

Estimativa de velocidades médias em Fortaleza: comparação entre radares de fiscalização e a API Google Distance Matrix

Average speed estimation in Fortaleza: comparison between enforcement radars and the Google Distance Matrix API

Marco Antonio Machado de Araújo¹ e Manoel Mendonça de Castro Neto^{✉, 2}

¹Universidade Federal do Ceará, Fortaleza, Ceará, Brasil, marcoaraujo86@gmail.com, ☎ 0009-0002-7312-0815

²Universidade Federal do Ceará, Fortaleza, Ceará, Brasil, manoel@det.ufc.br, ☎ 0000-0002-6317-4863

Recebido: 14 de agosto de 2025

Revisão final: 2 de maio de 2026

Aceito: 24 de junho de 2026

Publicado: 2 de setembro de 2026

Editor Associado:

Sara Ferreira 

Universidade do Porto, Portugal

Palavras-chave:

Estimação de velocidade média,
Nível de serviço do tráfego,
Planejamento e operação do tráfego.

Keywords:

Mean speed estimation,
Traffic level of service,
Traffic planning and operations.

DOI: [10.58922/transportes.v34.e3166](https://doi.org/10.58922/transportes.v34.e3166)



RESUMO

A gestão de tráfego urbano requer dados de tempo de viagem confiáveis. Fontes de dados massivos, como APIs comerciais, são alternativas de baixo custo a sensores físicos, mas as discrepâncias entre elas, especialmente em cidades de países em desenvolvimento, precisam ser mais bem compreendidas. Este artigo realiza uma análise comparativa pareada entre as estimativas de velocidade média da API Distance Matrix do Google e as de sensores de fiscalização eletrônica (FE). O estudo cobriu 47 trechos urbanos em Fortaleza durante o pico da manhã em 69 dias úteis. Os resultados revelam forte correlação ($r > 0,93$) para amostras com pelo menos 25 veículos coletados em 15 minutos, validando a API em condições de maior fluxo. Contudo, foi identificado um viés dependente da velocidade: a API tende a superestimar em até +4,0 km/h as velocidades em tráfego lento e a subestimá-las em até -6,5 km/h em regimes de maior fluidez. Nas velocidades mais frequentes (10-40 km/h), as diferenças ficaram na faixa de -3,1 a +2,4 km/h.

ABSTRACT

Urban traffic management relies on reliable travel time data. Big data sources, such as commercial APIs, are low-cost alternatives to physical sensors, but the discrepancies between them need to be better understood, especially in developing countries. This paper performs a paired comparative analysis between average speed estimates from Google's Distance Matrix API and those from enforcement radar (FE) sensors. The study covered 47 urban sections in Fortaleza, during the morning peak period over 69 weekdays. The results reveal a strong correlation ($r > 0.93$) for samples with at least 25 vehicles captured in 15 minutes, validating the API under higher flow conditions. However, a speed-dependent bias was identified: the API tends to overestimate speeds by up to +4.0 km/h in slow traffic and underestimate them by up to -6.5 km/h at higher speeds. For the most frequent speeds (10-40 km/h), the differences remained within a narrower range of -3.1 to +2.4 km/h.

1. Introdução

Dados de tempo de viagem confiáveis, que geram métricas de desempenho como velocidade média e atraso, são importantes para o planejamento e a operação de redes viárias urbanas. Tais dados subsidiam o monitoramento do tráfego, a simulação de intervenções e a estimativa de acessibilidade em contextos urbanos complexos (Genser *et al.*, 2021; Fink *et al.*, 2024). Tradicionalmente, a coleta desses dados é feita por sensores fixos instalados na via, como laços indutivos, radares e câmeras com reconhecimento óptico de caracteres (OCR - *Optical Character Recognition*), amplamente utilizados por órgãos de gestão do tráfego (He, Chow & Zhang, 2019; Araújo & Castro Neto, 2024).

