Revista Brasileira de Climatologia
Brazilian Journal of Climatology
OPEN ACCESS

EMISSÕES VEICULARES DE CO_2 EM CURITIBA-PR: ANÁLISE ESPAÇO-TEMPORAL E IMPACTO DA PANDEMIA DE COVID-19 EM MARÇO DE 2019 E 2020

Vehicular CO_2 emissions in Curitiba-PR: spatio-temporal analysis and impact of the COVID-19 pandemic in March 2019 and 2020

Emisiones vehiculares de CO_2 en Curitiba-PR: análisis espacio-temporal e impacto de la pandemia de COVID-19 en marzo de 2019 y 2020

Gabriel Leitoles
Programa de Pós-Graduação em Geografia
Universidade Federal do Paraná (UFPR)
Curitiba, Paraná, Brasil
leitolesgabriel@gmail.com

Wilson Flávio Feltrim Roseghini
Programa de Pós-Graduação em Geografia
Universidade Federal do Paraná (UFPR)
Curitiba, Paraná, Brasil
feltrim@ufpr.br

Max Wendell Batista dos Anjos
Universidade Federal de Juiz de Fora (UFJF)
Juiz de Fora, Minas Gerais, Brasil
maxanjos@campus.ul.pt

Resumo: Este estudo analisa a distribuição espaço-temporal das emissões veiculares de dióxido de carbono (CO_2) na cidade de Curitiba (PR), com ênfase na comparação entre março de 2019 e março de 2020, período marcado pelo início das restrições de mobilidade associadas à pandemia de covid-19. A estimativa das emissões foi realizada por meio de uma abordagem *bottom-up* integrada ao aprendizado de máquina. Um modelo *Random Forest* foi treinado com dados horários de contagem de tráfego provenientes de 201 estações de monitoramento, combinados a atributos da infraestrutura viária extraídos do *OpenStreetMap*, permitindo estimar o fluxo e a velocidade média em segmentos não monitorados. As emissões foram calculadas com base em fatores dependentes da velocidade utilizando o pacote VEIN. O modelo apresentou elevado desempenho em março de 2019 (R^2 = 0,92 para volume; R^2 = 0,86 para velocidade), com redução em março de 2020 (R^2 = 0,78), refletindo a instabilidade dos padrões de mobilidade durante o período pandêmico. Os resultados indicam reduções horárias de CO_2 entre 50% e 65% nos horários de pico em 2020, bem como diminuição expressiva das emissões totais (−52,5%). A análise espacial evidencia que as maiores reduções se concentraram nos principais eixos estruturais da cidade, associados ao tráfego pendular.

Palavras-chave: Emissões Veiculares. Aprendizado de máquina. Poluição do ar. Qualidade do ar.

Abstract: This study investigates the spatio-temporal distribution of vehicular carbon dioxide (CO_2) emissions in Curitiba (Brazil), focusing on a comparative analysis between March 2019 and March 2020, when mobility restrictions associated with the COVID-19 pandemic began. Emissions were estimated using a bottom-up approach integrated with machine learning techniques. A Random Forest model was trained using hourly traffic counts from 201 monitoring stations, combined with road infrastructure attributes derived from OpenStreetMap, enabling the estimation of traffic flow and average speed in unmonitored road segments. CO_2 emissions were calculated based on speed-dependent emission factors using the VEIN package. The model showed high performance for March 2019 (R^2 = 0.92 for traffic volume; R^2 = 0.86 for speed), with a decrease in March 2020 (R^2 = 0.78), reflecting increased variability in mobility patterns during the pandemic. Results indicate substantial reductions in hourly CO_2 emissions, ranging from 50% to 65% during peak hours in 2020, as well as a significant decrease in total emissions (−52.5%). Spatial analysis reveals that the largest reductions were concentrated along the main structural corridors of the city, which are strongly associated with commuting flows.

Keywords: Vehicular emissions. Machine learning. Air pollution. Air quality.

