

Modelagem de corredores exclusivos para ônibus em microssimuladores com base em perfis de velocidade derivados de GPS

Modeling exclusive bus corridors in microsimulators based on GPS-derived speed profiles

Iran Gonçalves Vieira Neto¹, Antônio Claudio Dutra Batista², Nelson de Oliveira Quesado Filho³, e Francisco Moraes de Oliveira Neto⁴

¹Universidade Federal do Ceará, Ceará, Brasil, iran.vieira@det.ufc.br, 0000-0002-7027-0087

²Universidade Federal do Ceará, Ceará, Brasil, claudiobatistata1012@alu.ufc.br, 0009-0003-6855-0041

³Universidade Federal do Ceará, Ceará, Brasil, nelson.quesado@det.ufc.br, 0000-0003-0533-9153

⁴Universidade Federal do Ceará, Ceará, Brasil, moraes@det.ufc.br, 0000-0002-7756-4619

Recebido: 25 de novembro de 2024

Revisado: 8 de dezembro de 2025

Aceito: 30 de dezembro de 2025

Publicado: 6 de março de 2026

Editor Associado:

Sara Ferreira

Universidade do Porto, Portugal

Palavras-chave:

Transporte público,
Localização automática de ônibus,
Corredores com vias exclusivas,
Microssimulação de tráfego.

Keywords:

Public transport,
Automatic vehicle location,
Exclusive bus corridor,
Traffic microsimulation.

DOI: 10.58922/transportes.v34.e3207



RESUMO

A calibração de modelos de microssimulação para corredores exclusivos de ônibus ainda enfrenta limitações devido à falta de dados reais sobre a variação de velocidades dos veículos. Este estudo propõe um método para estimar perfis espaciais de variação de velocidade com base em dados de sistemas de localização automática de veículos (AVL). Esses perfis foram utilizados para calibrar o modelo de car-following de Gipps no software Aimsun Next. A aplicação em um corredor BRT de Fortaleza revelou que os perfis estimados capturam bem as variações esperadas de velocidade no comportamento dos ônibus ao longo do corredor. Entretanto, a calibração e validação revelaram discrepâncias atribuídas à variabilidade nas operações, especialmente nos volumes e tempos de embarque e desembarque dos passageiros nas paradas, bem como em falhas na coordenação semafórica, o que evidencia a necessidade de ajustes no modelo. O método proposto demonstra o potencial do uso de dados de GPS na calibração de microssimuladores, contribuindo para avanços na modelagem e avaliação de sistemas de transporte público.

ABSTRACT

The calibration of microsimulation models for exclusive bus corridors still faces limitations due to the lack of real data on vehicle speed variation. This study proposes a method to estimate spatial profiles of speed variation based on data from automatic vehicle location (AVL) systems. These profiles were used to calibrate the Gipps car-following model in the Aimsun Next software. The application to a BRT corridor in Fortaleza showed that the estimated profiles effectively capture the expected speed variations in bus behavior along the corridor. However, the calibration and validation revealed discrepancies attributed to operational variability, particularly in passenger boarding and alighting volumes and times at stops, as well as failures in traffic signal coordination, highlighting the need for adjustments. The proposed method demonstrates the potential of using GPS data to calibrate microsimulators, contributing to advancements in modeling and evaluating public transport systems.

1. Introdução

O crescimento urbano e o aumento da motorização individual têm intensificado os desafios de mobilidade nas cidades. O maior poder aquisitivo da população, especialmente da classe média, tem levado a um aumento na posse de veículos particulares, agravando os congestionamentos e elevando as emissões de poluentes (Kharas, 2010; Lindau *et al.*, 2013). Paralelamente, o crescimento populacional e as mudanças nas dinâmicas urbanas têm gerado uma crescente demanda por transporte coletivo, destacando a necessidade de sistemas mais eficientes e sustentáveis. Embora a motorização individual ofereça benefícios como conforto e praticidade, seus impactos negativos reforçam a urgência de investir em soluções de transporte público que atendam à demanda de forma integrada, reduzam os impactos ambientais e promovam a qualidade de vida nas cidades.

Neste contexto, corredores exclusivos para ônibus, como os sistemas BRT (*Bus Rapid Transit*), têm se destacado como uma solução eficaz para melhorar a fluidez e a qualidade do transporte público,

priorizando veículos de alta capacidade em espaços urbanos limitados. A modelagem desempenha um papel crucial no planejamento, análise e otimização desses sistemas, permitindo avaliar seus benefícios operacionais e o potencial de redução de emissões. Entre as ferramentas de modelagem, a microsimulação tem se mostrado uma ferramenta poderosa para modelar o desempenho de corredores BRT, permitindo uma análise detalhada das condições operacionais e dos benefícios em termos de fluidez e redução de emissões.

No entanto, a calibração desses modelos para corredores BRT ainda enfrenta desafios significativos, especialmente pela falta de métodos padronizados e dados representativos. Estudos recentes têm explorado o uso de dados de GPS (*Global Positioning System*) na modelagem de tráfego, destacando sua eficiência na coleta de informações detalhadas sobre deslocamentos e padrões de velocidade (Vieira, Pereira & Andrade, 2023). Como muitos sistemas de transporte público utilizam GPS para monitoramento de frotas, esses dados representam uma oportunidade promissora para a calibração de modelos de tráfego e a análise de emissões de poluentes (Kan et al., 2018). Entretanto, pesquisas que utilizam dados de GPS para estimar perfis típicos de velocidade aplicados à calibração de microsimuladores de corredores BRT ainda são limitadas, evidenciando uma lacuna importante na literatura. Além disso, em geral, os sistemas de rastreamento de veículos do transporte coletivo em cidades de grande porte não apresentam alta resolução temporal (por ex., segundo a segundo), o que representa uma limitação adicional para a modelagem de corredores de ônibus.

Com intuito de contribuir com esta lacuna, neste estudo, propõe-se um método para calibrar o modelo de veículo seguidor de Gipps, no software Aimsun Next, tendo como alvo perfis espaciais de variação de velocidade, estimados com base em dados de sistemas de localização automática de veículos (AVL) por meio de GPS. O método foi aplicado para estimar perfis de velocidade e calibrar o microsimulador AimSun Next em um corredor BRT de Fortaleza, que dispõe de um sistema AVL com resolução temporal de 30 segundos. A abordagem busca integrar grandes volumes de dados de localização dos veículos para aprimorar a representação das condições operacionais do transporte público em contextos urbanos. Parte-se da hipótese de que, apesar da resolução temporal não ser tão elevada, o grande volume de registros ao longo do corredor é suficiente para calibrar o modelo de *car-following* do AimSun Next em um cenário de BRT, considerando que esse tipo de corredor opera de forma segregada e não é influenciado pelo tráfego geral.

O trabalho está estruturado como segue: a Seção 2 apresenta uma breve revisão da literatura sobre modelagem de microsimulação e calibração de microsimuladores com base em dados de GPS; a Seção 3 apresenta o método proposto; a Seção 4 apresenta os resultados da aplicação do método para o corredor BRT em Fortaleza; e a Seção 5 apresenta as conclusões do trabalho.

2. Revisão da literatura

Alguns estudos na literatura têm utilizado dados de GPS instalados em veículos como principal fonte para a calibração de modelos de tráfego, destacando sua eficácia na representação detalhada do desempenho veicular (Ibarra-Espinosa et al., 2020; Böhm, Nanni & Pappalardo, 2022). O GPS é amplamente adotado devido à sua ampla cobertura, continuidade confiável e capacidade de fornecer informações detalhadas sobre o comportamento dos veículos. Essa tecnologia permite capturar dados essenciais sobre o modo de condução, as trajetórias e o estado do tráfego em tempo real, viabilizando uma modelagem mais precisa do desempenho veicular (Kan et al., 2018). Quando integrado a outros dispositivos, o GPS, possibilita a coleta de dados de trajetória em intervalos de segundos, permitindo mensurar com precisão as variações de velocidade. Isso favorece a aplicação em modelos avançados que consideram aceleração e desaceleração, proporcionando estimativas mais robustas do desempenho e das emissões. Além disso, essa abordagem é especialmente útil para análises geograficamente distribuídas, permitindo compreender com maior riqueza de detalhes o desempenho veicular em diferentes contextos urbanos (Hao et al., 2017; Shan et al., 2019).

