

INFLUÊNCIA DAS CONDIÇÕES METEOROLÓGICAS NA OPERAÇÃO DE RODOVIAS DE PISTA DUPLA PAULISTAS

Juliana Mitsuyama Cardoso

Lucas Assirati

José Reynaldo Setti

Universidade de São Paulo

Escola de Engenharia de São Carlos

RESUMO

Este trabalho investiga a influência das condições meteorológicas adversas na operação de rodovias no estado de São Paulo. Dados de 12 sensores automáticos de tráfego foram combinados com dados de precipitação obtidos por meio da aplicação de visão computacional a imagens de radares meteorológicos. Esses dados foram separados em dois conjuntos (operação sob chuva e operação sob tempo bom) e usados para calibrar o modelo fluxo-velocidade-densidade de Van Aerde por meio de um algoritmo genético. Verificou-se uma redução de aproximadamente 10% na capacidade. Não foi detectado um efeito significativo da chuva sobre a velocidade livre ou sobre a velocidade na capacidade.

ABSTRACT

The research reported in this paper examines the influence of adverse weather on the operation of freeways in the state of São Paulo. Data from 12 loop detectors were combined with weather data obtained by computer vision from weather radar images. These data were divided in two sets (operation under good weather and operation under rainy weather) which were used to calibrate the Van Aerde traffic flow model by means of a genetic algorithm. The results indicate an average reduction of 10% on capacity. No significant effects of weather were found on the free speed or on the speed at capacity.

1. INTRODUÇÃO

As condições meteorológicas afetam o comportamento dos motoristas pois interferem na percepção e sensação de segurança. Os motoristas tendem a diminuir a velocidade para aumentar a distância entre os veículos (Goodwin, 2002). Em uma escala macroscópica, este comportamento influencia na operação das rodovias.

Em diversos países, registram-se esforços para estudar a influência de condições meteorológicas adversas sobre as correntes de tráfego: na Inglaterra (Hawkins, 1988), no Canadá (Ibrahim e Hall, 1994), na Alemanha (Brilon e Ponzlet, 1996), nos EUA (Smith et al., 2004; Hranac et al., 2006; Maze et al., 2006), e na Espanha (Camacho et al., 2010). Em função das evidências resultantes desses estudos, na sua versão mais recente, o *Highway Capacity Manual* (HCM 6a. ed.) recomenda fatores de ajuste para a capacidade e a velocidade de fluxo livre em *freeways* de acordo com as condições meteorológicas existentes (TRB, 2016, p. 11-43), ressaltando, entretanto que estes fatores de ajuste foram calculados para a realidade norte-americana, e devem ser ajustados para refletir as características climáticas e operacionais de cada localidade. No Brasil, existem poucos trabalhos que abordam os efeitos das condições meteorológicas. Caleffi et al. (2016) estudaram o efeito da chuva na segurança viária e Zechin et al. (2018) focaram na probabilidade de *breakdown* da corrente de tráfego, usando dados coletados na BR-290, na região metropolitana de Porto Alegre. Em Fortaleza, estudou-se a influência da chuva na velocidade de fluxo livre e fluxo de saturação em vias urbanas (Moreira et al., 2017).

Este trabalho visa verificar se condições meteorológicas adversas influenciam a operação de rodovias no estado de São Paulo, comparando o fluxo de tráfego em condições chuvosas com o

fluxo de tráfego sob bom tempo. Para atingir este objetivo foram utilizados dados de sensores de tráfego localizados em autoestradas e rodovias de pista dupla, que cobrem um extenso período (2011–2017), combinados com informações do tempo extraídas de imagens geradas por radares meteorológicos para o mesmo período. As questões de pesquisa colocadas para este estudo são: (1) Como determinar quais as condições meteorológicas nos períodos e nos locais em que os sensores automáticos de tráfego (SATs) coletavam dados? (2) Como e quanto as condições adversas do tempo afetam as correntes de tráfego em rodovias do estado de São Paulo?

Este texto está organizado da seguinte forma: após esta introdução, apresenta-se uma breve revisão da literatura e descrevem-se os dados usados no estudo. A seguir, são apresentados o método proposto e os resultados obtidos com a calibração das relações entre densidade, velocidade e fluxo de tráfego. Ao final, são tecidas considerações sobre os resultados obtidos.

2. REVISÃO DA LITERATURA

A influência das condições meteorológicas no tráfego rodoviário tem sido o foco de vários estudos. A chuva, a neve e a decorrente redução de visibilidade afetam a velocidade escolhida pelos motoristas, pois interferem na percepção e sensação de segurança (Hawkins, 1988; Edwards, 1999). Os motoristas tendem a diminuir suas velocidades para aumentar a distância de segurança entre os veículos (Goodwin, 2002). Esse comportamento faz com que ocorra a diminuição da capacidade, da velocidade de fluxo livre, e da velocidade na capacidade (TRB, 2000, p. 22-8).

A intensidade da precipitação é a principal razão para que os motoristas diminuam suas velocidades sob tempo ruim; por isso, alguns estudos segregam os efeitos da chuva em função de precipitações fracas e fortes. No Canadá, observou-se uma redução de 2 km/h na velocidade de fluxo livre sob chuva fraca e, sob chuva forte, reduções entre 5 e 10 km/h (Ibrahim e Hall, 1994); na Espanha, foram observadas reduções de 5,5 km/h (chuva fraca) e de 7 km/h, com chuva forte (Camacho et al., 2010). No Brasil, detectou-se uma redução de 10 km/h nas “velocidades médias na porção superior da curva” quando chovia em Porto Alegre (Caleffi et al., 2016). Nos EUA, detectaram-se reduções da velocidade na capacidade de 8–10% para chuva fraca e de 8–14% para chuva forte (Hranac et al., 2006).

