interferências causadas pelos ruídos sejam minimizadas.

Com a disseminação do uso de SATs para monitoramento de tráfego, muitos trabalhos se propuseram usar VLDBs para a modelagem de correntes de tráfego. Qu et al. (2015) usaram aproximadamente 48 mil observações; Dervisoglu et al. (2009) usaram uma base de dados com cerca de 27 mil observações; e Zhong et al. (2016), que dispunham de aproximadamente 10 mil observações para a calibração do modelo. VLDBs exigem que a calibração do modelo seja feita de modo automático o que pode levar a distorções nos resultados, se o conjunto de dados não for depurado e preparado para o processo.

Neste trabalho, a calibração do modelo usou cerca de 104 mil observações de volume e velocidade média. O método proposto está descrito nas seções a seguir.

### 3. DESCRIÇÃO DOS DADOS DE TRÁFEGO

A estação permanente de monitoramento de tráfego selecionada para este trabalho está instalada num trecho sem grandes inclinações longitudinais, onde o acesso é controlado e está fora da área de influência de dispositivos de acesso da via. Além disso, escolheu-se um ponto em que a capacidade da via foi atingida, apresentando observações na região de fluxo livre e na região de fluxo congestionado, para que fosse viável a calibração do modelo de Van Aerde. Este SAT localiza-se na região metropolitana de São Paulo, na Rodovia Ayrton Senna (SP070) no km 39,5 Leste. Os dados de tráfego foram fornecidos pela ARTESP (Agência de Transporte do Estado de São Paulo) e cobrem o período entre 1/9/2011 e 31/12/2017. Não havia dados disponíveis sobre incidentes, obras, bloqueios de faixas ou mau funcionamento do SAT.

Os dados são: a data, a hora, o número de veículos pesados, o número de veículos de passeio e a média das velocidades dos veículos detectados durante o intervalo de 15 minutos. Neste estudo, foram usadas apenas as observações registradas entre 5 e 22h, pois considerou-se que o tráfego durante a madrugada não é representativo, devido ao baixo volume de automóveis e grande porcentagem de veículos pesados.

Conforme descrito num outro trabalho (Cardoso et al., 2019), os dados foram tratados para eliminar as observações feitas com tempo chuvoso, a partir de informações dos radares meteorológicos do IPMet/UNESP (Centro de Meteorologia de Bauru). Além desse tratamento, no processamento dos dados para a formação do VLDB, foram excluídos as observações que apresentavam erros aparentes do funcionamento do SAT (como presença de valores repetidos várias vezes, valores muito discrepantes em relação à série temporal e ausência de informações). Mesmo após a eliminação destes dados, o banco de dados continha 103.606 observações em intervalos de 15 minutos. No entanto, dentre essas observações ainda existem muitos dados com ruídos, pois



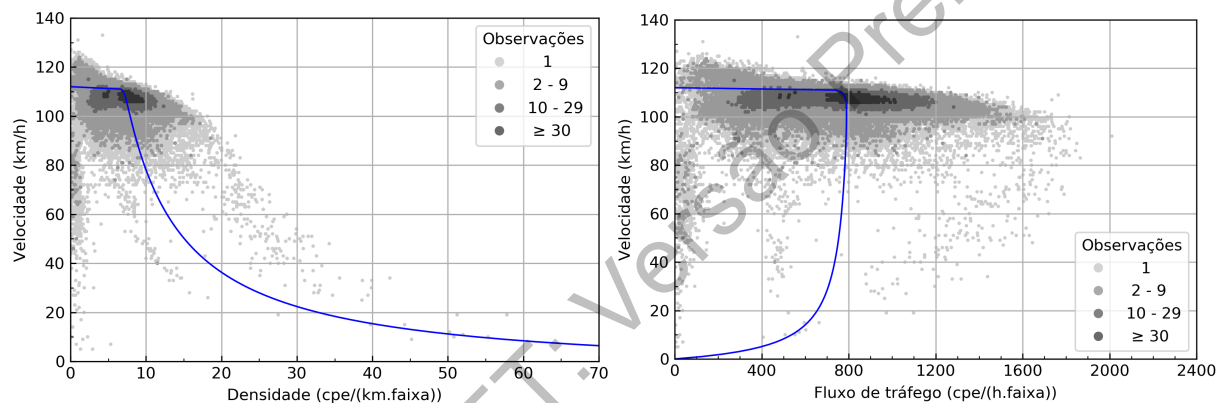
durante a operação da rodovia ocorrem obras, acidentes, interdições, leituras erradas dos sensores e demais incidentes que podem interferir na operação normal da rodovia.

#### 4. MÉTODO PROPOSTO

A abordagem adotada visa calibrar as relações entre fluxo, velocidade e densidade do modelo de Van Aerde usando uma base de dados muito grande (VLDB). Os passos para isso estão descritos a seguir.

##### 4.1. Redução e filtragem inicial dos dados de tráfego

O modelo proposto por Van Aerde e Rakha (1995) deve ser calibrado utilizando observações dos regimes de fluxo livre e de fluxo congestionado. O sucesso da calibração está condicionado a uma boa quantidade de dados em ambos os regimes. Porém, há dois problemas que interferem na calibração do modelo usando dados brutos do SAT: (1) o ruído (condições anormais de tráfego); e (2) a menor quantidade de períodos congestionados.



**Figura 1:** Modelo de Van Aerde ajustado para todas as observações do SAT estudado. O grande número de registros com densidade entre 5 e 10 cpe/(km.faixa) enviesam o modelo, resultando numa capacidade muito menor do que os fluxos máximos observados.