Resumen: Este estudio analiza la distribución espacio-temporal de las emisiones vehiculares de dióxido de carbono (CO_2) en la ciudad de Curitiba (Brasil), con énfasis en la comparación entre marzo de 2019 y marzo de 2020, período marcado por el inicio de las restricciones de movilidad asociadas a la pandemia de COVID-19. La estimación de las emisiones se realizó mediante un enfoque bottom-up integrado con técnicas de aprendizaje automático. Un modelo Random Forest fue entrenado con datos horarios de conteo de tráfico provenientes de 201 estaciones de monitoreo, combinados con atributos de la infraestructura vial extraídos de OpenStreetMap, lo que permitió estimar el flujo vehicular y la velocidad media en segmentos no monitoreados. Las emisiones de CO_2 se calcularon a partir de factores dependientes de la velocidad utilizando el paquete VEIN. El modelo presentó un alto desempeño en marzo de 2019 (R^2 = 0,92 para volumen; R^2 = 0,86 para velocidad), con una disminución en marzo de 2020 (R^2 = 0,78), reflejando la inestabilidad de los patrones de movilidad durante la pandemia. Los resultados evidencian reducciones horarias de CO_2 entre 50% y 65% en los horarios pico en 2020, así como una disminución significativa de las emisiones totales (−52,5%). El análisis espacial muestra que las mayores reducciones se concentraron en los principales corredores estructurales de la ciudad, asociados al tráfico pendular.

Palabras clave: Emisiones vehiculares. Aprendizaje automático. Contaminación del aire. Calidad del aire.

Submetido em: 05/04/2026
Aceito para publicação em: 25/08/2026
Publicado em: 15/11/2026



1. INTRODUÇÃO

A poluição atmosférica veicular representa um dos principais desafios ambientais dos centros urbanos contemporâneos, onde a queima de combustíveis fósseis libera compostos como dióxido de carbono (CO_2), monóxido de carbono (CO), óxidos de nitrogênio (NO_x) e material particulado (PM), com impactos diretos sobre a qualidade do ar, a saúde pública e o equilíbrio climático (CETESB, 2017; IPCC, 2023). Nesse contexto, o CO_2 destaca-se como o principal gás de efeito estufa associado ao setor de transportes, cuja emissão está diretamente relacionada ao consumo energético e à dinâmica da mobilidade urbana (Cozzi *et al.*, 2020).

No Brasil, a quantificação das emissões veiculares em alta resolução espaço-temporal permanece um desafio metodológico, uma vez que as estações fixas de monitoramento da qualidade do ar oferecem cobertura espacial fragmentada (Vormittag *et al.*, 2021), além de inventários nacionais que operam em escalas que obscurecem heterogeneidades intraurbanas relevantes.

A cidade de Curitiba (PR) apresenta um contexto importante para a realidade brasileira, com uma frota superior a um milhão de veículos (IBGE, 2024) e uma estrutura urbana organizada em eixos estruturais de transporte. Nesse contexto, a cidade apresenta áreas de intensa concentração de tráfego, onde a emissão de poluentes tende a ser mais elevada (Castelhano, 2019). Estudos já indicavam que a verticalização ao longo desses eixos contribui para a formação de cânions urbanos, favorecendo o aprisionamento de poluentes e intensificando sua concentração em determinadas regiões (Danni-Oliveira, 2000).

A pandemia de covid-19, reconhecida como pandemia pela Organização Mundial da Saúde em março de 2020, introduziu uma ruptura significativa nos padrões de mobilidade urbana em escala global, pois medidas de distanciamento social, restrições de circulação e redução das atividades econômicas resultaram em uma diminuição abrupta do fluxo de veículos, configurando um cenário diferenciado para a análise da relação entre mobilidade e emissões atmosféricas. Estudos indicam que houve reduções expressivas nas emissões globais de CO_2 durante esse período, associadas principalmente à queda no consumo de combustíveis fósseis (Le Quéré *et al.*, 2020), embora tais reduções tenham se mostrado, em grande parte, temporárias.