Com o avanço da tecnologia, a simulação de tráfego se tornou uma ferramenta essencial para analisar e entender os comportamentos dinâmicos no trânsito. A microsimulação é útil quando se busca compreender os fatores que impactam o desempenho do tráfego ou quando se deseja estudar

como as interações entre veículos em sistemas viários urbanos influenciam o nível de serviço de redes de transportes e as emissões veiculares. Um dos principais modelos de microsimulação é o modelo de *car-following*, que descreve as interações de aceleração e desaceleração entre os veículos em uma via. Esse modelo permite representar o comportamento de um veículo que segue outro de forma dinâmica, levando em consideração fatores como distância, velocidade e aceleração (Rakha & Gao, 2011). Desenvolvido para simular a interação entre veículos e suas respostas a distúrbios no tráfego, como frenagens bruscas ou acelerações repentinas, o modelo de *car-following* proporciona uma análise mais precisa da dinâmica de tráfego e dos efeitos das variações nas condições de condução.

Nos microsimuladores comerciais, dois modelos de *car-following* se destacam: o modelo de Gipps (1981), implementado no Aimsun Next, e o modelo de Wiedemann, adotado pelo PTV VISSIM (Olstam & Tapani, 2004). O modelo de Gipps baseia-se na interação entre os veículos, considerando as decisões de aceleração e desaceleração, e leva em conta as distâncias de seguimento e as velocidades relativas entre os veículos. Esse modelo busca representar, de forma precisa, as reações dos motoristas a mudanças no tráfego, como a necessidade de reduzir a velocidade ou manter uma distância segura. Por outro lado, o modelo de Wiedemann modela a interação entre os veículos utilizando regras probabilísticas e comportamentais, o que permite uma representação mais flexível e realista da dinâmica do tráfego. Nesse modelo, as decisões de aceleração e desaceleração dos veículos não são determinísticas, mas sim influenciadas por fatores comportamentais, como a percepção do motorista em relação ao veículo à frente, resultando em uma simulação mais detalhada das variações no fluxo de tráfego.

O modelo de Gipps se destaca na literatura devido à sua simplicidade e ao comportamento realista que apresenta na propagação de distúrbios no tráfego, o que o torna especialmente útil em simulações de tráfego em condições urbanas. Uma de suas principais vantagens é que ele requer apenas três parâmetros para sua calibração: aceleração máxima, desaceleração máxima e a velocidade desejada pelo veículo líder (Santos, 2013). Essa característica torna o modelo de Gipps particularmente vantajoso em cenários com disponibilidade limitada de dados, permitindo uma calibração eficiente sem a necessidade de informações detalhadas sobre as condições de tráfego ou os veículos (Zhang, Batterman & Dion, 2011). Devido às suas características, o modelo de Gipps, implementado no Aimsun Next, foi selecionado para esta pesquisa, visando analisar sua capacidade de representar as variações de velocidade obtidas a partir de perfis espaciais de velocidade veicular.

Em geral, os trabalhos sobre calibração de modelos de *car-following* utilizam dados microscópicos de trajetórias de veículos individuais para comparar velocidades, acelerações e posições a cada passo temporal da simulação, seja para veículos individuais ou para grupos específicos (Treiber & Kesting, 2013; Chaudhari et al., 2021; Vasconcelos & Bandeira, 2025). Esse tipo de calibração permite, na maioria dos casos, bons ajustes aos perfis temporais de velocidade observados, mas é suscetível o super-ajuste devido a erros de medição ou erros cumulativos nas estimativas modeladas de posição e velocidade (Ossen & Hoogendoorn, 2008; Vasconcelos & Bandeira, 2025).

Vasconcelos & Bandeira (2025) destacam que a calibração baseada apenas em medidas macroscópicas não captura as interações detalhadas entre veículos, enquanto a adição de dados microscópicos melhora a precisão do modelo. Além disso, erros nas acelerações individuais se propagam ao longo do tempo e da sequência de veículos, afetando diretamente previsões de posição, velocidade e métricas agregadas, como tempo de percurso e emissões (Long et al., 2024).

Para mitigar esses problemas, alguns estudos propõem calibrar modelos utilizando medidas microscópicas combinadas com métricas agregadas, como tempos médios de viagem ao longo de corredores ou trechos específicos (Treiber & Kesting, 2013; Long et al., 2024; Hale et al., 2022). Medidas agregadas funcionam como uma forma de regularização, reduzindo o viés introduzido pelos erros cumulativos e evitando que o modelo se ajuste excessivamente a ruídos presentes nos dados individuais (Long et al., 2024; Vasconcelos & Bandeira, 2025).

Dessa forma, métodos mais recentes, como o de Chaudhari et al. (2021) e Long et al. (2024), evidenciam que diferentes conjuntos de parâmetros microscópicos podem levar a comportamentos macroscópicos semelhantes. Assim, a calibração exclusivamente microscópica pode não refletir adequadamente métricas agregadas, como tempo de viagem ou consumo de combustível. Long et al. (2024) propuseram uma calibração denominada de *bi-scale* que combina medidas microscópicas (aceleração, posição, velo-

cidade) e macroscópicas (tempo médio de viagem e consumo médio de combustível), demonstrando maior precisão na reconstrução de trajetórias e nas medidas agregadas, além de reduzir o impacto de erros acumulativos nos dados microscópicos. [Hale et al. \(2022\)](#) também sugerem métodos híbridos, mas ressaltam que a obtenção de trajetórias detalhadas requer drones ou câmeras aéreas, o que pode limitar a aplicabilidade em larga escala.

Em síntese, a literatura indica que calibrações que combinam dados microscópicos e macroscópicos, considerando a propagação de erros e o efeito acumulativo das interações veiculares, são mais robustas e adequadas para aplicações em corredores urbanos, permitindo análises de desempenho de sistemas BRT e avaliação de desempenho ambiental ([Long et al., 2024](#); [Hale et al., 2022](#); [Treiber & Kesting, 2013](#)). No entanto, ainda são escassos os estudos que exploram a modelagem de corredores BRT utilizando dados de GPS com baixa resolução, mesmo quando disponíveis em grande quantidade de veículos, o que evidencia uma lacuna relevante na literatura. Vale ressaltar, conforme apontado por [Vasconcelos & Bandeira \(2025\)](#), que a obtenção de dados de trajetórias em condições reais é, em geral, uma tarefa desafiadora, especialmente quando se trata de análises em larga escala.

Diante dessas lacunas, hipotetizamos que seja possível calibrar modelos de *car-following*, adotando o modelo de Gipps implementado no Aimsun, utilizando dados de GPS de baixa resolução em larga escala, de modo a reconstruir o perfil médio de velocidade ao longo do espaço. Diferentemente de abordagens que utilizam apenas médias por arco ou trecho, esta hipótese sugere que a análise agregada poderia capturar melhor as variações de velocidade relevantes para desempenho operacional e impactos ambientais, como emissões veiculares. Ao mesmo tempo, espera-se que a regularização proporcionada por medidas agregadas reduza o sobre ajuste típico de calibrações puramente microscópicas, preservando a capacidade de reproduzir comportamentos individuais ([Long et al., 2024](#); [Vasconcelos & Bandeira, 2025](#)).

3. Método

Esta seção apresenta o método para a obtenção dos perfis de velocidade veicular e a modelagem de um corredor BRT no microssimulador Aimsun Next. O método proposto foi dividido em três etapas: (1) extração dos perfis de velocidade a partir de dados desagregados de GPS da frota de ônibus do transporte público de Fortaleza, (2) modelagem e calibração do modelo de *car-following* de Gipps no Aimsun Next e (3) validação do modelo calibrado. Na seção 3.1, a seguir, apresenta-se inicialmente uma breve caracterização do corredor escolhido para análise.

3.1. Caracterização da área de estudo

Em Fortaleza, foi escolhido o corredor BRT Bezerra de Menezes, localizado na avenida Bezerra de Menezes (Figura 1), com uma extensão de 2,58 km em cada sentido, 11 estações, com uma distância média de 600 m entre elas, e 15 interseções controladas por semáforo. De acordo com a ETUFOR (Empresa de Transporte Urbano de Fortaleza), em 2018, esse corredor atendia a uma demanda diária de 130.000 usuários ([BRTData, 2023](#)).

A avenida Bezerra de Menezes possui duas faixas de tráfego misto e duas faixas exclusivas para o BRT, junto ao canteiro central, com separação física utilizando balizadores. As plataformas, localizadas no canteiro central da via (Figura 2), comportam um veículo por vez e possuem altura nivelado à entrada dos ônibus (Figura 3a), o que facilita o embarque e desembarque dos passageiros. Além disso, as catracas de cobrança estão instaladas nas plataformas, otimizando o processo de pagamento. A via também oferece integração com o transporte não motorizado, por meio de uma ciclofaixa central que se estende por toda a sua extensão, além de pontos de aluguel de bicicletas situados ao lado das plataformas. Diariamente, transitam pela via 13 linhas municipais e 2 linhas intermunicipais.