A Figura 1 mostra o efeito desses dois problemas. Uma parte do ruído é aparente no gráfico que mostra a relação entre  $u$  e  $k$ . O grande número de observações em que a densidade é baixa –  $k < 5$  cpe/(km.faixa) – e a velocidade também é baixa ( $u < 80$  km/h) representam uma operação anômala da rodovia, em que veículos com espaçamento superior a 200 m viajam em velocidade muito abaixo do limite de velocidade, que é 120 km/h. O segundo aspecto pode ser visto pela grande concentração de observações em certas regiões dos gráficos, como indica a escala de cinza. Isso pode enviesar o ajuste, já que o modelo calibrado tende a passar mais próximo dessas regiões, visto que elas terão maior peso no cálculo do erro do modelo, resultando numa calibração distorcida, como mostram as curvas em azul na Figura 1. Por isso, o processo de calibração deve incluir um filtro para eliminar o ruído e uma forma de reduzir os dados repetidos, para que todas as faixas de densidade tenham o mesmo peso na calibração do modelo (Rakha e Arafteh, 2010).

Para isso, os dados do SAT foram segregados em faixas de densidade de 0,25 cpe/(km.faixa) de largura. Para cada faixa calcularam-se a média, a mediana e diferentes percentis (70º, 75º, 80º e 85º) da velocidade e da densidade. Assim, somente um elemento fluxo-velocidade representa cada faixa de densidade, garantindo uma distribuição uniforme dos dados para a calibração. A redução dos dados em suas respectivas médias, medianas e 85º percentil é apresentada na Figura 2. Os pontos correspondentes ao 85º percentil foram escolhidos para o ajuste porque se

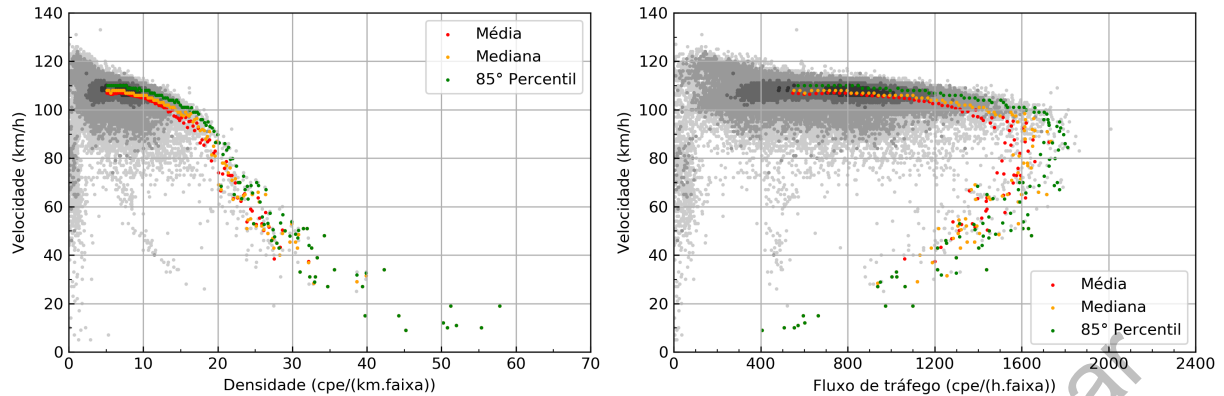


Figura 2: Redução dos dados SP-070 - km 39,5 Leste.

considerou que este valor representaria melhor a velocidade média dos automóveis, uma vez que o valor fornecido pelo SAT é a média da velocidade de todos os veículos que passam pelo intervalo (veículos leves e pesados). Neste local, o limite de velocidade dos veículos leves é maior que o limite de velocidade dos veículos pesados. Como os veículos pesados foram transformados em carros de passeio equivalentes usando-se o fator de conversão adotado pela ARTESP para o local ( $E_T = 2,5$ ), optou-se por usar o 85º percentil da velocidade para transformar a velocidade dos veículos pesados em velocidade de veículos equivalentes.

Para evitar o ruído associado às observações com baixa densidade, que pode distorcer e enviesar o ajuste do modelo, foram excluídas as observações em que  $k < 5$  cpe/(km.faixa), uma vez que dentro deste limite não há uma relação clara entre a densidade e a velocidade. É importante ressaltar que a filtragem e o ajuste da curva devem ser feitos a partir dos dados de velocidade e densidade, visto que a relação entre esses dois parâmetros é inequívoca: a velocidade nunca pode aumentar com o aumento da densidade, isto é, densidades baixas implicam em velocidades altas e vice-versa.

O ajuste do modelo foi realizado a partir dos dados de velocidade e densidade reduzidos pelo 85º percentil, com a densidade da  $i$ -ésima observação tendo sido calculada por  $k_i = q_i/u_i$ . Além de eliminar discrepâncias das observações em seu estado bruto, a redução em faixas de densidade fez com que cada valor da relação fluxo-velocidade-densidade tivesse igual influência na calibração do modelo, permitindo um melhor ajuste das curvas fluxo-velocidade e densidade-velocidade. No final desta etapa, havia 126 observações de densidade e velocidade para ajustar o modelo.