Esses dispositivos oferecem uma boa acurácia, porém apresentam custos elevados de instalação e manutenção, cobertura restrita e falhas operacionais. Além disso, a manutenção desses sistemas pode ser complexa, com problemas como a descalibração de sensores ou a necessidade de intervenções físicas na via para manutenção, que podem interromper o fluxo de tráfego. Além disso, a cobertura espacial limitada implica que muitos segmentos importantes da rede viária permanecem sem monitoramento direto, exigindo o uso de modelos de interpolação que nem sempre capturam a dinâmica local do tráfego.

Nos últimos anos, a difusão de smartphones e tecnologias de geolocalização viabilizou novas fontes de dados baseadas na movimentação de usuários. Plataformas como Google Maps, Here Technologies e

TomTom passaram a disponibilizar estimativas de tempo de viagem por meio de APIs comerciais, que integram dados históricos e em tempo real de milhões de dispositivos (Christodoulou *et al.*, 2020; Google, 2025). Essas soluções oferecem vantagens em capilaridade, atualização e custo, sendo promissoras para cidades em desenvolvimento. As principais vantagens dessas fontes de dados massivos (big data) são a sua cobertura geográfica virtualmente completa e o baixo custo de aquisição quando comparado à instalação de nova infraestrutura física. No entanto, como desvantagem, a natureza dos algoritmos de processamento dessas plataformas é frequentemente proprietária e de conhecimento restrito. Devido a isso, surge a motivação de estudos que avaliem as suas estimativas.

Kociánová, Kníž & Pisca (2025) compararam os dados de velocidade média da API com os dados estimados pela velocidade média entre radares em cinco trechos de rodovias rurais de pista simples na Eslováquia, com dados agregados em 5 minutos. Os erros absolutos médios (MAE) foram de 5,5 a 8,8 km/h e o erro percentual absoluto médio (MAPE) geral foi de 10%. Os autores observaram que as estimativas da Google não foram confiáveis em locais com baixos níveis de sinal GPS. Os autores também perceberam que a API do Google tendeu a demorar a reconhecer quedas bruscas de velocidade média.

Thebit & Cunha (2017) compararam estimativas de velocidade média estimadas pela API da plataforma Here Traffic com as estimadas com dados de laços indutivos em um trecho de autoestrada brasileira (BR-116). Os autores concluíram que os dados provenientes da API apresentaram maior dispersão e valores levemente abaixo dos estimados pelos sensores. Outros estudos que buscam validar ou comparar as estimativas de tempo de viagem ou de velocidade média da API do Google, ou de plataformas similares, com outras fontes de dados são Wagner *et al.* (2020) e Chamberlin, Haghighi & Fayyaz (2019).

Na revisão da literatura não foram encontrados estudos que comparem as estimativas de dados de APIs de plataformas como a Distance Matrix do Google em trechos urbanos de cidades brasileiras. Essa lacuna é cada vez mais importante devido ao uso cada vez mais disseminado desses tipos de dados (crowdsourced data). Recentemente, no Brasil, Cançado (2024) usou dados de tempo de viagem da APIs Distance Matrix do Google Maps para fazer uma análise da confiabilidade do tempo de viagem em rodovias de pista dupla de Minas Gerais.

Diante disso, o objetivo deste artigo é comparar a velocidade média em vias urbanas, estimada de duas formas: (i) a partir dos tempos de viagem médios estimados pela API Distance Matrix do Google Maps; e (ii) a partir dos tempos entre os instantes de passagem dos veículos por pares de sensores de fiscalização eletrônica (FE). Considerando que os valores obtidos com a FE sejam os de referência (ground-truth), assim como fez Kociánová, Kníž & Pisca (2025), este trabalho é visto como de validação das estimativas da API do Google. Com base em 47 trechos de vias urbanas de Fortaleza, Ceará, a análise busca caracterizar a correspondência entre os dois métodos sob diferentes condições de tráfego, identificando as implicações práticas das diferenças para o planejamento e a gestão do tráfego urbano. A velocidade média foi a variável escolhida, ao invés do tempo de viagem, por ser a principal medida de desempenho de vias urbanas. Além disso, como ela incorpora a extensão do trecho, permite que os resultados e as análises não dependam desse atributo.