O corredor também conta com paradas convencionais (sem elevação do nível) para as linhas intermunicipais e para as linhas do sistema complementar de Fortaleza (Figura 3b). Essas paradas estão situadas no canteiro central, mas são fisicamente separadas das plataformas do BRT, como destacado na




Figura 1 • Localização do corredor BRT da Av. Bezerra de Menezes.




Figura 2 • (a) Localização das paradas e semáforos ao longo do corredor, com destaque para (b) uma plataforma de BRT e uma parada convencional de ônibus.

Figura 2b. Na modelagem, foram considerados ambos os tipos de operação ao longo do corredor: em plataformas elevadas e em paradas convencionais.

3.2. Obtenção dos perfis de velocidade

O perfil de velocidade de uma via pode ser usado para a calibração de modelos de simulação de tráfego, uma vez que esses modelos dependem das características de aceleração dos veículos (EPA, 2003). Neste estudo, os perfis de velocidade de uma via foram adotados como um dos primeiros passos para determinar as medidas de eficácia no processo de calibração do modelo de microssimulação de tráfego, embora outras abordagens também sejam possíveis. Nesse contexto, Ragab, Hashim & Asar (2017) destacam o uso da velocidade média e da aceleração como parâmetros essenciais para a calibração precisa do modelo, uma vez que esses fatores influenciam diretamente os resultados da simulação em termos de eficiência de tráfego e impactos ambientais.

Para a obtenção dos perfis de velocidade, foram utilizados dados de GPS provenientes dos veículos de transporte público em Fortaleza, Ceará. Esses dados foram fornecidos pela Empresa de Transporte Urbano de Fortaleza (ETUFOR), que é a empresa responsável pela gestão do transporte público na



Figura 3 • (a) Estação do BRT e (b) Parada convencional.

cidade, que dispõe de equipamentos de geolocalização nos ônibus, os quais transmitem informações a cada 30 segundos. Os dados de GPS incluem informações sobre horários dos registros, latitude, longitude, código da linha e código do veículo.

O processo tem início com a obtenção dos dados de GPS de toda a frota de transporte público por ônibus de Fortaleza (Figura 4), referentes ao ano de 2023. Em seguida, realiza-se a seleção das linhas de ônibus que percorrem a extensão completa do BRT na avenida Bezerra de Menezes. Utilizou-se a linguagem Python para o processamento dos dados de GPS e a extração das variáveis necessárias para a análise.

As localizações das plataformas do BRT na via, assim como das paradas convencionais, foram obtidas a partir dos arquivos geográficos de localização das paradas e estações provenientes dos dados de GTFS (*General Transit Feed Specification*) para o ano de 2023, fornecido pela ETUFOR. O GTFS é um formato de dados aberto composto por vários arquivos de texto que contêm dados estruturados, como as rotas de transporte, os horários de partida e as localizações das paradas, permitindo que esses dados sejam facilmente acessados e processados por sistemas de transporte e aplicativos de mobilidade. Essas coordenadas foram fundamentais para determinar o sentido de cada viagem realizada, assegurando uma análise detalhada do comportamento do tráfego nos diferentes trechos do corredor.

A primeira etapa do tratamento dos dados consiste na filtragem da localização, utilizando as coordenadas geográficas da via em função da localização dos veículos captada pelo GPS. Na sequência, realiza-se uma filtragem por dia e horário, com a exclusão de sábados, domingos e feriados. Para os feriados nas terças-feiras, também foi excluída a segunda-feira anterior, e para feriados nas quintas-feiras, foi excluída a sexta-feira subsequente, garantindo que apenas os dias úteis relevantes fossem considerados na análise. Na análise realizada, foram utilizadas todas as viagens realizadas no sentido oeste – leste, no período de 09:00 a 10:00 para calibração, e 18:00 a 19:00 para validação.

Após a obtenção dos dados de localização de cada veículo no corredor de estudo para os dias úteis de 2023, determinou-se as velocidades médias no espaço a cada 30 segundos de registro dos veículos ao longo do corredor. Isto permitiu gerar perfis individuais de velocidade segmentados por espaços percorridos entre registros dos veículos ao longo do corredor. Como os registros de GPS podem ocorrer em qualquer ponto da rede para diferentes veículos, os dados foram discretizados em intervalos de 5 metros ao longo do corredor. Essa padronização permite uniformizar os perfis de velocidade e viabilizar a comparação entre eles, associando as velocidades de diferentes perfis a um mesmo segmento no espaço. Assim, os perfis espaciais obtidos com velocidades constantes a cada 30 segundos foram discretizados




Figura 4 • Fluxograma para a obtenção dos perfis de velocidade.

para perfis espaciais com velocidade constantes a cada 5 metros.

Os perfis de velocidade foram gerados tanto para os veículos das linhas que operam nas plataformas do BRT, quanto para os veículos que utilizam as paradas convencionais. Adotou-se, como referência para obtenção dos perfis, uma extensão de 2,58 km ao longo do corredor. Dessa forma, os registros de veículos que não permitiam a geração de um perfil completo de velocidade foram descartados. Falhas nos equipamentos de GPS, como a perda comunicação ou o não sincronismo durante a operação, podem resultar em poucos ou nenhum registro no trecho analisado.

Após a obtenção dos perfis de velocidade para cada veículo nos dois tipos de operação no corredor (em plataforma e em parada convencional) e para diferentes horários do dia, determinou-se um perfil típico para cada tipo de operação. Com esses perfis típicos, busca-se representar as variações esperadas que podem ocorrer de velocidade e aceleração ao longo do corredor. Na aplicação para este artigo, foi adotado o perfil médio de velocidades do corredor como perfil típico. Para determinar este perfil, adotou-se a média harmônica das velocidades médias no espaço por veículo a cada 5 m ao longo do corredor. A escolha da média harmônica – também conhecida como velocidade média no espaço – deve-se ao fato de que, em cada perfil, as velocidades atribuídas a cada veículo correspondem a velocidades médias no espaço calculadas para intervalos de 30 segundos, sendo discretizadas em valores constantes a cada 5 metros. Dessa forma, essa média representa de maneira mais precisa os tempos de percurso ao longo do corredor.

3.3. Modelagem do corredor BRT no Aimsun Next

A Figura 5 ilustra o processo de modelagem do corredor BRT no Aimsun Next, abrangendo a construção do modelo – considerando dados operacionais e geométricos do corredor – e a calibração do modelo de *car-following* de Gipps no microssimulador Aimsun Next, com base no perfil harmônico de velocidade dos ônibus, conforme detalhado nas seções seguintes.

3.3.1. Construção da rede

Para a simulação da via estudada, optou-se pela utilização da microssimulação, pois os modelos de simulação microscópicos permitem uma maior aleatoriedade e variabilidade nas demandas ao longo do tempo, gerando um maior poder de representatividade (Portugal, 2005). Após um esforço inicial de calibração do modelo, esses modelos possibilitam a representação de diversas possibilidades com baixo custo e tempo de execução. Além disso, por estimarem emissões instantâneas a cada segundo, os




Figura 5 • Fluxograma do método de modelagem do corredor BRT no Aimsun Next.

modelos microscópicos são particularmente adequados para-simulações em entroncamentos únicos, onde a dinâmica do tráfego e as emissões podem ser analisadas com mais precisão (Samaras *et al.*, 2019).


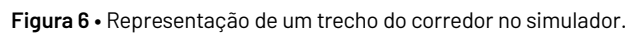
O simulador Aimsun Next (*Advanced Interactive Microscopic Simulator for Urban and Non-Urban Networks*), foi a ferramenta utilizada neste estudo. Inicialmente o software desenvolvido como um projeto acadêmico pioneiro na Universidade Politécnica da Catalunha (UPC). Mais tarde, foi adquirido pela Siemens, tornando-se parte da empresa YUNEX Traffic Group. Trata-se de um simulador híbrido que permite a utilização de simulações dinâmicas microscópicas, mesoscópicas e macroscópicas, possibilitando a avaliação de tráfego e emissões em quaisquer escalas e complexidades (AIMSUN, 2023). A escolha pelo Aimsun se deve ao fato de ser um software amplamente utilizado, que oferece uma modelagem detalhada do tráfego de rede, com a capacidade de distinguir entre diversos modos de transporte, além de permitir a modelagem de incidentes e a realização de simulações em nível macro, meso e micro, o que favorece um entendimento mais preciso da rede (Porto, 2015).

Para representar os atributos operacionais e geométricos do trecho em estudo, os dados do *Open-StreetMap* (OSM) foram importados diretamente para o Aimsun Next, que suporta esse formato. Foram consideradas as informações sobre a geometria da via, incluindo o número e a largura das faixas ao longo do corredor, além da localização das plataformas de BRT, das paradas convencionais e das interseções semaforizadas. A Figura 6 ilustra um segmento do corredor representado no simulador, mostrando uma plataforma do BRT, uma parada convencional e um cruzamento localizado próximo à Estação do BRT.