#### 4.2. Ajuste do modelo de Van Aerde através do algoritmo *hill climbing*

O modelo de Van Aerde foi ajustado com os dados produzidos na etapa anterior. Inicialmente, decidiu-se adotar a mesma estratégia usada por Van Aerde e Rakha (1995), ou seja, usar um AHC para encontrar os valores de  $u_f$ ,  $u_c$ ,  $q_c$  e  $k_j$  que resultem no melhor ajuste possível do modelo. O fluxograma da Figura 3 mostra a estrutura do algoritmo usado, que foi codificado em Python v. 3.7.0. Normalizando-se os valores do fluxo, densidade e velocidade, o problema de otimização pode ser expresso por:

$$\text{minimizar } E = \sum_i \left\{ \left( \frac{u_i - \hat{u}_i}{\bar{u}} \right)^2 + \left( \frac{q_i - \hat{q}_i}{\bar{q}} \right)^2 + \left( \frac{k_i - \hat{k}_i}{\bar{k}} \right)^2 \right\} \quad (\text{Rakha e Arafteh, 2010}) \quad (10)$$

sujeito a restrições específicas para esta aplicação, que são:

$$\hat{k}_i = \frac{1}{c_1 + \frac{c_2}{u_f - \hat{u}_i} + c_3 \hat{u}_i} \quad \forall i, \quad (11)$$

$$\hat{q}_i = \hat{k}_i \times \hat{u}_i \quad \forall i, \quad (12)$$

$$\hat{q}_i, \hat{k}_i, \hat{u}_i \geq 0 \quad \forall i, \quad (13)$$

$$u_c \leq 0,9 u_f, \quad (14)$$

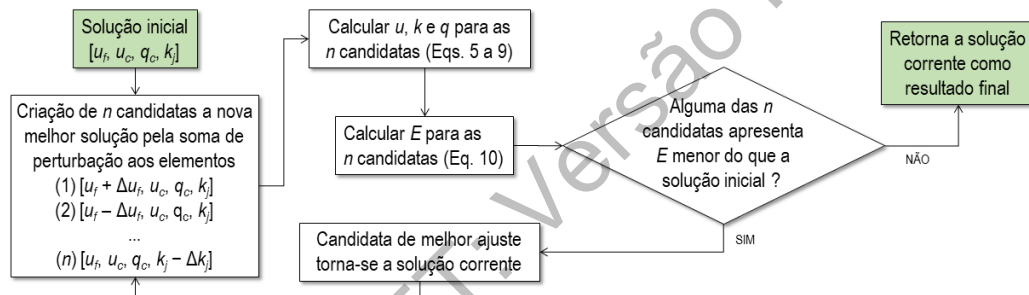
$$u_f \in [(0,9 \times u_{lim}), (1,1 \times u_{lim})], \quad (15)$$

$$u_c \in [50, 105] \text{ km/h}, \quad (16)$$

$$q_c \in [1000, 3000] \text{ veic}/(\text{h.faixa}), \text{ e} \quad (17)$$

$$k_j \in [75, 125] \text{ veic}/(\text{km.faixa}) \quad (18)$$

em que  $u_{lim}$  é a velocidade máxima regulamentada para a via e as demais variáveis já foram definidas no texto. As perturbações usadas no AHC foram unitárias.

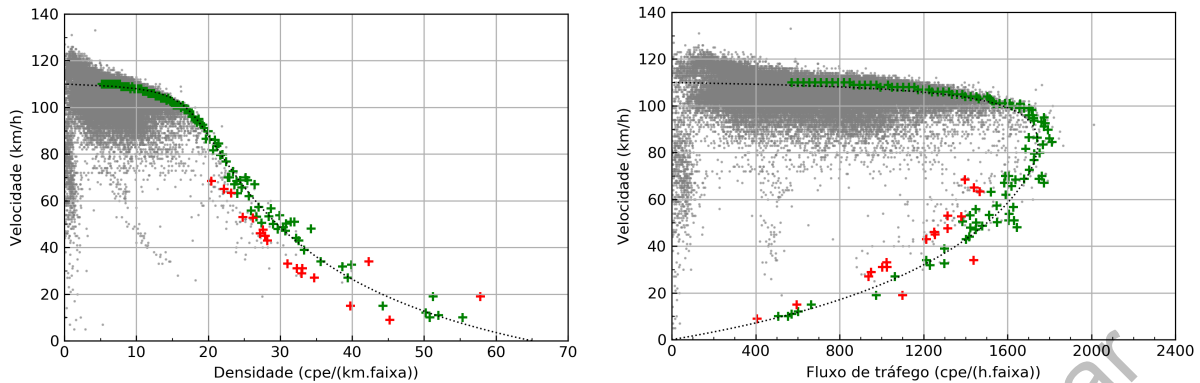


**Figura 3:** Fluxograma do AHC usado para calibração do modelo de Van Aerde com as observações do SAT do km 39,6 da SP-070.