2. Método

O método deste estudo foi estruturado em duas etapas sequenciais. A primeira, detalhada na seção 2.1, compreende a caracterização da área de estudo e descreve os procedimentos de coleta e tratamento dos dados das duas fontes de dados: os sensores de fiscalização eletrônica (FE) e a API Distance Matrix do Google. A segunda etapa, apresentada na seção 2.2, apresenta a análise estatística para realizar a comparação pareada das estimativas de velocidade.

2.1. Coleta de dados

O estudo foi conduzido na cidade de Fortaleza/CE, que tem população superior a 2,4 milhões de habitantes e frota veicular de aproximadamente 1,2 milhão de veículos (IBGE, 2023). Como outras

capitais, Fortaleza enfrenta pontos de congestionamentos nos horários de pico. O estudo abrangeu 47 trechos de vias urbanas, monitoradas por radares de FE (Figura 1). Os equipamentos de fiscalização eletrônica do estudo são da marca/modelo: ATLANTA/ATSMX_LITE, mITS/mITS Loop e FOCALLE/F-DIP. Eles medem velocidade com detectores do tipo intrusivo, instalados por faixa de tráfego. Todos os equipamentos possuem tecnologia Reconhecimento Óptico de Caracteres (OCR) para leitura de placas de todos os veículos detectados. A seleção dos trechos se baseou nos radares localizados em vias arteriais e que estivessem operando de forma contínua, segundo a base de dados fornecida pela Autarquia de Trânsito da cidade de Fortaleza.

A aquisição dos dados para a avaliação de ambos os métodos seguiu um procedimento detalhado. Para ambos os métodos de estimação avaliados, os dados foram coletados entre 14 de agosto e 29 de novembro de 2024, exclusivamente em dias úteis (segunda a sexta-feira, sem feriados), totalizando 69 dias de observação. As medições ocorreram diariamente no intervalo das 6h30 às 8h30, segmentado em janelas de 15 minutos. Foram considerados apenas automóveis e utilitários, devido a melhor classificação veicular desses tipos de veículos pelos sensores (Braga, 2016).

Para os dados dos radares de FE, o tempo de viagem de cada veículo foi calculado pela diferença entre os instantes de passagem pelos sensores, obtidos por meio de leitura de placas. Valores extremos de veículos individuais foram eliminados conforme adaptação do método de média móvel de Alves (2018). Neste procedimento, para cada veículo, calculou-se um tempo de viagem de referência usando a média dos tempos de quatro veículos adjacentes: os dois que passaram imediatamente antes e os dois que passaram imediatamente depois. O tempo de viagem de um veículo foi então classificado como outlier e removido da amostra se seu valor fosse 50% superior a essa média de referência.

A velocidade média de cada intervalo de 15 minutos foi estimada pela razão entre a extensão do trecho viário e a média dos tempos de viagem, sendo, portanto, uma estimativa da velocidade média no espaço. Para veículos que cuja viagem não ocorreu completamente dentro de um determinado intervalo de 15 minutos, adotou-se o seguinte critério de alocação de intervalo de 15 minutos ao veículo: para um determinado intervalo de 15 minutos, foram alocados os veículos cuja média entre os instantes de passagem pelos dois sensores se encontra nesse intervalo. Por exemplo, para um veículo que passou no primeiro radar às 7:56 e no segundo radar às 8:06, a média entre os dois valores é 8:01, portanto esse veículo foi alocado ao intervalo 8:00–8:15. Esse critério garante que o veículo seja alocado ao intervalo no qual ele passou mais tempo. No caso do exemplo, o veículo passou 6 minutos no período 8:00–8:15 e 4 minutos no anterior.