Vários estudos mostram que a capacidade também é afetada pela chuva. Três estudos conduzidos nos EUA sugerem que o efeito depende do local: Hranac et al. (2006) reportam uma redução de 10–11%, que não parece ser afetada pela intensidade da precipitação; Maze et al. (2006) constataram um decréscimo médio de 7% na capacidade sob chuva fraca e 14% sob chuva forte; Smith et al. (2004) observaram que a capacidade é reduzida entre 4–10% sob chuva fraca e 25–30% sob chuva forte.

Diversos estudos (Hranac et al., 2006; Rakha et al., 2008; Billot et al., 2009) analisaram o efeito das condições meteorológicas sobre a corrente de tráfego por meio da calibração do modelo de Van Aerde para as condições chuvosas e sem chuva. Este modelo pode ser calibrado a partir de dados de sensores automáticos e, além de ser capaz de representar diferentes tipos de rodovias, tem a vantagem de expressar os regimes de fluxo livre e fluxo congestionado através de uma função contínua, tão bem quanto modelos de regime múltiplo (Rakha, 2009).

Um aspecto importante na realização dos estudos sobre a influência das condições meteorológicas no fluxo de tráfego diz respeito aos dados do tempo, que costumam ser oriundos de estações

meteorológicas (Brilon e Ponzlet, 1996; Smith et al., 2004; Camacho et al., 2010). Esta abordagem requer que os pontos de coleta de dados de tráfego estejam próximos de estações meteorológicas para que as informações do tempo sejam espacialmente representativas e estejam correlacionadas às condições de tráfego (Billot et al., 2009).

Quando não se dispõe de uma densa rede de pluviômetros que estejam próximos dos sensores de tráfego, a medição realizada por radares meteorológicos se torna uma alternativa viável. Desde 1960, os radares vêm sendo usados para determinar as condições meteorológicas em tempo real (Wilson et al., 1998) e podem medir a distribuição espacial e a intensidade das chuvas com uma boa precisão (Austin, 1987). Desse modo, é possível combinar dados de precipitação com dados de tráfego coletados por sensores espalhados por uma grande região para estudar o efeito das condições meteorológicas sobre o comportamento de correntes de tráfego.

3. COLETA DE DADOS

Nesta seção, os dados de tráfego e os dados meteorológicos são apresentados. Como tanto uma corrente de tráfego operando próximo ou na capacidade como uma chuva são eventos de curta duração e não muito comuns, é indispensável dispor de um volume muito grande de dados para se obter uma amostra representativa de observações do tráfego na capacidade sob condições adversas do tempo, já que a probabilidade de ocorrência simultânea dessas duas condições é bastante pequena. Por isso, foram obtidos dados que cobrem o período de 1/9/2011 a 31/12/2017. Ainda que durante esses 2313 dias tenha havido inúmeras instâncias de mau funcionamento tanto dos radares como dos sensores de tráfego, trata-se de uma base de dados muito grande (VLDB, *very large database*) obtida a partir da fusão dos dados meteorológicos com os dados de tráfego.

Os dados de tráfego, fornecidos pela ARTESP (Agência de Transporte do Estado de São Paulo), foram coletados através de estações permanentes de monitoramento de tráfego (SAT, sensor automático de tráfego). Como foram escolhidos pontos de monitoramento onde rotineiramente atinge-se a capacidade da rodovia, eles estão situados no entorno de São Paulo, a região mais populosa do estado, como pode ser visto na Figura 1.

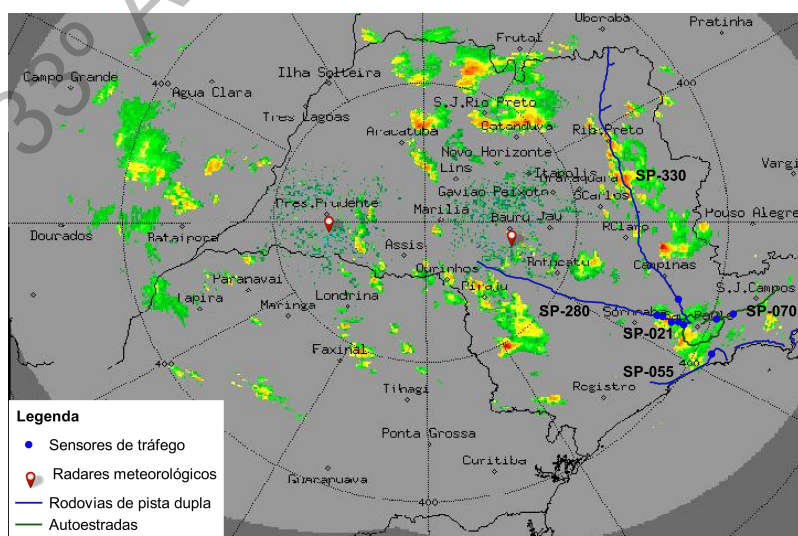


Figura 1: Localização e cobertura dos radares meteorológicos e estações de monitoramento de tráfego usados neste estudo [Adaptado de imagem fornecida pelo IPMet/UNESP]

Os dados do tempo consistem em imagens geradas pelos radares meteorológicos do IPMet/UNESP (Centro de Meteorologia de Bauru), em intervalos de 15 minutos. A Figura 1 mostra a localização dos radares meteorológicos do IPMet/UNESP, situados em Bauru e Presidente Prudente e sua área de cobertura. Como se pode depreender da Figura 1, todos os SATs selecionados para este estudo estão dentro da região coberta por esses radares.