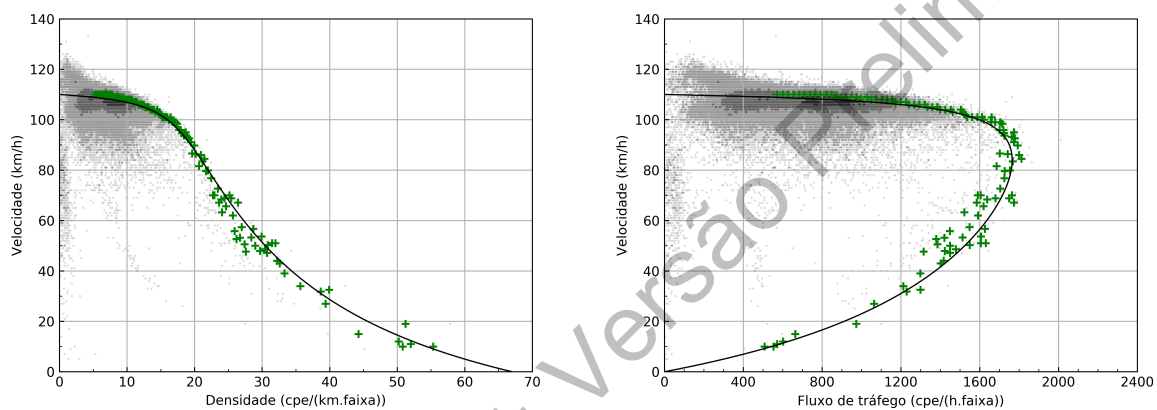
Os resultados deste estágio inicial da calibração do modelo, que é a aplicação do método proposto por Van Aerde e Rakha (1995) sem nenhuma modificação, são mostrados na Figura 4. Os pontos coloridos no gráfico mostram os dados usados para a calibração do modelo. Foi observado na função  $u = f(k)$  que diversos pontos (marcados em vermelho) ficavam muito distantes da função calibrada (linha pontilhada) – ou seja,  $|\hat{u}_i(k_i) - u_i(k_i)| \geq T$  km/h: a diferença absoluta entre a velocidade estimada e a velocidade observada para aquela densidade era maior que a tolerância  $T$ . Esses *outliers* foram considerados ruído (observações feitas sob condições anômalas).

Para eliminar estes *outliers*, decidiu-se modificar o método de calibração proposto originalmente, adicionando-se um segundo estágio consistindo de uma nova triagem dos dados seguido por um novo ajuste do modelo. A partir da primeira curva ajustada, uma tolerância  $T = \pm 10$  km/h foi estabelecida para os valores de velocidade observados. Assim, quaisquer observações com velocidades fora do intervalo de tolerância  $\hat{u}_i(k_i) \pm T$  foram automaticamente suprimidas pelo programa antes de uma nova rodada do AHC. Isso implicou na eliminação de 18 observações do conjunto de 126 observações usadas inicialmente. O resultado do segundo estágio de ajuste é apresentado na Figura 5.

O método de otimização *hill climbing* é um algoritmo heurístico que produz uma solução que não é necessariamente a ótima, mas que é razoavelmente boa para a maioria dos casos; isto é,



**Figura 4:** Ajuste da curva pelo AHC: primeiro estágio. Os *outliers* estão em vermelho e os pontos em verde são usados no segundo estágio do ajuste.



**Figura 5:** Resultado final da calibração pelo AHC, após eliminação automática de *outliers*.

o algoritmo pode incorrer em um máximo local. A presença de muitos máximos locais é uma característica intrínseca de séries temporais de velocidade média de uma corrente de tráfego, especialmente tratando-se de uma VLDB. Ao escolher esta abordagem, Van Aerde e Rakha (1995) estavam limitados aos recursos computacionais da época e, principalmente, ao pequeno número de observações disponíveis para calibrar o modelo (que variava entre 24, para um local, e 1199, para uma *freeway* na Holanda).

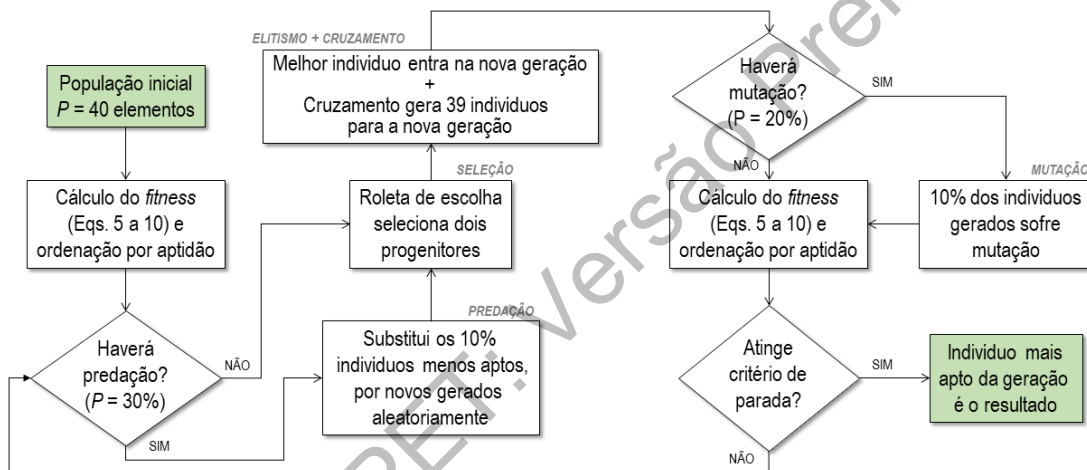
Ainda que o AHC tenha produzido bons resultados na aplicação a uma VLDB, vislumbrou-se a possibilidade de alteração do método de otimização, sem perda de generalidade do modelo, graças ao desenvolvimento computacional hoje existente. Estudos recentes, aplicados à simuladores de tráfego, revelam um aumento da eficiência na busca e otimização estocástica através do uso de algoritmos genéticos (Egami et al., 2004). Assim, motivados pela possibilidade de obtenção de uma solução global que seja mais precisa que a determinada pelo modelo tradicional, optou-se pela implementação de um AG adaptado às relações propostas por Van Aerde. A seção 4.3 apresenta uma proposta alternativa de método de otimização visando mitigar os efeitos de possíveis máximos locais.