Para a API Distance Matrix do Google Maps, foram realizadas consultas no modo de transporte “driving”, que engloba carros e utilitários, compatível com os tipos de veículo considerados nos dados




Figura 1 • Mapa com as vias de Fortaleza analisadas

analisados dos radares. As requisições foram programadas utilizando o parâmetro “departure_time” para especificar o início de cada janela de 15 minutos. Foi utilizado a opção de modelo de tráfego “best_guess”, que combina condições históricas e em tempo real para fornecer a estimativa mais provável de tempo de viagem. É importante notar que o algoritmo subjacente a essa estimativa é proprietário do Google (Google, 2025). As consultas abrangeram a mesma cobertura espacial e temporal da amostra obtida por fiscalização eletrônica; os pontos origem–destino coincidem com as localizações dos radares. A API disponibilizou estimativas do tempo médio de viagem a cada 15 minutos. Esses valores foram divididos pelas extensões dos trechos para se obter as velocidades médias espaciais, como feito com os dados dos radares.

2.2. Comparação entre as estimativas

Para melhor entender as diferenças entre as estimativas, as comparações foram feitas desagregadas por três fatores. Primeiro, pelo tamanho da amostra de tempos de viagem de campo, ou seja, pelo número de veículos registrados em ambos os radares de FE (variável n_{FE}) no trecho e no período de 15 minutos. Isso permite analisar se um maior tamanho amostral, o que resultaria em estimativas de velocidade média mais precisas pelos sensores, estaria em maior concordância com as estimativas da API. Ressalta-se que este fator (n_{FE}) representa o tamanho da amostra da estimativa pela FE, e não o volume de tráfego total. Os outros dois fatores foram o horário e a velocidade média, para avaliar se as condições de tráfego afetam a similaridade das estimativas. As diferenças entre as estimativas foram feitas com base no coeficiente de correlação (r), erro percentual absoluto médio (MAPE); regressão linear e intervalos de confiança para dados pareados com 95% de grau de confiança. Os MAPEs foram calculados pela seguinte Equação 1:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|API_i - FE_i|}{FE_i} \quad (1)$$

Em que: MAPE é o erro percentual absoluto médio; API_i é velocidade média do trecho no período de 15 minutos estimada pela API do Google; FE_i é a velocidade média do trecho no período de 15 minutos estimada pelos radares de fiscalização eletrônica; e n é o tamanho da amostra.

3. Resultados e discussão

A Figura 2 apresenta as comparações por tamanho da amostra de veículos no intervalo de 15 minutos (n_{FE}). O número n , entre parênteses, acima de cada gráfico, indica o número de pontos, ou seja, o número de intervalos de 15 minutos considerados. De modo geral, as correlações foram fortes ($r > 0,93$) para $n_{FE} > 25$. Para a faixa mais baixa ($n_{FE} < 25$ veículos), a correlação foi de 0,75. As retas de regressão (em vermelho) confirmam essa tendência: à medida que n_{FE} aumenta, o coeficiente angular se aproxima de 1,0 e o intercepto de zero, alinhando-se à reta de igualdade entre as estimativas (reta de 45°, tracejada). A comparação entre as retas de regressão e de identidade indica que, em média, para velocidades médias mais baixas, as estimativas da API tendem a ser maiores do que as da FE, e que, para velocidades mais altas, ocorre o contrário.