3.1. Dados de tráfego

Para esta pesquisa, foram escolhidos pontos de monitoramento instalados em trechos sem grandes inclinações longitudinais, onde o acesso é controlado e está fora da área de influência de dispositivos de acesso da via – ou seja, segmentos básicos de *freeways*, de acordo com o HCM. A seleção foi realizada usando-se um método anteriormente testado (Andrade e Setti, 2011). Além disso, a ARTESP registra que, nestes pontos, a capacidade da via é rotineiramente atingida, apresentando observações nas regiões de fluxo livre e de fluxo congestionado.

Os dados de tráfego fornecidos pela ARTESP são a contagem dos veículos comerciais e de passeio e velocidade média da corrente de tráfego, agregados em intervalos de 15 minutos. A Figura 1 apresenta a localização dos sensores de tráfego analisados e a Tabela 1 mostra as características da rodovia em cada ponto de coleta de dados.

Tabela 1: Características dos pontos de monitoramento do tráfego

Id	Rodovia	km	Sentido	Limite de velocidade		Número de faixas	Tipo de via	Ocupação lindeira
				Leves	Pesados			
1	SP-021	18,3	Externo	100	80	4	Autoestrada	Urbano
2	SP-021	18,3	Interno	100	80	5	Autoestrada	Urbano
3	SP-280	26,9	Oeste	100	90	3	Rodovia de pista dupla	Urbano
4	SP-280	26,9	Leste	100	90	3	Rodovia de pista dupla	Urbano
5	SP-330	55,2	Norte	100	80	2	Rodovia de pista dupla	Urbano
6	SP-330	55,2	Sul	100	80	2	Rodovia de pista dupla	Urbano
7	SP-055	276,9	Oeste	110	90	3	Rodovia de pista dupla	Rural
8	SP-070	30,0	Oeste	110	90	4	Autoestrada	Urbano
9	SP-070	54,1	Oeste	120	90	2	Autoestrada	Rural
10	SP-280	37,0	Leste	120	90	3	Rodovia de pista dupla	Rural
11	SP-280	51,9	Oeste	120	90	3	Rodovia de pista dupla	Rural
12	SP-280	59,6	Leste	120	90	3	Rodovia de pista dupla	Rural

3.2. Dados meteorológicos

Os dados meteorológicos consistem em imagens geradas pelos radares meteorológicos do IPMet que fornecem a cada 15 minutos a intensidade das chuvas em quase todo o estado de São Paulo. Um exemplo das imagens fornecidas pelo IPMet pode ser visto na Figura 2, em que a cor de cada *pixel* na imagem indica a existência de chuva e sua intensidade, através de uma escala de cores discreta. Cada *pixel* da imagem na Figura 2 representa uma área de 2,5 km × 2,5 km. As imagens têm 900×625 *pixels* e estão no formato *.tif*, capaz de armazenar dados de imagens usando compressão sem perdas, o que reduz a possibilidade de erros na determinação das condições meteorológicas.

A leitura da cor do *pixel* correspondente à geolocalização do SAT permite determinar se chove ou não naquele local, durante o intervalo de tempo a que se refere a imagem do radar. A ausência

de cor (*pixel* da cor preta) significa que não está chovendo na região (ausência de sinal refletido); outras cores precipitação e sua intensidade, de acordo com a escala no lado direito da Figura 2.




Figura 2: Imagem dos radares do IPMet, mostrando as chuvas detectadas no intervalo entre 6:00 e 6:15 de 20/11/2015 [fonte: IPMet/UNESP]

4. MÉTODO PROPOSTO

O método proposto é apresentado na Figura 3. Os dados dos SATs são usados para gerar o banco de dados de tráfego; as imagens dos radares do IPMet são usadas para criar o banco de dados meteorológicos. A seguir, faz-se a fusão desses dois bancos de dados, criando o banco de dados para o estudo. Este banco de dados contém, para cada SAT e para cada intervalo de tempo, a taxa de fluxo, a velocidade, a densidade e a condição do tempo (bom, chuva fraca, chuva moderada ou chuva forte). Escolhido o modelo matemático para representar as relações entre fluxo, velocidade e densidade, faz-se a calibração dos modelos para cada ponto de coleta de dados. Com os modelos calibrados, pode-se então estudar o efeito das condições meteorológicas adversas sobre o tráfego.

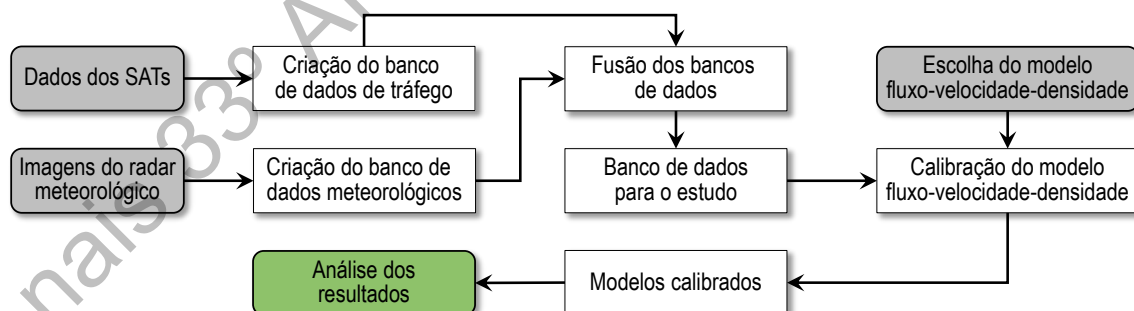


Figura 3: Fluxograma ilustrando o método utilizado neste estudo

4.1. Preparação do banco de dados meteorológicos

Para a criação do banco de dados meteorológicos, inicialmente foram determinados os *pixels* na imagem do radar que correspondem à latitude e longitude de cada SAT, através de uma determinação afim (Ono et al., 2000).