#### 4.3. Calibração do modelo de Van Aerde por algoritmo genético

Na tentativa de melhorar ainda mais o resultado da calibração do modelo de Van Aerde, optou-se pela implementação de um algoritmo genético (AG), que permite uma melhor exploração do espaço de soluções, sendo menos suscetível em incorrer em máximos locais. Os AGs estabelecem

uma analogia com a teoria da seleção natural, em que os indivíduos mais bem adaptados ao meio ambiente (as melhores soluções para o problema) têm maior chance de sobrevivência. Nos AGs, a adaptação ao meio ambiente é medida por meio de uma função de adaptação denominada função *fitness* (Goldberg, 1989, p. 9).

A evolução destes indivíduos dá-se através dos operadores genéticos elitismo, seleção, cruzamento, mutação e predação. O processo se inicia com uma população inicial em que são selecionados indivíduos que darão origem a uma nova geração. De tempos em tempos, ocorrem mutações para aumentar a variabilidade da população e predações para eliminar indivíduos mal adaptados (Srinivas e Patnaik, 1994). O processo de evolução continua através das diferentes gerações até que o número máximo de gerações seja atingido ou que o valor *fitness* se estabilize. O indivíduo mais bem adaptado ao ambiente desta geração representa a melhor solução. O fluxograma da Figura 6 demonstra o processo.



**Figura 6:** Estrutura do AG usado para ajustar o modelo de Van Aerde usando uma VLDB.

O processo usado inicia-se com a redução dos dados do SAT utilizando o cálculo do 85º percentil e, a seguir, executa-se o AG. Gera-se uma população inicial com  $P = 40$  indivíduos, sendo que cada indivíduo é composto por um conjunto, randomicamente criado, de quatro características (genes) a serem calibradas: velocidade de fluxo livre  $u_f$ , velocidade na capacidade  $u_c$ , fluxo na capacidade  $q_c$ , e densidade de congestionamento  $k_j$ .

O tamanho  $P$  da população inicial é um fator crítico, pois exerce grande influência no custo computacional da otimização. Caso  $P$  seja um valor muito pequeno, o algoritmo irá convergir precocemente, enquanto  $P$  demasiadamente grande irá desperdiçar recursos de máquina devido ao grande número de iterações necessárias para que ocorra alguma melhora no resultado (Arabas et al., 1994). Devido às particularidades de cada problema, não há uma regra geral para definir a população  $P$  (Diaz-Gomez e Hougen, 2007). Assim sendo, optou-se por uma abordagem clássica que define  $P$  pela regra  $P = 10 \times D$ , sendo  $D = 4$  características para este estudo (Storn, 1996).

Estabelecida a população inicial deve-se encontrar os indivíduos mais aptos, isto é, ordenam-se os indivíduos, de maneira decrescente pelo valor do erro quadrático ortogonal  $E$ , a função *fitness* usada neste AG. Com este fim, para cada indivíduo aplicam-se as Eqs. 5 a 9 e calcula-se o seu



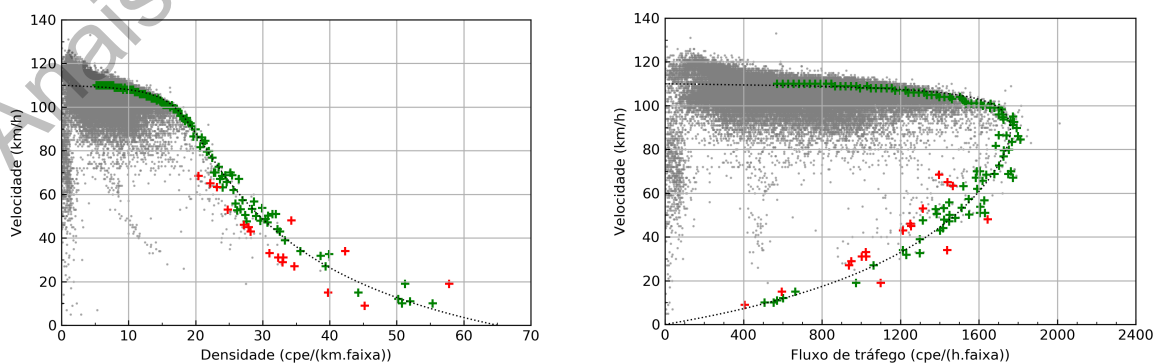
*fitness*  $E$  (Eq. 10). Os indivíduos mais aptos (com os menores valores de  $E$ ) ocupam as primeiras posições da lista.

A cada geração, há uma chance de ocorrer predação. Em caso positivo, os menos aptos são excluídos e substituídos por novos indivíduos, gerados aleatoriamente e, possivelmente, mais aptos. Neste estudo, a predação elimina os piores indivíduos a uma taxa  $t_p = 10\%$ , com probabilidade de ocorrência de  $P_p = 30\%$  a cada iteração (Sivanandam e Deepa, 2007).