Esse contexto excepcional pode ser interpretado como um experimento natural, no qual a redução forçada da mobilidade permite avaliar, de forma mais isolada, o impacto do tráfego veicular sobre as emissões urbanas. No Brasil, entretanto, ainda são escassos os estudos que investigam essas mudanças em alta resolução espaço-temporal, especialmente em escala intraurbana. Essa lacuna é ainda mais evidente quando se considera a integração entre modelagem de tráfego baseada em *Machine Learning* e estimativas de emissões veiculares (Anjos; Meier, 2025).

Diante desse cenário, o presente artigo tem como objetivo analisar a distribuição espaço-temporal das emissões de CO_2 provenientes do tráfego rodoviário na cidade de Curitiba, por meio da comparação entre dois períodos distintos: março de 2019, representando um cenário pré-pandêmico, e março de 2020, marcado pelo início das primeiras medidas de restrição associadas à covid-19. Para isso, é empregada uma abordagem *bottom-up*, estratégia que estima fenômenos agregados a partir da integração de dados detalhados em nível individual ou local (Gurney *et al.*, 2017), baseada em *Machine Learning*, na qual um modelo *Random Forest* é utilizado para estimar o fluxo de veículos e a velocidade média em segmentos viários não monitorados, a partir de atributos da infraestrutura urbana e dados observados de tráfego.

A partir dessas estimativas, as emissões de CO_2 são calculadas utilizando fatores de emissão dependentes da velocidade (Ibarra-Espinosa *et al.*, 2018), permitindo a construção de um inventário detalhado das emissões em escala intraurbana.

2. METODOLOGIA

2.1. Área de estudo e base de dados

A cidade de Curitiba (Figura 1), capital do estado do Paraná, está localizada no Primeiro Planalto Paranaense, entre a Escarpa Devoniana a oeste e a Serra do Mar a leste. Seu relevo é predominantemente ondulado, com altitudes que favorecem a formação de microclimas e influenciam diretamente os padrões de dispersão de poluentes atmosféricos (Castelhano, 2019).

Curitiba possui uma população predominantemente urbana e elevada densidade demográfica (mais de 4.000 hab/km²), com áreas de significativa verticalização, especialmente

ao longo dos chamados "eixos estruturais" definidos no Plano Serete da década de 1970 (Schmitz *et al.*, 2011).

Esses eixos combinam vias de tráfego rápido com faixas exclusivas para ônibus, concentrando usos residenciais, comerciais e de transporte. A configuração desses espaços, marcada por construções altas e próximas, favorece a formação de "canyons urbanos", que dificultam a dispersão de poluentes e criam *hotspots* de concentração atmosférica (Castelhano, 2019).

Figura 1 – Mapa de localização da cidade de Curitiba e estações contagem de veículos**.**