As condições meteorológicas nesses *pixels* foram determinadas através de visão computacional, com um programa escrito em Python 3.6, usando Pillow, uma biblioteca de processamento de

imagens para Python. Esse programa lê o valor RGB dos *pixels* de interesse, em cada uma das imagens do radar. Cada parâmetro RGB varia de 0 a 255 e a combinação dos três produz uma gama cromática. A cor preta – RGB (0,0,0) – indica que não estava chovendo na região (ausência de sinal refletido) e, quando o *pixel* apresenta um valor RGB diferente de (0,0,0), significa que chovia no local no período em que os dados do radar foram coletados. A intensidade da chuva é definida pela refletividade do radar que é expressa em decibel (dBZ) e apresenta relação com uma escala de cores, conforme indicado do lado direito da Figura 2: *fraca* (menos que 3 mm/h), se a intensidade do sinal estiver entre 15 e 30 dBZ; *moderada* (3–25 mm/h), para sinal entre 30 e 45 dBZ; e *forte* (acima de 25 mm/h), se o sinal for maior que 45 dBZ.

Ao final do processamento das imagens, têm-se um banco de dados que contém as seguintes informações: data, hora, local, e o tempo (sem chuva, chuva fraca, chuva moderada, chuva forte, ou sem informação). Essas informações referem-se ao período de 15 min anterior ao instante em que a imagem do radar foi gerada. O número de observações assim obtidas para cada SAT pode ser visto na terceira coluna da Tabela 2 (Tempo). Como os radares sofrem interrupções, há diversos intervalos para os quais não há imagens. Esses intervalos são marcados como “sem informação” no banco de dados e não estão contados na Tabela 2.

Tabela 2: Número de observações correspondendo a intervalos de 15 min em cada banco de dados

Id	Banco de dados		Fusão de dados	Dados das 5h às 22h		
	Tráfego	Tempo		Total	Sem chuva	Com chuva
1	153.804	173.391	116.725	82.571	79.778	2.793
2	154.257	173.391	117.301	82.967	80.155	2.812
3	118.226	107.690	91.059	66.827	64.280	2.547
4	126.436	107.690	92.724	65.698	63.152	2.546
5	131.986	107.692	100.319	71.050	67.895	3.155
6	130.499	107.692	99.251	70.272	67.128	3.144
7	161.403	164.529	126.451	89.533	87.535	1.998
8	198.361	173.403	148.517	105.277	102.251	3.026
9	208.423	173.399	162.412	114.913	112.081	2.832
10	128.391	107.686	97.380	68.948	66.191	2.757
11	130.594	107.684	99.975	70.727	67.527	3.200
12	128.283	107.692	98.293	69.633	66.599	3.034
Total	1.770.663	1.611.939	1.350.407	958.416	924.572	33.844

4.2. Preparação do banco de dados de tráfego

Os dados de tráfego foram fornecidos pela ARTESP sob a forma de planilhas, com organização e formatação variadas. O número de observações disponíveis para cada SAT pode ser visto na segunda coluna da Tabela 2 (Tráfego). Usando-se um conjunto de programas em Python, os dados foram tratados para seguir um mesmo formato, em intervalos de 15 min, de modo similar ao usado no banco de dados do tempo. Cada registro informa: a data, a hora, o local, o número de carros de passeio, o número de veículos pesados, e a média das velocidades dos veículos detectados durante o intervalo. Nos períodos em que o SAT não funcionou, os dados de contagem e velocidade ficam vazios. Esses intervalos não estão contados na Tabela 2.

4.3. Fusão dos dados e criação do banco de dados para o estudo

Para a fusão dos bancos de dados de tráfego e do tempo, criou-se um programa em Python que combinava os registros dos dois bancos de dados, criando um novo banco de dados cujos

registros eram compostos de: data, hora, local, número de carros de passeio, número de veículos pesados, a velocidade média, e as condições meteorológicas durante o período. Os registros em que faltava alguma informação (de tráfego ou do tempo) foram eliminados na fusão dos dois bancos de dados. O número de observações remanescentes após esta etapa pode ser visto na quarta coluna da Tabela 2 (Fusão de dados).

Como a porcentagem de veículos pesados varia de intervalo para intervalo de observação e de local para local, os veículos pesados foram convertidos para carros de passeio equivalentes (cpe) usando-se o fator de equivalência estabelecido pela ARTESP para cada trecho. Em seguida, a densidade da corrente foi estimada através da equação fundamental do tráfego ($k = q/v$), de tal modo que, para cada intervalo de observação têm-se a taxa de fluxo de tráfego q , em cpe/(h.faixa), a velocidade média da corrente de tráfego v (km/h), a densidade da corrente k , em cpe/(km.faixa), e a condição do tempo.

Foram usados apenas os dados de tráfego registrados entre 5h e 22h, já que se considerou que o fluxo durante as madrugadas não é representativo da operação das rodovias, dados os baixos volumes e grande porcentagem de veículos pesados. As duas últimas colunas da Tabela 2 mostram os tamanhos das amostras para cada local estudado. Pode-se notar que os períodos de chuva são pouco frequentes, variando entre 2,2% e 4,5% da amostra; os períodos de chuva forte ou moderada são ainda mais raros. Por isso, decidiu-se classificar as observações em apenas dois grupos: *tempo bom* ou *tempo chuvoso*, sem considerar a intensidade da chuva.