Conforme apresentado na Seção 3.2, foram definidos dois períodos de análise: de 09:00 a 10:00 para a calibração e de 18:00 a 19:00 para a validação da rede. As configurações dos tempos semafóricos em cada uma das 15 interseções controladas do corredor, para diferentes períodos de um dia típico, foram fornecidas pela Autarquia Municipal de Trânsito e Cidadania (AMC), órgão gestor do tráfego de Fortaleza. Os semáforos operam em regime de tempo fixo e de forma coordenada. A Figura 7 apresenta, de forma esquemática, a programação semafórica adotada no modelo para o período da manhã analisado (09:00 a 10:00), incluindo o ciclo semafórico, a distribuição dos tempos de verde e as defasagens entre os semáforos no sentido oeste-leste. No período da tarde, os semáforos passam a operar com um ciclo mais longo, de 160 segundos, provavelmente em função do aumento do volume de tráfego no corredor.

Quanto às características operacionais da oferta de transporte público por ônibus no corredor BRT avaliado, com base nos dados da ETUFOR, o corredor é atendido por quatro tipos de veículos que operam em 15 linhas. Destas, seis são linhas urbanas convencionais que utilizam as estações do BRT, enquanto nove são linhas complementares que atendem às paradas convencionais.

As linhas que operam nas plataformas do BRT utilizam veículos do tipo pesado, equipados com ar-condicionado, com capacidade para 42 passageiros sentados e um limite total de 84 passageiros.



O próximo passo é a criação da matriz OD (Origem-Destino) de pedestres, que se tornam os usuários do transporte público na simulação. Neste estudo, as análises consideraram apenas o sentido oeste-leste do corredor, o que exigiu a estimativa dos volumes de usuários nas cinco paradas e plataformas

localizadas nesse sentido de tráfego. Foram inseridas áreas de entrada e saída dos pedestres na simulação para cada ponto de parada de transporte público, além de serem inseridos os quantitativos de usuários e os tempos de embarque e desembarque dos passageiros.

Os volumes de usuários, assim como os tempos de embarque e desembarque, foram coletados em campo nas plataformas de BRT e nas paradas convencionais, com a devida autorização da ETUFOR. A coleta de dados foi realizada entre 8 h e 9 h da manhã. Para a coleta, foram definidos dois pontos, abrangendo duas plataformas do BRT e duas paradas convencionais. Um dos pontos de coleta foi localizado nas proximidades de um polo gerador de tráfego (um shopping center), onde se espera o maior volume de passageiros no corredor. O outro ponto foi escolhido em um segmento intermediário do corredor, onde se estima um volume menor de embarques e desembarques. Assumiu-se neste estudo que o volume de usuários nos outros três pontos da rede fossem similares ao do ponto de coleta intermediário.

A coleta envolveu a contagem do número de usuários que embarcaram e desembarcaram nos ônibus nas diferentes linhas que operam no corredor, além do registro dos tempos de embarque e desembarque. Esses tempos correspondem ao intervalo entre a abertura das portas e o momento em que os passageiros efetivamente entram ou saem do veículo, respectivamente. No modelo, adotou-se os tempos médios de embarque e desembarque por passageiro e os volumes de passageiros por linha, coletados em campo.

Dessa forma, foram considerados tempos de embarque de 1,2 segundos e de desembarque de 0,9 segundos nas plataformas. Já nas paradas convencionais, os tempos adotados foram de 2,0 segundos para embarque e 1,1 segundos para desembarque. Cabe destacar que, nas estações do BRT, o pagamento da tarifa é realizado fora do veículo e o embarque/desembarque ocorre por duas portas. Por outro lado, nas paradas convencionais, o pagamento é feito dentro do veículo, com bilhete único ou dinheiro, havendo apenas uma porta utilizada para embarque e outra para desembarque.

Quanto ao volume de passageiros, no período da manhã, adotou-se uma demanda de 200 passageiros por hora na estação do BRT localizada nas proximidades do shopping center. Para a parada convencional nesse mesmo ponto, considerou-se uma demanda de 90 passageiros por hora. Nos demais pontos da rede, os volumes foram ajustados em 10% a menos, com base nos resultados obtidos no ponto de coleta intermediário. No período da tarde, foram utilizados os dados do sistema de bilhetagem eletrônica fornecidos pela ETUFOR, a partir dos quais foi possível estimar os totais de embarques nas plataformas do BRT e nas paradas convencionais. Os resultados indicaram um acréscimo de aproximadamente 20% no volume de passageiros nas estações do BRT em relação ao período da manhã, enquanto nas paradas convencionais os volumes permaneceram semelhantes.

3.3.2. Seleção dos parâmetros e calibração e validação do modelo de *car-following* do Aimsun Next

Neste estudo, focou-se na calibração dos parâmetros relacionados ao modelo de veículo seguidor do Aimsun Next, uma vez que o corredor BRT em análise possui duas faixas: uma faixa à direita destinada às linhas que utilizam as plataformas do BRT e uma faixa à esquerda para as linhas que atendem às paradas convencionais. Os modelos de mudança de faixa e de ultrapassagem não foram considerados, pois o objetivo era priorizar o comportamento de seguimento de veículos nas condições específicas do corredor, onde a dinâmica de troca de faixas não é representativa ou relevante para o cenário analisado.

O modelo de *car-following* implementado no Aimsun Next consiste em uma variação do modelo Gipps (1981, 1986). O modelo é formado por dois componentes: a aceleração, que representa a pretensão do condutor em atingir uma certa velocidade desejada, e a desaceleração, que reproduz os obstáculos desencadeados pelo veículo precedente enquanto o veículo seguidor busca atingir a velocidade desejada. Conforme discutido na revisão, no modelo de veículo seguidor de Gipps, três parâmetros precisam ser calibrados: aceleração máxima (em m/s^2), desaceleração máxima (em m/s^2) e a velocidade desejada dos condutores. Os parâmetros de aceleração e desaceleração definem o limite máximo que o veículo pode atingir, sendo a desaceleração máxima reservada para situações especiais, como evitar uma colisão durante uma perseguição. Além destes parâmetros, o modelo também considera um parâmetro de desaceleração normal (em m/s^2), que é o valor de desaceleração dos veículos em circunstâncias normais, como em perseguição.

A velocidade desejada reflete a velocidade que o condutor busca alcançar em condições normais, sem a presença de uma perseguição. No Aimsun Next, essa velocidade é representada por um parâmetro comportamental que indica o quanto os condutores respeitam o limite de velocidade da via. Por exemplo, um valor maior que 1 para esse parâmetro sugere que os condutores tendem a ultrapassar o limite regulamentar de velocidade. No caso do corredor analisado, o limite de velocidade da via é de 50 km/h.

Tanto no modelo de Gipps quanto no Aimsun Next, são considerados outros fatores comportamentais dos condutores, como a percepção da desaceleração do veículo à frente (veículo líder) pelo veículo seguidor. Essa percepção é modelada por meio de um parâmetro chamado fator de sensibilidade, que varia de 0 a 1. Valores menores que 1 indicam que o condutor do veículo seguidor subestima a desaceleração do veículo líder, tornando-se menos cauteloso.

No modelo de *car-following* do Aimsun Next, o efeito lateral do tráfego sobre a velocidade é considerado por meio do modelo de veículo lateral em duas faixas. Esse modelo assume que a velocidade dos veículos em uma faixa pode ser influenciada pela presença de veículos na faixa adjacente, sendo dois parâmetros principais utilizados para representar esse efeito: a distância de influência e o número de veículos de influência. Entretanto, este modelo não foi adotado neste estudo, pois, devido à operação distinta do corredor em duas faixas que servem dois tipos distintos de paradas, assumiu-se que a velocidade de um veículo em uma faixa não seja significativamente impactada pela presença de veículos na faixa adjacente.

Adicionalmente, foram calibrados os parâmetros agressividade do *headway* e o tempo de reação (AIMSUN, 2024). O parâmetro de agressividade do *headway* representa o quanto os condutores estão dispostos a seguir outros veículos com tempos ou distâncias entre veículos menores (mais agressivo) ou com tempos ou distâncias maiores (mais cauteloso). Um valor maior do que 1 para este parâmetro indica um condutor mais agressivo do que o normal. Já o tempo de reação (em segundos) representa o tempo que um motorista leva para reagir às mudanças de velocidade do veículo à frente. Para cada tipo de veículo, pode ser definido um conjunto de valores discretos de tempo de reação associado a uma distribuição de probabilidade discreta.