As áreas sombreadas em azul na Figura 2 representam uma faixa de tolerância de ± 5 km/h em torno da reta de igualdade. Percebe-se que quanto maior n_{FE} , maior a proporção de pontos dentro dessa faixa. Para n_{FE} maior que 25, o R^2 se estabiliza. A maior similaridade entre as estimativas para amostras veiculares maiores pode indicar maior qualidade das estimativas da API, pois quanto maior o número de veículos amostrados pelos radares, melhor tende a ser a estimação da velocidade média do trecho pela FE, a qual pode servir como referência. A API se baseia em dados de *Floating Car Data* (FCD), que utiliza a localização anônima de smartphones e veículos como sensores móveis (Google, 2025), portanto trechos e horários com maior fluxo de veículos (maior n_{FE}) também tendem a gerar estimativas mais estáveis e alinhadas com a realidade medida em campo. A estabilização do R^2 a partir




Figura 2 • Velocidades médias FE x API, por número de veículos amostrados (n_{FE})

de $n_{FE} > 25$ sugere que este pode ser um limiar mínimo de densidade amostral para que se obtenha uma concordância satisfatória entre as fontes de dados neste contexto.

Os resultados da comparação por n_{FE} e hora do dia estão apresentados na Tabela 1 e Figura 3. Na Tabela 1, nota-se que para $n_{FE} > 25$, as correlações foram maiores e os MAPEs menores em todos os horários, com uma notável exceção às 6h30, quando trechos com $n_{FE} > 100$ resultaram em uma correlação inesperadamente baixa ($r = 0,53$). Dentre as rotas avaliadas nesse horário, a R17-2 (Av. Raul Barbosa-SN), conhecida por apresentar congestionamentos severos a partir das 6h45, concentrou o maior número de observações ($n = 47$). Embora a formação de filas intermitentes nesse período de transição de tráfego seja uma possível explicação para a anomalia, uma causa definitiva para essa discrepância isolada não pôde ser estabelecida no escopo deste trabalho. Dessa forma, esse resultado é reconhecido como uma limitação da análise e um ponto que merece investigação futura. Ressalta-se, contudo, que essa exceção pontual não invalida a forte concordância geral observada entre as estimativas nas demais condições avaliadas.

A Figura 3 mostra que nas classes $n_{FE} \geq 75$ a API estimou velocidades médias levemente superiores às da FE (diferenças entre 0,0 e 1,9 km/h, considerando os limites mais extremos dos intervalos). Por outro lado, para amostras menores, a API tendeu a fornecer velocidades inferiores às da FE (diferenças de 0,3 km/h a -2,4 km/h). Comparando-se os intervalos dentro de cada categoria de n_{FE} , não parece haver um padrão bem definido das diferenças das estimativas de velocidade média em função do horário.

As comparações com base na velocidade média da FE estão na Figura 4, que traz os intervalos de

Tabela 1 • Tamanho da amostra (n), coeficiente de correlação (r) e erro proporcional absoluto médio (MAPE) entre as estimativas, por número de veículos amostrados (n_FE) e horário

Hora	n_FE < 25			n_FE 25-49			n_FE 50-74		
	n	r	MAPE	n	r	MAPE	n	r	MAPE
06:30	966	0,75	0,13	554	0,93	0,10	215	0,95	0,08
06:45	953	0,76	0,15	617	0,92	0,10	308	0,90	0,09
07:00	887	0,79	0,16	604	0,92	0,12	324	0,91	0,10
07:15	873	0,75	0,19	595	0,93	0,13	369	0,92	0,12
07:30	922	0,74	0,18	582	0,93	0,12	409	0,92	0,14
07:45	931	0,75	0,21	597	0,93	0,13	386	0,92	0,13
08:00	981	0,72	0,19	621	0,94	0,13	403	0,93	0,11
08:15	920	0,68	0,21	588	0,94	0,13	424	0,94	0,09
Média	929	0,74	0,18	595	0,93	0,12	355	0,92	0,11