4.4. Redução dos dados de tráfego

Para a análise da influência da precipitação sobre o fluxo de tráfego é necessária uma coleta de dados por um extenso período de tempo para que exista uma quantidade suficiente de dados com o tempo chuvoso. Dessa forma, este trabalho utilizou dados coletados por sensores de tráfego entre os anos de 2011 e 2017. Num conjunto de dados dessa magnitude, é inevitável que, junto com a informação, também haja ruídos que interferirão na calibração dos modelos. Esses ruídos podem ser provenientes de mau funcionamento dos sensores, fechamento de faixas para obras ou por causa de acidentes, e um sem número de outras causas, sobre as quais não se dispõe de informações que possam ser obtidas com facilidade.

O ajuste do modelo de Van Aerde (Rakha, 2009) requer observações de velocidade e densidade ao longo de toda a gama de densidades, do regime não congestionado ao regime congestionado. Para uma boa calibração deste modelo é importante que se disponha de uma boa quantidade de dados nos dois regimes; porém, o número de períodos congestionados é sempre significativamente inferior à quantidade de dados não congestionados, o que também pode distorcer os resultados da calibração (Cardoso et al., 2019).

Para solucionar o problema da maior quantidade de informações sobre períodos não congestionados e reduzir a interferência do ruído, os dados registrados foram segregados em faixas estreitas de densidade, com largura de 0,25 cpe/(km.faixa). Para cada faixa foram calculadas a média, a mediana e diferentes percentis (70, 75, 80 e 85º percentil) da velocidade média e das densidades para cada faixa. Dessa forma, assegura-se que haja somente um valor de fluxo e velocidade em cada faixa de densidade, garantindo uma distribuição uniforme de dados para a calibração (Rakha e Arafteh, 2010).

Verificou-se que não houve diferenças significativas na calibração do modelo de Van Aerde apresentada pelos diferentes percentis calculados e optou-se pelo 85º percentil. A redução dos dados em suas respectivas médias, medianas e 85º percentil é apresentada nas Figuras 4 e 5. Pode-se perceber que curva descrita pelo 85º percentil melhor representa os dados de tráfego, já que o ruído aumenta a dispersão da velocidade média e faz com que a média e a mediana fiquem menores. Por isso, decidiu-se que a calibração do modelo fluxo-velocidade-densidade seria feita com base nos 85º percentis da velocidade média e da densidade, em cada faixa da densidade, o que corresponde aos pontos verdes nas Figuras 4 e 5.




Figura 4: Obtenção dos dados para calibração do modelo sem chuva (SP-280, km 26,9 Leste)




Figura 5: Obtenção dos dados para calibração do modelo com chuva (SP-280, km 26,9 Leste)

4.5. Calibração do modelo fluxo-velocidade-densidade

A análise da influência da precipitação na operação das rodovias exige um modelo macroscópico eficiente e flexível, com graus de liberdade suficientes para que seja possível verificar as mudanças causadas pela chuva. O modelo proposto por Van Aerde atende a essas exigências e por isso foi escolhido para este estudo.

No modelo de Van Aerde, as relações entre a densidade k , a velocidade média u da corrente de tráfego e a taxa de fluxo de tráfego q são dadas pelas expressões (Van Aerde e Rakha, 1995):

$$q = u \cdot k \quad \text{e} \quad k = \frac{1}{c_1 + \frac{c_2}{u_f - u} + c_3 u} \quad (1)$$

em que u_f é a velocidade de fluxo livre; u_c é a velocidade na capacidade; q_c , a capacidade; k_j representa a densidade de congestionamento; e c_1 (km); c_2 (km²/h); e c_3 (h) são constantes

calculadas por:

$$c_1 = \frac{u_f}{k_j u_c^2} (2u_c - u_f) \quad (2) \quad c_2 = \frac{u_f}{k_j u_c^2} (u_f - u_c)^2 \quad (3) \quad c_3 = \frac{1}{q_j} - \frac{u_f}{k_j u_c^2}. \quad (4)$$

A calibração do modelo está descrita num outro trabalho (Cardoso et al., 2019), o qual o leitor interessado deverá consultar para maiores detalhes. A calibração foi conduzida através de um algoritmo genético (AG), uma técnica que busca a melhor solução através de um processo baseado na seleção natural e genética, no qual as características que fazem um indivíduo estar bem adaptado ao meio ambiente são propagadas e aprimoradas de uma geração para outra (Coley, 1999).

No AG usado neste estudo, parte-se de uma população inicial composta por P soluções (indivíduos) criadas atribuindo-se valores aleatórios para os quatro parâmetros do modelo, u_f , u_c , q_c e k_j . Aplicando os operadores genéticos seleção, cruzamento, mutação, predação e elitismo, o AG procura direcionar a população em direção ao ótimo global ao longo de diversas gerações (Coley, 1999). Os operadores genéticos procuram replicar fenômenos naturais. A seleção pressiona a população fazendo com que indivíduos pouco adaptados tenham menor chance de sobrevivência. O grau de adaptação é medido através de uma função *fitness*. A função *fitness* escolhida para o AG usado é:

$$E_i = \sum_i \left\{ \left(\frac{u_i - \hat{u}_i}{\bar{u}} \right)^2 + \left(\frac{q_i - \hat{q}_i}{\bar{q}} \right)^2 + \left(\frac{k_i - \hat{k}_i}{\bar{k}} \right)^2 \right\} \quad (5)$$

em que E_i é o erro quadrático ortogonal estimado para um evento i ; 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 usando-se as Eqs. 1 a 4; e \bar{u} , \bar{q} e \bar{k} são os valores máximos observados de velocidade, fluxo e densidade. Os indivíduos de uma geração são ordenados em função do seu grau de adaptação; os mais bem adaptados têm maior chance de serem escolhidos para formar a próxima geração, através dos operadores seleção, cruzamento e elitismo.