Com exceção dos parâmetros para o veículo seguidor em duas faixas, assume-se que os parâmetros variam entre diferentes condutores. Assim, para cada parâmetro, o simulador permite que estas variações sejam representadas por meio de um modelo de distribuição normal truncada. Uma distribuição truncada é uma distribuição de probabilidade restrita a um intervalo específico, em que valores fora desses limites são excluídos. Para garantir que a soma das probabilidades no intervalo restrito seja igual a 1, as probabilidades são redimensionadas de forma adequada (Oliveira, 2004). No modelo de *car-following* do Aimsun Next, então, deve ser calibrado para cada fator comportamental os parâmetros da distribuição normal truncada, como segue: os seus limites mínimo e máximo, a média e o desvio padrão.

A Tabela 1 apresenta os valores padrões do Aimsun Next adotados como valores iniciais para os parâmetros de calibração utilizados neste estudo. Conforme discutido anteriormente, esses foram os parâmetros selecionados para a calibração do modelo de *car-following*, considerando o contexto de um corredor BRT, onde o único fator que influencia o desempenho do tráfego são as acelerações e desacelerações dos veículos ao seguir outros veículos.

Com relação ao processo de calibração, esses parâmetros foram ajustados com base nos dados de desempenho do corredor, representados pelos perfis harmônicos de velocidade, considerando os dois tipos

Tabela 1 • Valores padrões para os parâmetros do Aimsun Next do modelo de *car-following*

Parâmetro	Média	Desvio Padrão	Mínimo	Máximo
Aceitação do Limite de Velocidade	1	0,1	0,9	1,1
Aceleração Máxima (m/s ²)	1	0,3	0,8	1,8
Agressividade do <i>Headway</i>	0	0,5	-1	0
Desaceleração Máxima (m/s ²)	5	1	4	6
Desaceleração Normal (m/s ²)	2	1	1,5	4,5
Fator de Sensibilidade	1	0	1	1
Tempo de Reação (s)	2	—	—	—

de operação. Para a calibração, adotou-se uma abordagem sequencial, ajustando cada parâmetro individualmente e de forma iterativa até obter o melhor alinhamento, com base em medidas de similaridade e correlação entre os perfis de velocidade modelados e observados para cada tipo de operação.

O ajuste dos parâmetros foi realizado seguindo uma sequência específica. Primeiro, calibraram-se os parâmetros relacionados à aceleração e à desaceleração dos veículos. Em seguida, ajustou-se o fator de sensibilidade, responsável por influenciar a percepção dos condutores quanto à desaceleração do veículo à frente. Por fim, foram definidos o parâmetro de aceitação do limite de velocidade, a agressividade do *headway* e o tempo de reação.

Os parâmetros foram calibrados de forma iterativa, com o objetivo de maximizar a similaridade entre os perfis médios de velocidade – obtidos a partir dos valores médios de velocidade a cada 5 metros – modelado e observado no corredor. O perfil médio dos dados simulados foi obtido da mesma forma que o perfil médio observado. A calibração dos parâmetros foi realizada separadamente para cada tipo de operação (em plataforma e em parada convencional). Os perfis em cada iteração eram comparados utilizando as seguintes métricas de ajuste: o coeficiente de correlação de Pearson, que avalia a similaridade nas formas dos perfis médios de velocidade, e o erro quadrático médio (*EQM*), conforme Equação 1, que é uma medida de similaridade que mede a magnitude das diferenças entre os valores observados e simulados. O processo iterativo seguiu um método tradicional de ajuste, no qual pequenas modificações nos parâmetros eram realizadas de forma progressiva, buscando otimizar os indicadores adotados para a comparação entre os perfis. Essa abordagem sistemática permitiu identificar os parâmetros mais influentes e aprimorar a calibração do modelo. Nesse processo, cada parâmetro foi ajustado individualmente, mantendo-se o melhor valor encontrado para calibrar o parâmetro seguinte. A calibração foi iniciada a partir dos valores padrão (*default*) e o procedimento foi repetido diversas vezes.

$$EQM = \frac{\sum_{i=1}^N (v_i^o - v_i^s)^2}{N} \quad (1)$$

em que: v_i^o é a velocidade média observada no trecho i de 5 m; v_i^s é a velocidade média simulada no trecho i de 5 m; e N é o número de trechos de 5 metros ao longo do corredor simulado.

Para cada iteração, foi realizada uma simulação com duração de uma hora cada, adotando um período de *warm-up* de 10 minutos. Esse tempo foi definido como suficiente para que o primeiro veículo a entrar na rede percorresse toda a extensão do trecho em análise a uma velocidade de 15 km/h, significativamente inferior à velocidade de fluxo livre. Dessa forma, esse intervalo garante que a rede esteja totalmente carregada ao final dos 10 minutos.

Embora existam métodos mais robustos de calibração baseados em algoritmos heurísticos de busca, a escolha por essa abordagem mais simples foi motivada por sua eficiência computacional e pela sua adequação ao objetivo do estudo, que é demonstrar a eficácia do uso de perfis de velocidade na calibração do simulador. Adotou-se também a recomendação de [Hale et al. \(2022\)](#), os quais, com base em [Punzo, Montanino & Ciuffo \(2014\)](#), argumentam que há um número mínimo de parâmetros e determinados intervalos de valores suficientes para reproduzir de forma realista o comportamento de seguimento veicular, tornando o processo de calibração mais eficiente do ponto de vista computacional. Dessa forma, foram selecionados apenas os principais parâmetros para calibração, conforme apresentado na Tabela 1.

3.3.3. Análise da eficácia da modelagem e validação do modelo

Com base nos perfis harmônicos de velocidade obtidos do simulador, avaliou-se a capacidade do modelo de representar as variações de velocidade ao longo do corredor, tanto na etapa de calibração e quanto por meio da validação do modelo. Na etapa de calibração, a análise foi realizada comparando os perfis de velocidade observados e modelados para os dois tipos de operação no corredor (nas plataformas e nas paradas convencionais de ônibus). Assim, foram calculados o *EQM* e o coeficiente de correlação de Pearson em cada etapa do processo iterativo, desde a simulação inicial com os parâmetros padrão até a última iteração da calibração. Os resultados comparativos dos perfis, bem como os valores de *EQM* e de correlação obtidos em algumas iterações, são apresentados na Seção 4.2.

A etapa de validação foi realizada com o perfil de velocidade obtido a partir das simulações do modelo já calibrado, mantendo os mesmos parâmetros gerais de simulação adotados na calibração (uma hora de duração e um período de *warm-up* de 10 minutos), e considerando a operação do corredor no período da tarde. Adotou-se as mesmas métricas de análise para fins de comparação. Nesta etapa, assim como na de calibração, também foi avaliado o desempenho do modelo com parâmetros padrão em comparação ao modelo com parâmetros calibrados. Dessa forma, foi possível verificar o quão bem o modelo conseguiu reproduzir as acelerações e desacelerações observadas na realidade, que ocorrem devido às operações nas plataformas e paradas de ônibus, bem como às interrupções causadas pelos semáforos.

Devido à resolução dos dados de GPS utilizados, com registros a cada 30 segundos, não foi possível realizar a calibração do modelo com base em informações de velocidade e distância entre veículos em intervalos menores. Diante disso, considera-se validada a eficácia do modelo quando o perfil de velocidade média obtido na simulação com o modelo calibrado, aplicado ao período de validação, não apresenta diferença significativa em relação ao perfil derivado dos dados de GPS para o mesmo período. Além disso, avaliou-se o grau de divergência entre o perfil modelado e aquele gerado pelo modelo com parâmetros padrão.

Por fim, para avaliar se a velocidade média no espaço (média harmônica) representa melhor os tempos médios nos trechos de 5 metros e, conseqüentemente, o tempo de percurso ao longo do corredor nos dois períodos analisados, foram comparados os tempos de percurso modelados e observados para os veículos no sentido oeste-leste. A análise incluiu a comparação das distribuições dos tempos de percurso por meio de *boxplots*, além da aplicação de testes de hipóteses para comparação de médias.

É importante destacar que, idealmente, o modelo calibrado com o método proposto deveria ser comparado a outro método já consolidado na literatura, o que não foi feito neste estudo. No entanto, a comparação com o modelo utilizando parâmetros padrão, bem como o processo de validação, foi adotada como uma alternativa de verificação. Diante dessa limitação, sugere-se que estudos futuros comparem o método proposto com outras abordagens, utilizando dados com maior resolução temporal, e explorem estratégias complementares de validação para avaliar a robustez e a confiabilidade do modelo calibrado.