Hora	n_FE 75-99			n_FE > 100		
	n	r	MAPE	n	r	MAPE
06:30	70	0,89	0,08	101	0,53	0,11
06:45	161	0,91	0,08	123	0,91	0,09
07:00	137	0,86	0,09	126	0,91	0,10
07:15	174	0,94	0,11	153	0,92	0,09
07:30	229	0,96	0,10	180	0,96	0,08
07:45	229	0,96	0,12	187	0,96	0,10
08:00	189	0,96	0,09	193	0,93	0,09
08:15	147	0,94	0,08	188	0,91	0,08
Média	167	0,93	0,09	156	0,88	0,09

confiança da média das diferenças pareadas (API menos FE). Nota-se uma tendência (viés) de a API superestimar em faixas de baixa velocidade (até 25 km/h) e subestimar a partir de 25 km/h. A maior discrepância ocorre na faixa de 50 a 55 km/h, onde a API chega a subestimar a velocidade em 6,5 km/h, em média. Uma hipótese para essa subestimação em velocidades mais altas podem ser explicadas devido a API provavelmente incorporar o limite de velocidade regulamentar e um comportamento de condução médio mais conservador em seus modelos, resultando em uma estimativa de velocidade média menor. Esse resultado é consistente com a pesquisa de [He, Chow & Zhang \(2019\)](#), que também observaram diferenças dependentes das condições de tráfego ao comparar a API do Google com dados de sensores em Hong Kong.

A precisão das estimativas da API é maior nas velocidades intermediárias, o que está associado, pelo menos em parte, ao tamanho amostral: essas classes concentram a maior parte das observações (n). Para as velocidades médias entre 10 e 40 km/h, as mais frequentes na amostra, as diferenças pontuais foram de +2,4 a -3,1 km/h.

4. Conclusão

A comparação entre as estimativas de velocidade da API Distance Matrix do Google Maps e dos dados de radares de fiscalização eletrônica (FE) estabeleceu forte correlação entre os dois métodos, especialmente quando o tamanho da amostra de veículos registrados em pares de radares de FE (n_FE) é superior a 25. A crescente similaridade com o aumento de n_FE sugere maior validação à API, pois quanto maior n_FE, melhor tende a ser a estimativa da velocidade média a partir dos dados dos radares.

Com relação às análises por classes de velocidade, a análise indica um viés sistemático: a API tende a superestimar (+4,0 km/h) as velocidades em condições de tráfego lento (0–5 km/h). Uma hipótese de causa para esse viés é o que concluíram [Kociánová, Kníž & Pisca \(2025\)](#), que a API do Google tende a demorar a reconhecer quedas bruscas de velocidade média. Por outro lado, a API tende a subestimar a velocidade (-6,5 km/h) em condições de grande fluidez (50–55 km/h). Essas informações de vieses




Figura 3 • Intervalos de confiança de 95% das médias das diferenças ($D=API-FE$), por número de veículos amostrados (n_{FE}) e por horário




Figura 4 • IC95% da Diferença API - FE por Faixa de Velocidade Real

podem guiar analistas a fazerem esses ajustes em suas estimativas em situações de congestionamento e de fluxo praticamente livre.

Para as classes de velocidade mais frequentes na amostra (10 a 40 km/h), as estimativas pontuais das diferenças médias variaram de +2,4 a -3,1 km/h. Esses valores podem ser considerados relativamente pequenos, porém não desprezíveis, em análises do nível de serviço do tráfego de vias urbanas segundo a metodologia do Highway Capacity Manual (NAS, 2022). A partir da tabela 16-3 do manual, para vias com velocidade de fluxo livre de 56 km/h, as diferenças de velocidades entre classes adjacentes de nível de serviço vão de 4,8 km/h (entre as classes D e E) a 8,0 km/h (entre as classes A e B). Na mesma tabela, as diferenças entre as velocidades de fluxo livre, que são base para definir o nível de serviço, são de 8,0 km/h (5 milhas/hora).

Com relação à hora do dia, em contrapartida, não foram observados padrões claros de variação nas diferenças das estimativas, o que possivelmente se deve à agregação de dados de vias com diferentes níveis de saturação em um mesmo horário. Para o período de análise considerado neste trabalho, das 6h30 às 8h30, os efeitos do fator hora do dia são os efeitos causados pela variação das demandas e dos resultantes níveis de serviço.