O operador elitismo faz com que o indivíduo melhor adaptado de uma geração seja escolhido para compor a geração seguinte, garantindo-se que a melhor solução de uma geração não seja perdida em função do acaso durante os processos de seleção ou mutação. Os $(P - 1)$ componentes da nova geração são criados através dos operadores seleção e cruzamento. Os dois genitores do novo indivíduo são selecionados através de uma roleta de escolha, em que a probabilidade de um indivíduo ser selecionado para cruzamento é diretamente proporcional ao seu grau de adaptação: os mais bem adaptados têm maior chance de serem escolhidos que os pouco adaptados (Coley, 1999). Selecionados dois genitores, o operador cruzamento decide quais parâmetros de cada genitor formarão o seu descendente. O processo repete-se até que todos os $(P - 1)$ novos indivíduos sejam criados.

De tempos em tempos, aplicam-se os operadores mutação e predação à geração atual. A mutação consiste em alterar aleatoriamente o valor de um ou mais parâmetros de um indivíduo para gerar uma nova solução. A mutação evita a falta de variação na população, que tende a fazer com que os descendentes sejam réplicas dos seus genitores, o que é comum em populações geneticamente estagnadas (Coley, 1999). No algoritmo usado, adotou-se uma probabilidade $P_m = 0,2$ de ocorrer mutação numa dada geração. Em caso positivo, 10% da população, escolhidos ao acaso, têm pelo

menos um dos seus genes (parâmetros) substituídos por novos valores, gerados aleatoriamente. A predação serve para eliminar as piores soluções de uma geração e substituí-las por outras, geradas aleatoriamente. No AG usado, é aplicada de forma similar à mutação, com uma probabilidade $P_p = 0,3$ de ocorrer numa dada geração. A taxa de predação é 10% da população, quando a predação ocorre. Os indivíduos com piores valores de *fitness* são substituídos por novos indivíduos, gerados de forma randômica.

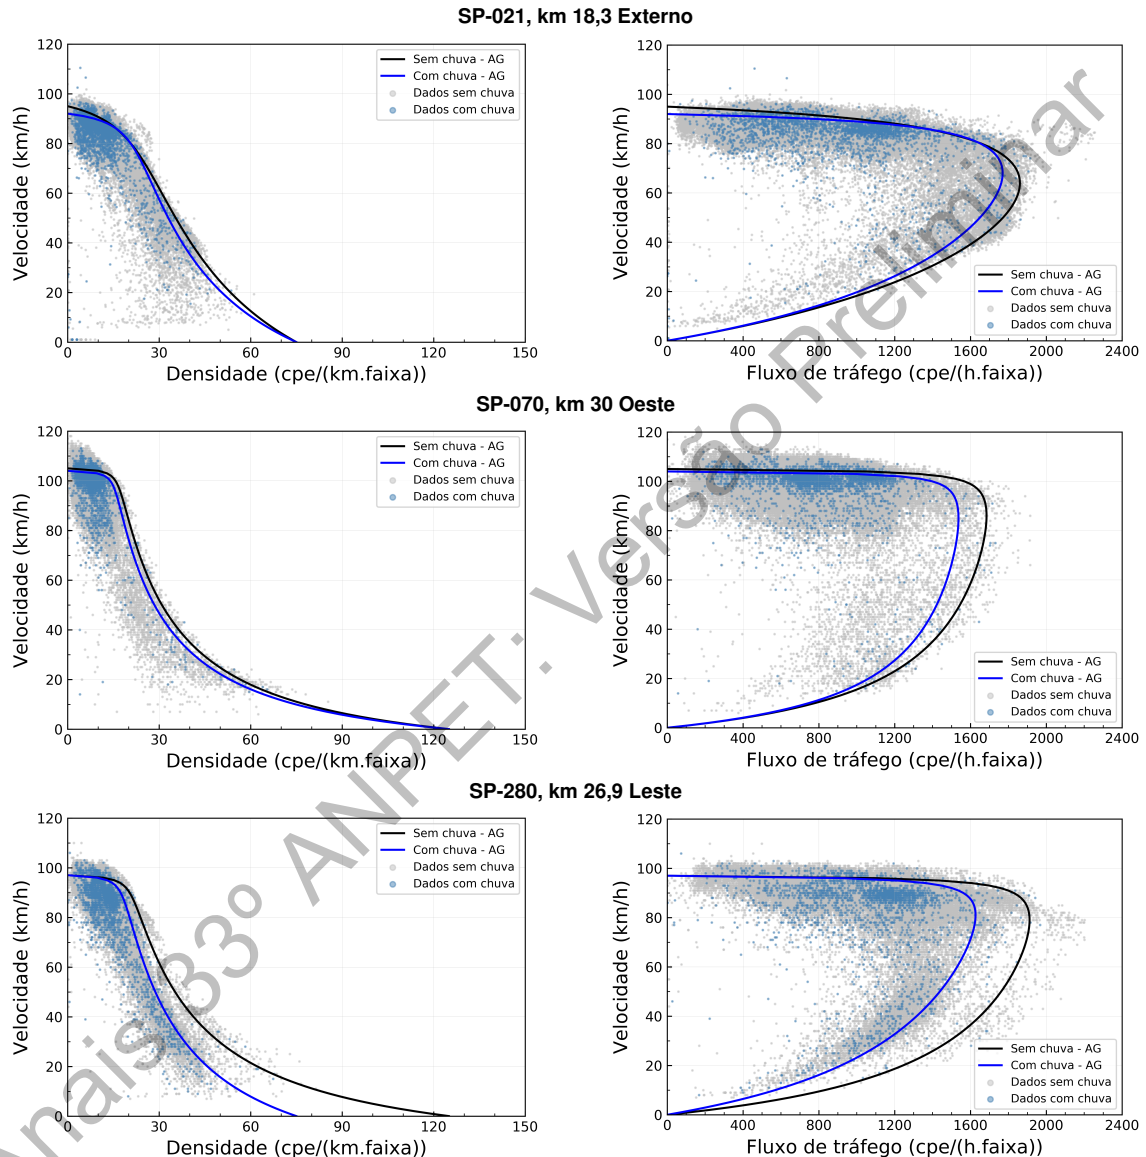


Figura 6: Resultados da calibração do modelo fluxo-velocidade-densidade de Van Aerde para três dos trechos estudados