Ainda, dados de GPS com maior resolução temporal, como em intervalos de um segundo, não são comuns nos sistemas de rastreamento de veículos do transporte coletivo. Dessa forma, a obtenção desses dados exigiria uma coleta em campo, o que representa uma desvantagem para métodos alternativos. Caso o método proposto neste estudo, baseado em perfis médios obtidos a partir de um grande conjunto de perfis observados, se mostre eficaz, isso representará um avanço para a calibração de modelos de corredores BRT, uma vez que dados de AVL são amplamente disponíveis nesses sistemas.

4. Resultados

Esta seção apresenta os resultados dos perfis harmônicos de velocidade obtidos após o processamento dos dados de GPS de 2023, e da calibração e validação do modelo de *car-following* para o corredor BRT avaliado.

4.1. Parâmetros calibrados e interpretação

A calibração do modelo ocorreu ao longo de 74 iterações. A Figura 8 apresenta a evolução do *EQM* (a) e da correlação de Pearson (b) ao longo dessas iterações, destacando os cenários de melhor desempenho. Observa-se que o *EQM* diminui drasticamente nas primeiras iterações, com uma redução significativa em relação ao modelo com parâmetros padrão (iteração zero). Os menores valores de *EQM* foram obtidos apenas após diversas replicações do processo (63 para o perfil da plataforma BRT e 52 para a operação em plataforma convencional). Quanto à correlação, não houve melhora expressiva em relação ao modelo com parâmetros padrão. A maximização da correlação ocorreu na iteração 31 para os veículos que utilizam a plataforma BRT e na iteração 4 para aqueles que operam na plataforma convencional. Diante disso, optou-se por adotar os parâmetros que minimizam o *EQM*, uma vez que a correlação não apresentou variações relevantes ao longo das iterações.

Os valores obtidos para os parâmetros do simulador estão apresentados na Tabela 2. Cada parâmetro foi analisado individualmente, e aqueles que não demonstraram influência significativa nos perfis de velocidade, com base na análise de correlação e no erro quadrático médio, foram mantidos nos valores padrão do simulador. Esse foi o caso do parâmetro Aceitação do Limite de Velocidade (adimensional), possivelmente devido à baixa ocorrência de fluxo livre no cenário estudado.

A comparação entre os valores dos parâmetros calibrados e os do modelo padrão no Aimsun Next sugere um comportamento mais cauteloso por parte dos condutores. Observou-se, por exemplo, que os valores médios calibrados dos parâmetros de aceleração, desaceleração, agressividade do *headway* e tempo de reação foram menores, indicando acelerações e desacelerações mais suaves (de menor intensidade) e maior cautela dos condutores. Além disso, a menor dispersão nos parâmetros de agressividade do *headway*, desaceleração normal e desaceleração máxima sugere um comportamento mais homogêneo, reforçando a característica geral de maior cautela em relação ao modelo com parâmetros padrão.

Por outro lado, verificou-se uma heterogeneidade mais pronunciada na sensibilidade às acelerações dos veículos à frente. Os resultados indicam que os condutores tendem a superestimar a aceleração




Figura 8 • (a) Evolução do *EQM* e (b) da correlação no processo de calibração.

Tabela 2 • Valores dos parâmetros obtidos após calibração do Aimsun Next

Parâmetro	Cenário	Estação	Média	Desvio Padrão	Mínimo	Máximo
Aceitação do Limite de Velocidade	Padrão	—	1	0,1	0,9	1,1
	Ótimo	BRT Convencional	1 1	0,1 0,1	0,9 0,9	1,1 1,1
Aceleração Máxima (m/s²)	Padrão	—	1	0,3	0,8	1,8
	Ótimo	BRT Convencional	0,5 1	0,05 0,5	0,42 0,18	0,58 1,82
Agressividade do Headway	Padrão	—	0	0,5	−1	0
	Ótimo	BRT Convencional	−0,75 −0,75	0,38 0,38	−1 −1	−0,13 −0,13
Desaceleração Máxima (m/s²)	Padrão	—	5	1	4	6
	Ótimo	BRT Convencional	5 2	0,5 0,2	4,18 1,67	5,82 2,33
Desaceleração Normal (m/s²)	Padrão	—	2	1	1,5	4,5
	Ótimo	BRT Convencional	0,5 0,5	0,25 0,25	0,09 0,09	0,91 0,91
Fator de Sensibilidade	Padrão	—	1	0	1	1
	Ótimo	BRT Convencional	2 2	0,2 0,2	1,67 1,67	2,33 2,33
Tempo de Reação (s)	Padrão	—	2	—	—	—
	Ótimo	BRT Convencional	1,5 1,5	— —	— —	— —

do veículo à frente, já que tanto os valores mínimos quanto os máximos foram superiores a 1, o que corrobora um comportamento mais cauteloso. Esse resultado mostra-se mais condizente com a realidade do que a suposição de um comportamento homogêneo, conforme indicado pelos valores padrão desse parâmetro.

Vale ressaltar, que para uma análise mais aprofundada do comportamento dos condutores, o ideal seria comparar com outros contextos urbanos e com corredores BRT com estruturas distintas. O corredor BRT neste estudo é um trecho curto de 3 km, com várias interrupções (15 semáforos e 5 a 6 estações por sentido, distribuídas aproximadamente a cada 600 metros), o que pode afetar o comportamento de condução, já que pode ocorrer algum tipo de interrupção a cada 200 ou 300 metros. A frequência de interrupções pode impedir que os veículos consigam atingir um limite de velocidade desejado em alguns trechos, influenciando, assim, nos resultados.

4.2. Análise de ajuste e eficácia do modelo calibrado

Em cada iteração do processo de calibração do modelo, obtiveram-se perfis de velocidade e tempos de percurso para aproximadamente 100 veículos simulados, considerando as condições de tráfego simuladas e a operação semafórica definida na modelagem do corredor (Seção 3.3.1). Por sua vez, os perfis médios harmônicos observados foram obtidos a partir dos dados de velocidade de 3.932 veículos no período da manhã e 650 veículos no período da tarde.

A Figura 9 apresenta os resultados das últimas iterações do processo de calibração para cada parâmetro. Observa-se que, para alguns deles, foi possível identificar um valor de mínimo local do *EQM*. Destacam-se, em especial, os parâmetros de aceleração máxima, desaceleração normal e tempo de reação, que demonstraram exercer maior influência sobre a variação do *EQM*.




Figura 9 • Resultado de *EQM* nas últimas iterações do processo de calibração.

A Figura 10 compara os perfis médios de velocidade simulado e observado, referente à etapa de calibração, para os dois cenários de operação, considerando os modelos com parâmetros padrão (a) e

com parâmetros calibrados (b). Já a Figura 11, compara os perfis médios simulado e observado, referente à etapa de validação, para os mesmos cenários operacionais e de modelagem. Em geral, observa-se que os perfis simulados, mesmo para o modelo com parâmetros padrão, representam bem as variações de velocidade devido à influência dos semáforos e estação/paradas de ônibus, resultando numa correlação razoável entre os perfis simulados e observados (Tabela 3).

O modelo calibrado, quando comparado ao modelo padrão, resultou em perfis simulados mais próximos dos observados, em ambos os cenários de calibração e validação. O *EQM* foi reduzido em 59%, de 163,29 para 66,26, para a operação em plataforma BRT, e em 60%, de 169,39 para 67,56 na operação em plataformas convencionais. A eficácia da calibração é corroborada pela redução do *EQM* no cenário de validação. Neste caso, o *EQM* reduziu em 53%, de 153,15 para 72,74, para operação em plataforma BRT e em 65%, de 201,02 para 69,73, na operação em plataformas convencionais. Estes resultados indicam que o modelo calibrado foi capaz de capturar as principais tendências do comportamento de velocidade, ainda que persistam discrepâncias em determinados trechos. Os pontos de redução de velocidade coincidem com as localizações das plataformas de BRT, paradas e semáforos, o que reforça que as características do corredor foram bem representadas na simulação.

A Tabela 3 apresenta as correlações de Pearson entre os perfis observados e simulados. Observa-se que o processo de calibração, com exceção da operação em BRT na calibração, não resultou em aumento significativo da correlação em relação ao modelo com parâmetro padrão. Assim, as correlações que já eram razoáveis, da ordem 0,6, se mantiveram neste nível após a calibração. Esse resultado está alinhado com a hipótese de que a forma de variação dos perfis, no corredor em análise, está fortemente associada à localização e às operações nos semáforos e nas paradas convencionais e estações.

Por fim, as análises complementares de comparação entre os tempos de percurso modelados e observados, tanto na calibração quanto na validação, indicam que o método de calibração, baseado no




Figura 10 • Perfis harmônicos para o cenário de calibração, com parâmetros padrão (a) e calibrados (b).




Figura 11 • Perfis harmônicos para o cenário de validação, com parâmetros padrão (a) e calibrados (b).