A nova geração é criada por meio dos operadores elitismo, seleção e cruzamento. Através do elitismo, o indivíduo mais apto de uma geração é selecionado para a próxima geração, garantindo que uma boa solução não será descartada por acaso durante o processo de seleção de indivíduos para produzir a geração seguinte. Os  $(P-1)$  demais indivíduos da nova geração são criados através do cruzamento de dois progenitores selecionados pelo método da roleta de escolha (Chambers, 2000), em que os progenitores são escolhidos de tal forma que indivíduos mais aptos têm maior chance de se reproduzirem. Para tanto, realiza-se o somatório  $S$  de todos os erros  $E_i$  de modo que a probabilidade  $p_i$  de escolha de um indivíduo seja inversamente proporcional a sua contribuição para  $S$ . Escolhidos os dois progenitores por esse método, sorteia-se com igual probabilidade de ocorrência se um, dois, três ou quatro genes virão de um progenitor, com o complemento vindo do outro progenitor. Essa combinação de genes cria um novo indivíduo para a próxima geração. O processo é repetido até que tenham sido criados os indivíduos necessários para completar a população da próxima geração.


Por fim, têm-se o operador mutação, que é aplicado de maneira semelhante à predação, ocorrendo a uma taxa constante  $t_m = 10\%$  da população com uma probabilidade de ocorrência randômica  $P_m = 20\%$  por iteração. A mutação permite escapar de cenários em que já não ocorre grande variabilidade na população e, portanto, os descendentes tendem a ser réplicas exatas dos pais. Nesses casos, a mutação é uma oportunidade de gerar um novo e melhor indivíduo a partir de uma população estagnada (Coley, 1999).

O processo do AG ocorre até a milésima geração, para que seja possível explorar o maior número de soluções que atendam à função objetivo. Esse número de iterações, talvez exagerado, foi determinado devido ao baixo custo computacional para atingir esse patamar, cerca de 10 minutos, e também pelo fato de um número maior de gerações não ter resultado em soluções melhores nos testes realizados.



**Figura 7:** Resultado do estágio inicial do ajuste do modelo de Van Aerde por AG. Os *outliers* estão em vermelho e os pontos em verde são usados no segundo estágio do ajuste da curva.

A redução dos dados empíricos em faixas de densidade e o cálculo do respectivo 85º percentil eliminou anomalias do espaço amostral, permitindo um melhor ajuste das curvas fluxo-velocidade e densidade-velocidade propostas por Van Aerde. O problema de otimização é o mesmo, expresso pelas Eqs. 10 a 18. Novamente o artifício dos dois estágios foi utilizado, para garantir a remoção de ruídos sobreviventes ao primeiro tratamento. A Figura 7 apresenta o resultado do primeiro estágio da calibração do modelo; os 17 *outliers* definidos pela tolerância  $T = \pm 10$  km/h estão mostrados em vermelho. A Figura 8 mostra o resultado final da calibração, após o segundo estágio do ajuste da curva.



**Figura 8:** Resultado final da aplicação do AG para calibração do modelo de Van Aerde, após a eliminação dos *outliers*.

## 5. ANÁLISE DOS RESULTADOS


Para a avaliação dos resultados do ajuste, usou-se uma métrica  $Q$  definida como:

$$Q_i = \alpha \cdot \exp(-\beta \cdot E_i / \gamma) \quad (19)$$

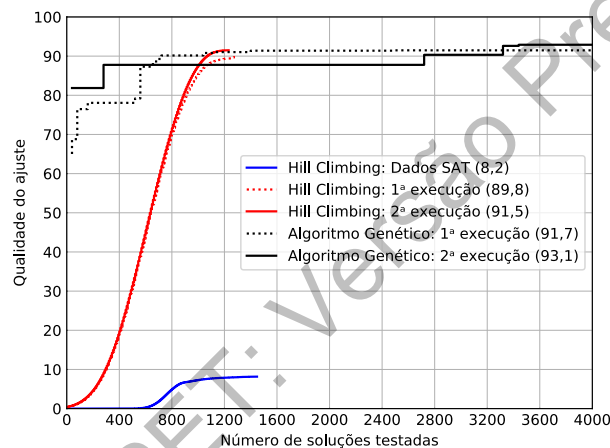
em que  $E_i$  é o erro quadrático ortogonal da melhor solução da geração (ou iteração)  $i$ , definido pela Eq. 10; e  $\alpha$ ,  $\beta$  e  $\gamma$  são fatores de escala, cujos valores foram arbitrariamente escolhidos como sendo  $\alpha = 100$ ,  $\beta = 5$  e  $\gamma = 1$ . A Eq. 19 mostra que  $0 < Q_i \leq 100$ ; ou seja, quanto maior o erro quadrático ortogonal  $E_i$ , menor o valor de  $Q_i$  e se  $E_i = 0 \Rightarrow Q_i \rightarrow 100$ .

Os gráficos da Figura 9 mostram o resultado final da calibração dos modelos com as três estratégias testadas. As funções em azul, se referem ao modelo calibrado sem redução nem filtragem dos dados do SAT pelo AHC, correspondem à aplicação direta do método usado por Van Aerde e Rakha (1995). Pode-se notar que esta estratégia é gravemente afetada pela concentração de observações na região que compreende fluxos entre 400 e 1200 cpe/(h.faixa). As funções em vermelho e preto representam o resultado da calibração usando a estratégia da redução de dados e duas execuções de otimização (1ª execução: calibração inicial + eliminação dos *outliers* e 2ª execução: calibração final) com o AHC (vermelho) e o AG (preto). Nota-se que a abordagem proposta consegue resultados que representam melhor a corrente de tráfego. Além disso, percebe-se que os dois algoritmos produzem resultados similares, já que as funções estão praticamente superpostas.

A Figura 10 permite comparar a evolução da qualidade do ajuste  $Q_i$  em função do número de soluções testadas. Cada iteração do AHC implica em testar 8 soluções (2 variações para cada um dos 4 parâmetros de calibração), ao passo que cada geração do AG implica em testar pelo menos 39 soluções (mais, se os operadores predação e mutação forem aplicados naquela geração).