A Figura 6 ilustra o resultado da calibração para três dos doze locais selecionados para este estudo. Os pontos cinzas correspondem aos dados brutos para os intervalos de observação sem chuva; os pontos azuis representam as observações sob tempo chuvoso. A Tabela 3 exibe os resultados dos 12 modelos calibrados através do algoritmo genético.

Tabela 3: Modelos fluxo-velocidade-densidade calibrados usando o algoritmo genético

Id	Tempo bom					Tempo chuvoso					Diferença (tempo bom – tempo chuvoso)				
	u_f	u_c	q_c	k_j	k_c	u_f	u_c	q_c	k_j	k_c	Δu_f	Δu_c	Δq_c	Δk_j	Δk_c
<i>Limite de velocidade de 100 km/h</i>															
1	95	64	1861	75	29,1	92	68	1770	75	26,0	-3%	6%	-5%	0%	-10%
2	94	78	1918	75	24,6	93	84	1646	113	19,6	-1%	8%	-14%	51%	-20%
3	95	76	1978	88	26,0	95	77	1829	81	23,8	0%	1%	-8%	-8%	-9%
4	97	79	1912	125	24,2	97	81	1627	75	20,1	0%	3%	-15%	-40%	-17%
5	98	84	1640	76	19,5	97	87	1566	78	18,0	-1%	4%	-5%	3%	-8%
6	99	81	1797	92	22,2	99	86	1617	78	18,8	0%	6%	-10%	-15%	-15%
<i>Limite de velocidade de 110 km/h</i>															
7	99	53	1561	108	29,5	99	53	1527	75	28,8	0%	0%	-2%	-31%	-2%
8	105	86	1685	125	19,6	104	85	1537	125	18,1	-1%	-1%	-9%	0%	-8%
<i>Limite de velocidade de 120 km/h</i>															
9	112	89	1824	82	20,5	111	93	1517	82	16,3	-1%	4%	-17%	0%	-20%
10	108	80	1575	108	19,7	109	76	1491	75	19,6	1%	-5%	-5%	-31%	0%
11	108	70	1661	75	23,7	108	69	1381	75	20,0	0%	-1%	-17%	0%	-16%
12	110	85	1574	75	18,5	108	86	1433	83	16,7	-2%	1%	-9%	11%	-10%
Média											-1%	2%	-10%	-5%	-11%

5. ANÁLISE DOS RESULTADOS

Observando-se a Tabela 3, é possível perceber que o fator mais afetado pela precipitação é a capacidade, pois em todos os locais estudados foi constatada redução significativa sob tempo chuvoso. A velocidade de fluxo livre, por outro lado, parece ser pouco afetada pela chuva, tendo apresentado uma redução máxima de 3 km/h entre tempo firme ou chuvoso. Quanto à velocidade na capacidade a variação está num intervalo de ± 6 km/h. A densidade na capacidade $k_c = q_c/u_c$ acompanha o comportamento da capacidade, pois esses dois parâmetros estão altamente correlacionados e também apresentou redução em todos os locais estudados.

A variabilidade dos valores da densidade de congestionamento é maior: em cinco dos 12 locais, houve uma nítida redução; em 3 outros verificou-se aumento e, k_j ficou praticamente inalterada em 4 locais. Isso pode ser explicado pela raridade de casos em que se observa chuva concomitante com congestionamentos severos. Isso pode ser visto na Figura 5, pela escassez de pontos na região em que a velocidade é inferior a 20 km/h e a taxa de fluxo é menor que 800 cpe/(h.faixa). A falta de informação sobre essa região do modelo faz com que o AG encontre valores bastante dispersos para a densidade de congestionamento.

6. CONSIDERAÇÕES FINAIS

Os resultados indicam que a precipitação impacta o fluxo de tráfego nas rodovias no estado de São Paulo. A velocidade de fluxo livre, em seis locais estudados apresentou redução e em cinco locais a velocidade não se alterou com o tempo chuvoso. O efeito mais nítido é sobre a capacidade, com redução em todos os pontos estudados e com uma redução média de 10%. A densidade na capacidade também apresenta uma redução, ainda que a velocidade na capacidade não apresente uma redução significativa.

Esses resultados podem ser explicados pelo fato de a velocidade livre representar o desejo do motorista em viajar em uma determinada velocidade, e isto só é possível quando o fluxo na via está baixo. Dessa forma, com o fluxo veicular baixo, a chuva não interfere na sensação de segurança e o motorista não reduz a velocidade de forma significativa. No entanto, quando está chovendo

e o fluxo é mais elevado, próximo à capacidade, os motoristas tendem a aumentar a distância de segurança entre os veículos, diminuindo a densidade na capacidade e, conseqüentemente, causando uma redução na capacidade da via sob condições chuvosas. Isso é corroborado pela densidade na capacidade verificada neste estudo, que se reduz sob mau tempo.