Tabela 3 • Correlação (Pearson) entre as velocidades observadas e simuladas

Etap	Estação	Correlação (Padrão)	Correlação (Ótimo)	Valor-p H0: Δ correlação = 0
Calibração	BRT	0,59	0,62	0,020
	Convencional	0,61	0,55	0,001
Validação	BRT	0,61	0,59	0,362
	Convencional	0,64	0,54	< 0,001

perfil médio harmônico, resultou em um modelo que representa bem o comportamento dos tempos de percurso. A Figura 12 apresenta essa comparação por meio de *boxplots*, evidenciando a distribuição dos tempos de percurso simulados e observados como resultados dos processos de calibração e validação.

A Tabela 4 apresenta os tempos de percurso médios de cada cenário e os valores-p do teste *t* utilizado para comparar os tempos médios observados e modelados. Verifica-se que, enquanto o modelo com parâmetros padrão produziu tempos de percurso médios significativamente diferentes dos observados, o modelo calibrado, exceto no cenário de operação em plataforma BRT na etapa de validação, resultou em tempos médios que não diferem significativamente dos valores observados.

A hipótese inicial era de que a simulação representasse adequadamente as condições reais da via, o que foi corroborado pelos gráficos dos perfis de velocidade, pelos erros quadráticos médios, pelos coeficientes de correlação e pelas médias dos tempos de percurso obtidos. Ainda assim, alguns elementos precisam ser aprimorados no simulador para uma representação mais precisa de eventos específicos. Um exemplo é a redução mais acentuada da velocidade nas paradas, observada na operação real, possivelmente associada a variabilidade do tempo necessário para o embarque e desembarque de passageiros em uma mesma linha. Esse tempo pode ser influenciado por variações na demanda




Figura 12 • Distribuição dos tempos de percurso.

Tabela 4 • Médias das durações de percurso observadas e simuladas

Etapa	Estação	Duração Observada	Cenário	Duração Simulada	Valor-p
Calibração	BRT	8,67	Padrão	7,01	< 0,001
			Ótimo	9,04	0,037
	Convencional	8,85	Padrão	7,01	< 0,001
			Ótimo	9,44	0,017
Validação	BRT	8,23	Padrão	7,14	< 0,001
			Ótimo	10,32	< 0,001
	Convencional	9,04	Padrão	6,90	< 0,001
			Ótimo	9,32	0,146

ao longo da hora, ou ao longo do corredor, ou por diferenças individuais no tempo gasto por cada passageiro nessas operações. A variabilidade nos tempos de embarque e desembarque, bem como nas flutuações de demanda por linha e no espaço, não foi integralmente considerada neste estudo – que adotou tempos fixos por passageiro e volumes constantes de passageiros por linha – configurando uma limitação relevante a ser melhor abordada em pesquisas futuras. Ainda assim, os resultados demonstram que o método de calibração foi eficaz, gerando perfis simulados, em ambas as operações, coerentes com os perfis observados.

Ademais, como observado no perfil médio coletado, há uma redução de velocidade em determinados semáforos consecutivos que merece atenção. Idealmente, se os semáforos funcionassem conforme a configuração programada, um veículo que para em um semáforo deveria, em teoria, conseguir passar pelo próximo sem interrupções, salvo interferências externas pontuais. No entanto, essas interferências e irregularidades, mesmo pontuais, não são perceptíveis em um gráfico médio anual, como o utilizado neste estudo. Isso reforça a hipótese de que ocorreram interrupções na coordenação semafórica.

5. Conclusões

Este estudo teve como objetivo propor um método para estimar perfis típicos de velocidade em corredores exclusivos de ônibus do tipo BRT, a partir de dados de localização automática de veículos, e aplicar esses perfis na calibração de modelos de microssimulação, com foco especial no modelo de *car-following* de Gipps. A abordagem proposta buscou integrar grandes volumes de dados de localização dos veículos em corredores BRT para aprimorar a representação das condições operacionais do transporte público em contextos urbanos.

Os resultados demonstraram que o modelo de microssimulação foi capaz de representar adequadamente as condições reais da via, destacando-se pela fidelidade dos tempos de viagem simulados, que, na maioria dos casos, não apresentaram diferença significativa na média em relação aos tempos observados.

Mais importante ainda, os resultados da simulação com base no modelo calibrado evidenciam o potencial de calibração do Aimsun Next para corredores de transporte público do tipo BRT, utilizando dados de perfis de velocidade obtidos por GPS. A correlação moderada, em torno de 0,60, entre os perfis de velocidade típicos, observados e simulados, indica que o modelo conseguiu capturar as principais tendências de variação de velocidade ao longo da via, especialmente as reduções de velocidade próximas às plataformas BRT, paradas convencionais e semáforos. No entanto, o modelo não foi capaz de representar possíveis perdas de coordenação entre semáforos consecutivos ao longo do corredor, o que foi evidenciado por reduções mais acentuadas de velocidade nesses trechos nos perfis observados.

A análise segmentada entre veículos que utilizam plataformas BRT e aqueles que realizam paradas convencionais revelou correlações de 0,62 e 0,55, respectivamente, na etapa de calibração, e de 0,59 e 0,54, na etapa de validação. Uma hipótese para essa diferença pode estar relacionada às variações na demanda e nos tempos de embarque e desembarque nas plataformas, que não foram bem representados no modelo. O EQM, por sua vez, apresentou uma redução em torno de 60% resultado do processo de calibração, o que corrobora a eficácia do método.

Adicionalmente, o modelo foi validado para um contexto diferente de oferta e demanda em relação ao cenário de calibração. Os resultados apontam que o modelo calibrado foi capaz representar as variações de velocidade típicas do corredor, apresentando desempenho similar ao cenário de calibração. A abordagem de calibração e validação de forma segmentada, por tipo de operação, é crucial para capturar as dinâmicas específicas de operação de cada trecho, e para que o modelo reproduza com precisão a variação de velocidade ao longo do corredor. Isso permite sua aplicação, por exemplo, na estimativa de emissões, uma vez que esse cálculo depende das variações de aceleração e desaceleração ao longo do trajeto. A calibração de modelos de emissões, como o de [Panis, Broekx & Liu \(2006\)](#), implementado no Aimsun, pode se beneficiar significativamente de uma calibração mais detalhada do modelo de *car-following*, utilizando perfis típicos que representem mais fielmente as condições reais de cada trecho do corredor.

O estudo identificou algumas limitações, como a necessidade de ajustes na representação das reduções de velocidade durante o embarque e desembarque de passageiros, e a possível descoordenação dos semáforos ao longo do corredor. Esses fatores, não capturados pelo modelo, impactam o desempenho do corredor. Para trabalhos futuros, recomenda-se uma melhor representação das variações na demanda de passageiros ao longo do corredor, além de uma integração mais eficaz com o órgão gestor de trânsito para garantir a coordenação semafórica durante o experimento. Essas melhorias são importantes para avaliar, conforme proposto neste estudo, o uso de dados de GPS para a calibração de microssimuladores, permitindo uma maior precisão na replicação das condições reais em contextos urbanos complexos.

Outra limitação relevante do estudo diz respeito ao método de calibração e avaliação adotado. Conforme discutido, o objetivo deste trabalho é contribuir para o aprimoramento das práticas de modelagem de corredores BRT, caracterizados por possuírem faixas exclusivas para o transporte público, em microssimuladores de tráfego, ressaltando a importância do uso de dados massivos de localização veicular para uma representação mais precisa das condições operacionais desses corredores. No entanto, o método proposto de calibração do modelo de *car-following* no Aimsun Next neste estudo foi simplificado. Dessa forma, o uso de métodos heurísticos de busca, amplamente documentados na literatura, combinados a dados massivos de perfis de velocidade representa uma linha promissora de investigação para novas pesquisas. Portanto, estudos futuros devem investigar a eficácia do método proposto em comparação com outras abordagens de calibração disponíveis na literatura, especialmente aquelas baseadas em dados desagregados do movimento veicular no tráfego. Ainda, a aplicação de métodos mais robustos de calibração se torna especialmente relevante para permitir a calibração com diferentes perfis típicos para um mesmo corredor, em vez de utilizar apenas um perfil geral.

Além disso, há uma lacuna na capacidade de representar as variações de velocidade em corredores com faixas exclusivas ou de tráfego misto, que sofrem influência de veículos do tráfego geral. A interferência desses veículos é um fator relevante, especialmente em corredores de tráfego misto, onde a interferência dos veículos individuais é mais acentuada. A modelagem dessas interações precisa ser aprimorada para refletir melhor as condições operacionais desses corredores, o que é essencial para obter estimativas mais precisas de emissões e para o planejamento eficiente do transporte público.