Como principais limitações deste estudo, cita-se que ele se concentrou no pico da manhã e em veículos leves, não sendo diretamente generalizável para outros horários ou modos de transporte. Além disso, a natureza “caixa-preta” do algoritmo do Google impede uma análise causal mais aprofundada acerca das diferenças observadas.

Como recomendações para estudos futuros, as comparações entre as estimativas podem ser feitas com base nas características físicas e operacionais das vias, para se compreender melhor as possíveis causas das diferenças entre os métodos. Além disso, trabalhos futuros podem avaliar os impactos das diferenças das estimativas nos resultados de estudos de tráfego que se baseiam na velocidade média ou no tempo de viagem, como análises de nível de serviço e de confiabilidade de tempo de viagem de vias urbanas.

Ainda como sugestão, trabalhos futuros podem englobar estimativas feitas por outros métodos, como GPS de veículos de transporte coletivo e de transporte por aplicativos, seja por automóvel ou por motocicleta. Outros estudos podem ainda analisar os efeitos da resolução temporal das coletas via API, investigando se a agregação de dados capturados em maior frequência (a cada minuto, por exemplo) altera as diferenças entre as duas estimativas. Por fim, a incorporação de variáveis externas, como condições climáticas e ocorrência de eventos ou incidentes, poderá contribuir para um entendimento mais abrangente das condições sob as quais as estimativas de diferentes métodos convergem ou divergem, aprimorando escolha ou a aplicação combinada dessas fontes de dados no planejamento e na operação do tráfego urbano.

Em conclusão, este trabalho não teve como objetivo concluir qual dos dois métodos de estimação é superior. O objetivo foi avaliar as diferenças das estimativas. Além disso, considerando os dados da FE como referência, por serem observações precisas dos instantes de passagem dos veículos pelos radares, entende-se que este estudo traz um esforço de validação das estimativas da API do Google. Porém, ressalta-se que as estimativas de velocidade média dos radares de FE também estão sujeitas a erros –como qualquer método de estimação–, pois somente parte dos veículos são registrados pelos radares.

Agradecimentos

O presente trabalho foi realizado com o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES). Os autores agradecem à Autarquia de Municipal de Trânsito e Cidadania (AMC), da Prefeitura Municipal de Fortaleza, pelos dados.

Declaração de contribuição de autoria CRediT

Marco Antonio Machado de Araújo: Curadoria de dados, Análise formal, Investigação, Metodologia, Software/programas de computador, Visualização, Escrita – esboço original, Escrita – revisão e edição. *Manoel Mendonça de Castro Neto*: Conceitualização, Análise formal, Aquisição de financiamento, Investigação, Metodologia, Administração do projeto, Recursos, Supervisão, Escrita – revisão e edição.

Uso de tecnologia assistida por inteligência artificial

Os autores usaram a ferramenta ChatGPT apenas para correção gramatical e apoio no desenvolvimento das rotinas computacionais para tratamento dos dados. Os autores assumem total responsabilidade pelo uso de tais ferramentas.

Declaração de conflitos de interesse

Os autores declaram não haver conflito de interesses a ser informado.

Data availability statement

Os dados que suportam este estudo foram fornecidos pela autarquia Municipal de Trânsito e Cidadania de Fortaleza e os autores não têm o direito de redistribuí-los. As solicitações devem ser dirigidas ao provedor dos dados.