Parece não haver um efeito claro da chuva sobre a densidade de congestionamento; entretanto, isso pode ser um artefato do modelo em função da baixa ocorrência de congestionamentos severos sob chuva. Essa falta de informação sobre situações onde a densidade é muito alta e a velocidade é muito baixa pode causar algum viés na calibração do parâmetro k_j , visto que o modelo de Van Aerde não é muito sensível às variações nesse parâmetro.

Agradecimentos À ARTESP e ao IPMet que gentilmente cederam os dados utilizados nesta pesquisa, que teve apoio financeiro 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

- Andrade, G. R. e J. R. Setti (2011). Método para caracterização e classificação de trechos homogêneos rodoviários. In 7º Congresso Brasileiro de Rodovias e Concessões – CBRReC 2011, Foz do Iguaçu. ABCR.
- Austin, P. M. (1987). Relation between measured radar reflectivity and surface rainfall. *Monthly Weather Review* 115(5), 1053–1070.
- Billot, R., N. El Faouzi, e F. De Vuyst (2009). Multilevel assessment of the impact of rain on drivers' behavior: Standardized methodology and empirical analysis. *Transportation Research Record: Journal of the Transportation Research Board* 2107, 134–142.
- Brilon, W. e M. Ponzlet (1996). Variability of speed-flow relationships on German autobahns. *Transportation Research Record: Journal of the Transportation Research Board* 1555, 91–98.
- Caleffi, F., S. T. Lucchesi, M. J. Anzanello, e H. B. B. Cybis (2016). Influência das condições climáticas e de acidentes na caracterização do comportamento do tráfego em rodovias. *Transportes* 24(4), 57–63.
- Camacho, F. J., A. García, e E. Belda (2010). Analysis of impact of adverse weather on freeway free-flow speed in Spain. *Transportation Research Record: Journal of the Transportation Research Board* 2169, 150–159.
- Cardoso, J. M., L. Assirati, e J. R. Setti (2019). Calibração de modelos fluxo-velocidade-densidade a partir de bases de dados muito grandes. In *Anais do XXXIII Congresso Nacional de Pesquisa em Transportes*, Balneário Camboriú. ANPET.
- Coley, D. A. (1999). *An introduction to genetic algorithms for scientists and engineers*. World Scientific Publishing Company.
- Edwards, J. B. (1999). Speed adjustment of motorway commuter traffic to inclement weather. *Transportation Research Part F: Traffic Psychology and Behaviour* 2(1), 1–14.
- Goodwin, L. C. (2002). Weather impacts on arterial traffic flow. Technical report, Mitretek Systems for the Road Weather Management Program, Virginia.
- Hawkins, R. K. (1988). Motorway traffic behaviour in reduced visibility conditions. In *Second International Conference on Vision in Vehicles*, Nottingham, pp. 9–18. Vision in Vehicles II.
- Hranac, R., E. Sterzin, D. Krechmer, H. A. Rakha, M. Farzaneh, M. Arafeh, et al. (2006). Empirical studies on traffic flow in inclement weather. Technical report, Federal Highway Administration, Washington, D.C.
- Ibrahim, A. T. e F. L. Hall (1994). Effect of adverse weather conditions on speed-flow-occupancy relationships. *Transportation Research Record: Journal of the Transportation Research Board* 1457, 184–191.
- Maze, T., A. M., e G. Burchett (2006). Whether weather matters to traffic demand, traffic safety, and traffic operations and flow. *Transportation Research Record: Journal of the Transportation Research Board* 1948, 170–176.
- Moreira, R. M., S. L. Costa, e F. J. Craveiro (2017). Impacto de condições ambientais adversas na velocidade de fluxo livre e de fluxo de saturação em vias urbanas. In *Anais do XXXI Congresso Nacional de Pesquisa em Transportes*, Recife, pp. 3140–3151. ANPET.
- Ono, T., S. Hattori, H. Hasegawa, e S.-i. Akamatsu (2000). Digital mapping using high resolution satellite imagery based on 2D affine projection model. *International Archives of Photogrammetry and Remote Sensing* 33(B3/2; Part 3), 672–677.
- 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., M. Farzaneh, M. Arafteh, e E. Sterzin (2008). Inclement weather impacts on freeway traffic stream behavior. *Transportation Research Record: Journal of the Transportation Research Board* 2071, 8–18.
- Smith, B. L., K. G. Byrne, R. B. Copperman, S. M. Hennessy, e N. J. Goodall (2004). An investigation into the impact of rainfall on freeway traffic flow. In *83rd Annual Meeting of the Transportation Research Board*, Washington, D.C.
- TRB (2000). *Highway Capacity Manual*. Washington, D.C.: Transportation Research Board, National Research Council.
- TRB (2016). *Highway Capacity Manual*. Washington, D.C.: Transportation Research Board, National Research Council.
- Van Aerde, M. e H. Rakha (1995). Multivariate calibration of single regime speed-flow-density relationships [road traffic management]. In *Pacific Rim TransTech Conference. 1995 Vehicle Navigation and Information Systems Conference Proceedings. 6th International VNIS. A Ride into the Future*, pp. 334–341. IEEE.
- Wilson, J. W., N. A. Crook, C. K. Mueller, J. Sun, e M. Dixon (1998). Nowcasting thunderstorms: A status report. *Bulletin of the American Meteorological Society* 79(10), 2079–2099.
- Zechin, D., D. R. Acosta, H. B. B. Cybis, e R. Abreu (2018). Influência da chuva na probabilidade de breakdown. In *XXXII Congresso Nacional de Pesquisa em Transportes*, Gramado, pp. 3577–3588. ANPET.

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