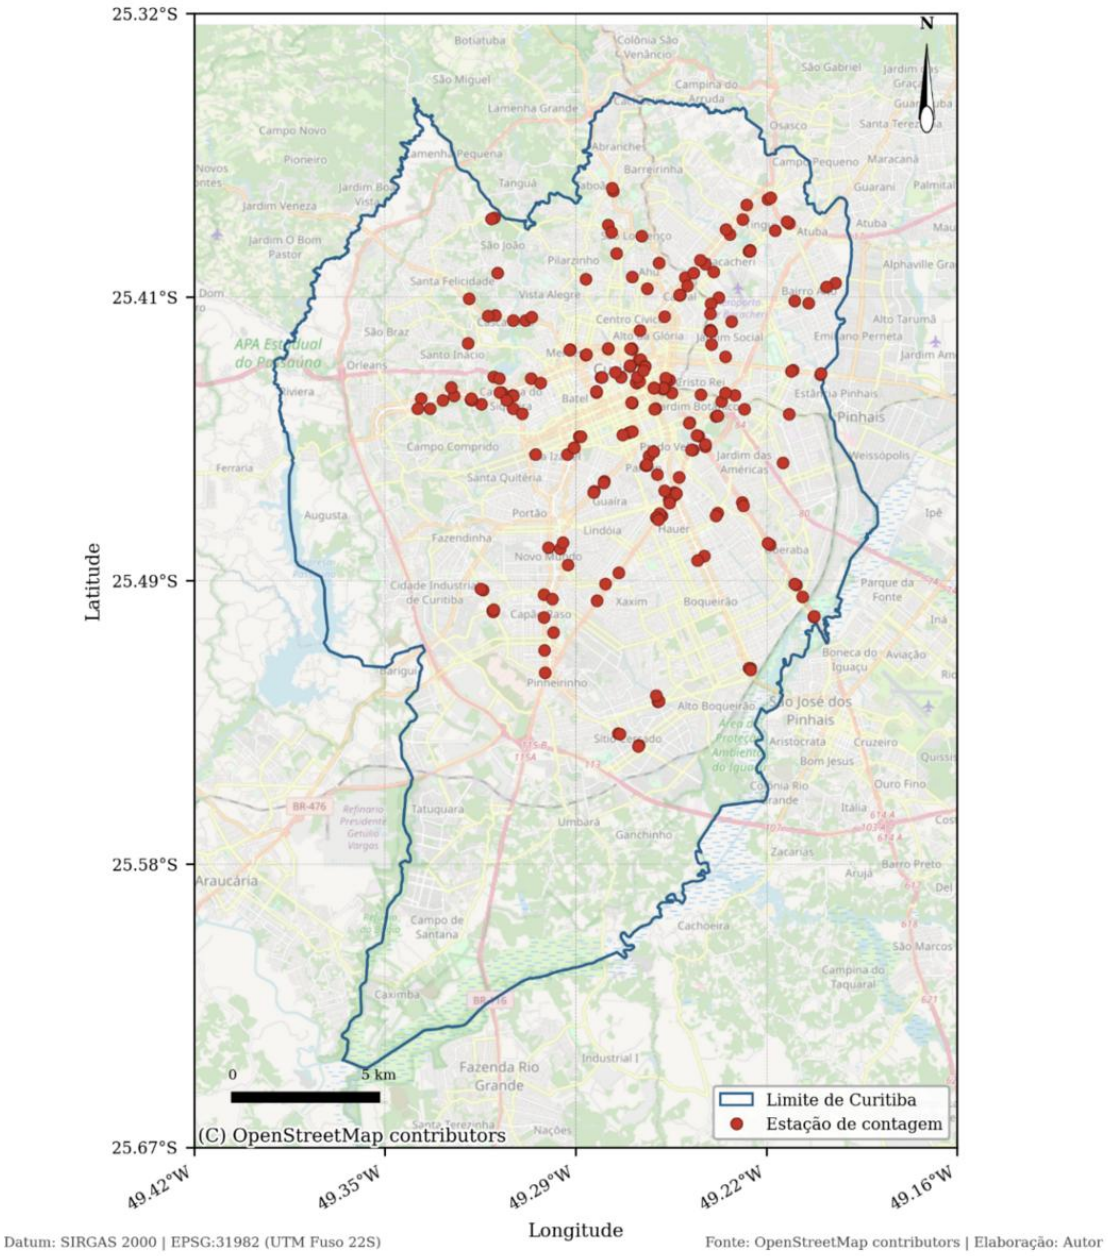

Fonte: Elaborado pelos autores (2026).

As informações espaciais e de infraestrutura da rede viária foram extraídas do projeto colaborativo *OpenStreetMap* (OSM), via plataforma Geofabrik, utilizando os pacotes do R *osmdata* (Padgham *et al.*, 2017) e *sf*, realizou-se a coleta, agregação e o tratamento georreferenciado dos dados. As vias foram categorizadas em cinco classes hierárquicas principais (*motorway*, *trunk*, *primary*, *secondary* e *tertiary*). Além da infraestrutura de transporte, foram integradas variáveis de uso e cobertura do solo adjacentes aos segmentos viários, tais como áreas de lazer (*leisure*), zonas comerciais (*shop*), amenidades (*amenity*), edificações (*building*) e áreas naturais (*natural*).