**Figura 9:** Comparação do resultado final do AHC e AG: a função azul corresponde ao modelo ajustado com as 104 mil observações; as funções vermelha e preta são os modelos ajustados pela abordagem proposta para a redução e filtragem dos dados.



**Figura 10:** Evolução da qualidade do ajuste da calibração em função do número de gerações para cada alternativa testada

A aplicação direta do método de Van Aerde e Rakha (1995) (baseada num AHC) aos dados brutos do SAT apresentou uma qualidade de ajuste máxima de 8,2 após 1448 soluções testadas. A baixa qualidade de ajuste é explicada pela quantidade excessiva de observações com valores baixos de fluxo de tráfego, o que justifica a necessidade da aplicação do tratamento proposto.

A calibração do modelo de Van Aerde por *hill climbing* aplicado aos dados reduzidos apresentou, em sua primeira execução, uma qualidade de ajuste de 89,8 após 1280 soluções testadas. Vale ressaltar que a redução dos dados empíricos em faixas de densidade auxiliou no bom resultado apresentado por este modelo por minimizar os ruídos existentes nos dados brutos ponderando a relação fluxo-velocidade-densidade mais precisamente. Na segunda execução, após a exclusão dos *outliers* usando as estimativas de  $\hat{u} = f(k)$  produzidas pelo modelo ajustado na primeira rodada de calibração, o modelo calibrado melhorou sua qualidade de ajuste para 91,5, necessitando testar 1232 soluções para chegar neste resultado.

Na abordagem utilizando AG, o processo de criação estabeleceu uma população inicial com  $P = 40$  indivíduos aleatoriamente criados; no AHC, o processo se inicia a partir de uma única solução inicial, em que todos os parâmetros de calibração recebem o valor mínimo admissível.

Fica claro, portanto, que o AG estará muito mais propenso à se beneficiar de uma boa solução desde as primeiras soluções testadas. Esse fato pode ser observado na Figura 10 ao se verificar que as curvas do método via AG iniciam com valores de qualidade de ajuste nitidamente superiores às curvas via AHC. Além disso, na primeira execução do AG, testadas 1400 soluções, a qualidade do ajuste já é superior ao resultado final via AHC, sugerindo que o método via AG é capaz de melhor explorar o espaço de soluções. Na segunda execução do AG, após a exclusão dos *outliers* atinge-se uma qualidade de ajuste de 93,1 após 3400 soluções testadas, atestando que a abordagem proposta (tratamento dos dados brutos + calibração inicial via AG + aplicação de um filtro adicional para *outliers* + calibração final via AG) converge mais rapidamente para os melhores resultados.

Finalmente, deve-se ressaltar que apenas 30 gerações no AG (que correspondem grosseiramente a 1200 soluções testadas) bastariam para atingir a mesma qualidade de ajuste que foi obtida com o AHC.

## 6. CONSIDERAÇÕES FINAIS

A aplicação direta do método proposto por Van Aerde e Rakha (1995) à uma VLDB não forneceu uma boa calibração das relações entre fluxo, velocidade e densidade. A VLDB usada neste estudo contém cerca de 104 mil observações, que incluem ruídos que interferem na calibração. Além disso, a grande quantidade de observações no regime de fluxo livre faz com que a capacidade determinada pelo modelo seja subestimada. Com o intuito de solucionar estes problemas foi proposta a redução dos dados brutos em faixas de densidade para que cada conjunto de dados fluxo-velocidade-densidade tivesse igual influência no ajuste do modelo e o ruído fosse minimizado.

A nova abordagem ao modelo, por meio da implementação de um algoritmo genético foi benéfica por otimizar a busca por soluções ótimas ao invés de soluções subótimas, recorrentemente encontradas na modelagem tradicional. A calibração por algoritmo genético apresentou maior probabilidade de iniciar o processo iterativo a partir de uma solução superior à fornecida pela busca baseada num AHC. Além disso, com poucas gerações o AG já apresenta um resultado melhor do que o AHC.

Por fim, Van Aerde e Rakha (1995) utilizam dados agregados em intervalos variando entre 1 e 5 minutos para calibrar o modelo fluxo-velocidade-densidade. Constatou-se, neste estudo, que o modelo também pode apresentar uma boa calibração para observações em intervalos de 15 minutos.

**Agradecimentos** À ARTESP e ao IPMet que gentilmente cederam os dados utilizados nesta pesquisa. Esta pesquisa foi realizada com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) - Código de Financiamento 001, e de uma bolsa de produtividade em pesquisa do CNPq. (Proc. 312460/17-1).