Agradecimentos

Os autores agradecem ao CNPq, pela concessão de bolsa de produtividade (Proc. 312019/2017-3), à CAPES, pela bolsa de mestrado, e à Secretaria de Conservação e Serviços Públicos da Prefeitura Municipal de Fortaleza (SCSP) que forneceu a base de dados.

Declaração de contribuição de autoria CRediT

Iran Vieira Neto: Conceituação, Metodologia, Curadoria de dados, Análise formal, Escrita da versão inicial; *Antônio Claudio Batista*: Curadoria de dados, Análise formal; *Nelson Quesado Filho*: Metodologia, Curadoria de dados, Análise formal, Revisão da versão final; *Francisco de Oliveira Neto*: Supervisão, Conceituação, Metodologia, Revisão da versão final.

Uso de tecnologia assistida por inteligência artificial

Os autores declaram que nenhuma ferramenta de inteligência artificial foi usada na pesquisa aqui relatada ou na preparação deste artigo.

Declaração de conflitos de interesse

Os autores declaram que não há conflitos de interesses.

Declaração de disponibilidade de dados

Os dados, modelos e códigos que suportam os resultados deste estudo estão disponíveis mediante solicitação ao autor correspondente, Francisco Moraes de Oliveira Neto.

References

- AIMSUN (2023). AIMSUN Mobility Solutions. URL: <https://www.aimsun.com/> [visitado 20.10.2023].
- AIMSUN (2024). Aimsun Next Users Manual (version 24.0.1). URL: <https://docs.aimsun.com/next/> [visitado 01.12.2024].
- BRTData (2023). BRT Fortaleza. URL: https://brtdata.org/location/latin_america/brazil/fortaleza [visitado 27.2.2026].
- Böhm, M., M. Nanni, & L. Pappalardo (2022). Gross polluters and vehicle emissions reduction. *Nature Sustainability* 5(8), 699–707. DOI:10.1038/s41893-022-00903-x.
- Chaudhari, A., K. Srinivasan, B. Chilukuri, M. Treiber, & O. Okhrin (2021). Calibrating Wiedemann-99 model parameters to trajectory data of mixed vehicular traffic. *Transportation Research Record* 2676(1), 718–35. DOI:10.1177/03611981211037543.
- EPA (2003). *User's Guide to MOBILE6.1 and MOBILE6*. London: EPA.
- Gipps, P. (1981). A behavioural car-following model for computer simulation. *Transportation Research Part B: Methodological* 15(2), 105–11. DOI:10.1016/0191-2615(81)90037-0.
- Gipps, P. (1986). A model for the structure of lane changing decisions. *Transportation Research Part B: Methodological* 20(5), 403–14. DOI:10.1016/0191-2615(86)90012-3.
- Hale, D., A. Ghiasi, F. Khalighi, D. Zhao, X. Li, & R. M. James (2022). Vehicle trajectory-based calibration procedure for microsimulation. *Transportation Research Record* 2677(1), 1764–81. DOI:10.1177/03611981221124597.
- Hao, P., K. Boriboonsomsin, G. Wu, & M. J. Barth (2017). Modal activity-based stochastic model for estimating vehicle trajectories from sparse mobile sensor data. *IEEE Transactions on Intelligent Transportation Systems* 18(3), 701–11. DOI:10.1109/TITS.2016.2584388.
- Ibarra-Espinosa, S., R. Y. Ynoue, K. Ropkins, X. Zhang, & E. D. Freitas (2020). High spatial and temporal resolution vehicular emissions in south-east Brazil with traffic data from real-time GPS and travel demand models. *Atmospheric Environment* 222, 117–36. DOI:10.1016/j.atmosenv.2019.117136.
- Kan, Z., L. Tang, M. Kwan, & X. Zhang (2018). Estimating vehicle fuel consumption and emissions using GPS big data. *International Journal of Environmental Research and Public Health* 15(4), 566. DOI:10.3390/ijerph15040566.
- Kharas, H. (2010). *The Emerging Middle Class in Developing Countries*. Paris: OECD Development Centre. URL: https://www.oecd.org/en/publications/the-emerging-middle-class-in-developing-countries_5kmp8lncrns-en.html [visitado 27.2.2026].
- Lindau, L., G. Petzhhold, C. Silva, & D. Facchini (2013). BRT e corredores prioritários para ônibus: panorama no continente americano. In *Anais do XXVII Congresso de Pesquisa e Ensino em Transporte (Belém, PA)*.

- Long, K., H. Shi, Z. Chen, Z. Liang, X. Li, & F. de Souza (2024). Bi-scale car-following model calibration based on corridor-level trajectory. *Transportation Research Part E, Logistics and Transportation Review* 186, 103497. DOI:10.1016/j.tre.2024.103497.
- Oliveira, M. (2004). Modelos de regressão com variável dependente truncada ou censurada. URL: https://www.fep.up.pt/disciplinas/2E103/ec_cens.pdf [visitado 28.2.2026].
- Olstam, J. & A. Tapani (2004). *Comparison of Car-Following Models*. Linköping: Swedish National Road Administration.
- Ossen, S. & S. Hoogendoorn (2008). Validity of trajectory-based calibration approach of car-following models in presence of measurement errors. *Transportation Research Record* 2088(1), 117–25. DOI:10.3141/2088-13.
- Panis, L., S. Broekx, & R. Liu (2006). Modelling instantaneous traffic emission and the influence of traffic speed limits. *The Science of the Total Environment* 371(1-3), 270–85. DOI:10.1016/j.scitotenv.2006.08.017.
- Porto, E. (2015). Análise dos impactos gerados pela restrição de tráfego de veículos de carga em ambiente urbano através de microssimulação. Mestrado (dissertação), Universidade Federal de Santa Catarina, Florianópolis. URL: <https://repositorio.ufsc.br/xmlui/handle/123456789/136333> [visitado 27.2.2026].
- Portugal, L. (2005). *Simulação de Tráfego: Conceitos e Técnicas de Modelagem*. Rio de Janeiro: Interciência.
- Punzo, V., M. Montanino, & B. Ciuffo (2014). Do we really need to calibrate all the parameters? variance-based sensitivity analysis to simply microscopic traffic flow models. *IEEE Transactions on Intelligent Transportation Systems* 16(1), 184–93. DOI:10.1109/TITS.2014.2331453.
- Ragab, M., I. Hashim, & G. Asar (2017). Impact of road traffic on air emissions: case study Kafr El-Sheikh City, Egypt. *International Journal for Traffic and Transport Engineering* 7(3), 391–405. DOI:10.7708/ijtte.2017.7(3).09.
- Rakha, H. & Y. Gao (2011). Calibration of steady-state car-following models using macroscopic loop detector data. In *75 Years of the Fundamental Diagram for Traffic Flow Theory: Greenshields Symposium*, Transportation Research Circular E-C149, Washington, DC, pp. 178–198. TRB. URL: <https://onlinepubs.trb.org/onlinepubs/circulars/ec149.pdf>.
- Samaras, C., D. Tsokolis, S. Toffolo, G. Magra, L. Ntziachristos, & Z. Samaras (2019). Enhancing average speed emission models to account for congestion impacts in traffic network link-based simulations. *Transportation Research Part D, Transport and Environment* 75, 197–210. DOI:10.1016/j.trd.2019.08.029.
- Santos, P. (2013). Método de calibração de um modelo veículo seguidor para BRT e Ônibus em corredor segregado. Mestrado (dissertação), Universidade Federal do Rio Grande do Sul, Porto Alegre. URL: <http://hdl.handle.net/10183/75917> [visitado 27.2.2026].
- Shan, X., X. Chen, W. Jia, & J. Ye (2019). Evaluating urban bus emission characteristics based on localized MOVES using sparse GPS data in Shanghai, China. *Sustainability* 11(10), 2936. DOI:10.3390/su11102936.
- Treiber, M. & A. Kesting (2013). Microscopic calibration and validation of car-following models – a systematic approach. *Procedia: Social and Behavioral Sciences* 80, 922–39. DOI:10.1016/j.sbspro.2013.05.050.
- Vasconcelos, L. & J. Bandeira (2025). Calibration of the Intelligent Driver Model (IDM) at the microscopic level. *Future Transportation* 5(2), 57. DOI:10.3390/futuretransp5020057.
- Vieira, J., R. Pereira, & P. Andrade (2023). Estimating public transport emissions from General Transit Feed Specification data. *Transportation Research Part D: Transport and Environment* 119, 103757. DOI:10.1016/j.trd.2023.103757.
- Zhang, K., S. Batterman, & F. Dion (2011). Vehicle emissions in congestion: Comparison of work zone, rush hour and free-flow conditions. *Atmospheric Environment* 45(11), 1929–39. DOI:10.1016/j.atmosenv.2011.01.030.