Referências

- Alves, A. S. (2018). Comparação da variabilidade do tempo de viagem entre automóveis e ônibus em vias urbanas de Fortaleza. Mestrado (dissertação), Universidade Federal do Ceará, Fortaleza.
- Araújo, M. A. M. & M. M. Castro Neto (2024). Confiabilidade do tempo de viagem em vias de Fortaleza: análise exploratória com dados de fiscalização eletrônica. In *Anais do 38º Congresso de Pesquisa e Ensino em Transportes (Florianópolis, SC)*, Florianópolis. URL: <https://proceedings.science/anpet/anpet-2024/trabalhos/confiabilidade-do-tempo-de-viagem-em-vias-de-fortaleza-analise-exploratoria-com?lang=pt-br> [visitado 14/08/2025].
- Braga, C. K. V. (2016). Qualidade da classificação veicular por laços indutivos do sistema de fiscalização eletrônica de Fortaleza. Monografia (conclusão de curso), Universidade Federal do Ceará, Fortaleza.
- Cançado, A. L. E. (2024). Análise da confiabilidade do tempo de viagem em rodovias de pista dupla de Minas Gerais. Mestrado (dissertação), Universidade Federal de Minas Gerais, Belo Horizonte. URL: <https://hdl.handle.net/1843/77989>.
- Chamberlin, R., N. Haghighi, & K. Fayyaz (2019). HERE data validation. Relatório técnico UT-19.25, Utah Department of Transportation, Utah. URL: https://rosap.nrl.bts.gov/view/dot/61720/dot_61720_DS1.pdf.
- Christodoulou, A. L., L. Dijkstra, P. Christidis, *et al.* (2020). A fine resolution dataset of accessibility under different traffic conditions in European cities. *Scientific Data* 7(1), 279. DOI:10.1038/s41597-020-00619-7, PMID:32843662.
- Fink, C., E. Willberg, R. Klein, *et al.* (2024). A travel time matrix data set for the Helsinki Region 2023 that is sensitive to time, mode and interpersonal differences, and uses open data and novel open-source software. *Scientific Data* 11(1), 858. DOI:10.1038/s41597-024-03689-z, PMID:39122727.
- Genser, A., N. Hautle, M. Makridis, *et al.* (2021). An experimental urban case study with various data sources and a model for traffic estimation. *Sensors* 22(1), 144. DOI:10.3390/s22010144, PMID:35009687.
- Google (2025). *Google Maps Platform Documentation*. Google. URL: <https://developers.google.com/maps/documentation> [visitado 14/08/2025].
- He, Z., C.-Y. Chow, & J.-D. Zhang (2019). A comparative analysis of journey time from Google Maps and Intelligent Transport System in Hong Kong. In *Anais do 2019 IEEE 21st International Conference on High Performance Computing and Communications; IEEE 17th International Conference on Smart City; IEEE 5th International Conference on Data Science and Systems (HPCC/SMARTCITY/DSS)*, Zhangjiajie, China. IEEE. DOI:10.1109/HPCC/SmartCity/DSS.2019.00366.
- IBGE (2023). *Panorama do Censo 2022*. Instituto Brasileiro de Geografia e Estatística. URL: <https://cidades.ibge.gov.br/brasil/ce/fortaleza/panorama> [visitado 14/08/2025].
- Kociánová, A., A. Kníž, & P. Piska (2025). Comparative analysis of traffic speed data on two-lane rural road segments: radar technology, Google Maps API, and license plate recognition. *Civil and Environmental Engineering* 21(1), 698–711. DOI:10.2478/cee-2025-0065.
- NAS (2022). *Highway Capacity Manual 7th Edition: a Guide for Multimodal Mobility Analysis*. Washington, D.C.: National Academy of Sciences.
- Thebit, M. M. & A. L. Cunha (2017). Comparação de dados de tráfego disponíveis na web obtidos por sensores fixos. In *Anais do 31º Congresso Nacional de Pesquisa e Ensino em Transporte da ANPET (Recife, PE)*, Recife. ANPET.
- Wagner, J. S., M. Eschbach, K. Vosseberg, *et al.* (2020). Travel time estimation by means of Google API data. *IFAC PapersOn-Line* 53(2), 15434–15439. DOI:10.1016/j.ifacol.2020.12.2365.