## REFERÊNCIAS BIBLIOGRÁFICAS

- Arabas, J., Z. Michalewicz, e J. Mulawka (1994). GAVaPS-a genetic algorithm with varying population size. In *Proc. of the 1st IEEE Conference on Evolutionary Computation. IEEE World Congress on Computational Intelligence*, p. 73–78. IEEE.
- Cardoso, J. M., L. Assirati, e J. R. Setti (2019). Influência das condições meteorológicas na operação de rodovias de pista dupla paulistas. In *Anais do XXXIII Congresso Nacional de Pesquisa em Transportes*, Balneário Camboriú. ANPET.
- Chambers, L. D. (2000). *The Practical Handbook of Genetic Algorithms: Applications*. Chapman and Hall/CRC.
- Coley, D. A. (1999). *An introduction to genetic algorithms for scientists and engineers*. World Scientific Publishing



- Company.
- Demarchi, S. H. (2003). Uma nova formulação para o modelo fluxo-velocidade-densidade de Van Aerde. In CNT/ANPET (Ed.), *Transporte em Transformação – 7*, p. 77–94. Brasília, DF: LGE.
- Dervisoglu, G., G. Gomes, J. Kwon, R. Horowitz, e P. Varaiya (2009). Automatic calibration of the fundamental diagram and empirical observations on capacity. In *88th Annual Meeting of the Transportation Research Board*.
- Diaz-Gomez, P. e D. Hougen (2007). Initial population for genetic algorithms: A metric approach. In *Proc. of the 2007 Intl. Conference on Genetic and Evolutionary Methods, GEM 2007*, Las Vegas, p. 43–49.
- Draper, N. e H. Smith (1980). *Applied Regression Analysis* (2nd. ed. ed.). New York: John Wiley & Sons.
- Egami, C. Y., J. R. Setti, e L. R. Rillet (2004). Algoritmo genético para calibração automática de um simulador de tráfego em rodovias de pista simples. *Transportes* 12(2), 5–14.
- FGSV (2015). *Handbuch für die Bemessung von Straßenverkehrsanlagen: HBS 2015 Forschungsgesellschaft für Straßen und verkehrswesen*. Cologne: FGSV.
- Goldberg, D. E. (1989). *Genetic Algorithms in Search, Optimization and Machine Learning*. Boston: Addison-Wesley Longman.
- Greenberg, H. (1959). An analysis of traffic flow. *Operations Research* 7(1), 79–85.
- Hall, F., V. F. Hurdle, e J. H. Banks (1992). Synthesis of recent work on the nature of speed-flow and flow-occupancy (or density) relationships on freeways. *Transportation Research Record* 1365, 12–18.
- Karim, A. e H. Adeli (2002). Comparison of fuzzy-wavelet radial basis function neural network freeway incident detection model with California algorithm. *Journal of Transportation Engineering* 128(1), 21–30.
- Kerner, B. S. (2004). *The Physics of Traffic – Empirical Freeway Pattern Features, Engineering Applications, and Theory*. Berlin Heidelberg: Springer.
- Kühne, R. D. (2011). Greenshields’ legacy: Highway traffic. In *75 Years of the Fundamental Diagram for Traffic Flow Theory – Greenshields Symposium*, Transportation Research Circular E-C149, p. 3–11. Washington, DC, USA: Transportation Research Board.
- Knoop, V. L. e W. Daamen (2017). Automatic fitting procedure for the fundamental diagram. *Transportmetrica B: Transport Dynamics* 5(2), 129–144.
- Lu, S., Y. Jun, H. Mahmassani, G. Wenjun, e K. Bum-Jin (2010). Data mining-based adaptive regression for developing equilibrium speed-density relationships. *Canadian Journal of Civil Engineering* 37(3), 389–400.
- May, A. D. (1990). *Traffic Flow Fundamentals*. Upper Saddle River, NJ, USA: Prentice Hall.
- Qu, X., S. Wang, e J. Zhang (2015). On the fundamental diagram for freeway traffic: a novel calibration approach for single-regime models. *Transportation Research Part B: Methodological* 73, 91–102.
- Rakha, H. (2009). Validation of Van Aerde’s simplified steady-state car-following and traffic stream model. *Transportation Letters* 1(3), 227–244.
- Rakha, H. e M. Arafteh (2010). Calibrating steady-state traffic stream and car-following models using loop detector data. *Transportation Science* 44(2), 151–168.
- Rakha, H. e B. Crowther (2003). Comparison and calibration of FRESIM and INTEGRATION steady-state car-following behavior. *Transportation Research Part A: Policy and Practice* 37(1), 1–27.
- Sivanandam, S. N. e S. N. Deepa (2007). *Introduction to Genetic Algorithms*. Berlin: Springer.
- Srinivas, M. e L. M. Patnaik (1994). Adaptive probabilities of crossover and mutation in genetic algorithms. *IEEE Transactions on Systems, Man, and Cybernetics* 24(4), 656–667.
- Storn, R. (1996). On the usage of differential evolution for function optimization. In *Proceedings of North American Fuzzy Information Processing*, p. 519–523. IEEE.
- TRB (2016). *Highway Capacity Manual*. Washington, D.C.: Transportation Research Board, National Research Council.
- Treiber, M., A. Hennecke, e D. Helbing (2000). Congested traffic states in empirical observations and microscopic simulations. *Physical Review E* 62, 1805–1824.
- Van Aerde, M. e H. Rakha (1995). Multivariate calibration of single regime speed-flow-density relationships. In *Pacific Rim TransTech Conference. 1995 Vehicle Navigation and Information Systems Conference Proceedings. 6th International VNIS*, p. 334–341. IEEE.
- Zhong, R., C. Chen, A. H. Chow, T. Pan, F. Yuan, e Z. He (2016). Automatic calibration of fundamental diagram for first-order macroscopic freeway traffic models. *Journal of Advanced Transportation* 50(3), 363–385.

---

J. M. Cardoso (julianam.cardoso@usp.br), L. Assirati (assirati@usp.br), J. R. Setti (jrasetti@usp.br)  
Dep. de Engenharia de Transportes, Escola de Engenharia de São Carlos, Universidade de São Paulo  
Av. Trabalhador São-carlense 400, 13566-590 – São Carlos, SP, Brasil