Os dados de contagem de tráfego foram fornecidos pela Secretaria Municipal de Defesa Social e Trânsito de Curitiba, abrangendo 201 estações de monitoramento distribuídas pela malha viária da cidade. Para cada estação, estão disponíveis registros horários de fluxo por tipo de veículo e velocidade média, em km/h, para ambos os meses definidos.

2.2. Modelagem preditiva com *Random Forest*

Para estimar o fluxo e a velocidade dos veículos em trechos viários não monitorados, adotou-se o algoritmo de *Machine Learning* denominado *Random Forest*, que se baseia na construção de múltiplas árvores de decisão para criar modelos preditivos robustos (Breiman, 2001). Com o intuito de evitar o sobreajuste (*overfitting*) e garantir a capacidade de generalização do modelo, a base de dados das estações de contagem foi dividida temporalmente através do pacote *caret* (Kuhn, 2009), destinando 80% das observações para o treinamento e 20% para a fase de teste e validação.

As variáveis explicativas temporais foram geradas com o auxílio dos pacotes *timetk* (Dancho, 2022) e *recipes* (Kuhn; Wickham, 2022), permitindo extrair assinaturas de série temporal a partir dos registros de data e hora. Foram criados índices específicos, como hora do dia, período (diurno/noturno) e dia da semana, elementos essenciais para que o algoritmo identificasse os padrões cíclicos de mobilidade. O modelo preditivo foi implementado computacionalmente utilizando o pacote R *ranger* (Wright; Ziegler, 2015), executado com uma configuração padronizada de 500 árvores.

A avaliação do desempenho do modelo nos dados de teste foi realizada a partir do cálculo do Coeficiente de Determinação (R^2) e da Raiz do Erro Quadrático Médio (RMSE), com equações exemplificadas, respectivamente, na Figura 2.

Figura 2 – Equações do coeficiente de determinação (R^2) e Raiz do erro quadrático médio (RMSE)

$$R^2 = \frac{SQR}{SQT} = \frac{\sum_{i=1}^{n}(\hat{y}i - \bar{y})^2}{\sum_{i=1}^{n}(yi - \bar{y})^2}$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^{n} di^2}{n}}$$

Fonte: Elaborado pelos autores (2026).

2.3. Estimativas das emissões veiculares

A quantificação das emissões de dióxido de carbono (CO_2) foi conduzida por meio de uma abordagem *bottom-up*, utilizando o pacote VEIN (*Vehicular Emissions Inventory*) na linguagem R (Ibarra-Espinosa *et al.*, 2018). O modelo VEIN calcula as emissões a partir do produto entre a atividade viária (fluxo de veículos) e os fatores de emissão dinâmicos, que são estritamente dependentes da velocidade de operação nos segmentos.

Aplicou-se a função ef_ldv_speed() para calcular os fatores de emissão específicos para a categoria de veículos leves. O modelo considerou os padrões de emissão Proconve L6, equivalentes ao padrão europeu Euro 5, assumindo a predominância do uso de gasolina e motorização de até 1,4 litro, características majoritárias da frota curitibana (IBGE, 2025). A relação matemática adotada para o cálculo do fator de emissão do CO_2 em função da velocidade (v) é expressa pela equação apresentada na Figura 3.

Figura 3 – Equação do fator de emissão de CO_2 em relação à velocidade

$$FE_{CO2} = \frac{174 + 0,364 \cdot v + 0,00874 \cdot v^2}{1 + 0,0685 \cdot v - 0,000247 \cdot v^2} \cdot \left(\frac{44}{12,011 + (1,008 \cdot 1,8)} \right)$$

Fonte: Ibarra-Espinosa *et al.* (2018).

2.4. Avaliação entre os diferentes períodos

Para mensurar os efeitos das restrições de mobilidade urbana decorrentes da pandemia de covid-19, estabeleceu-se uma análise comparativa direta entre os resultados modelados para março de 2019 e março de 2020. O impacto foi avaliado pelo cálculo da diferença relativa das emissões, expressa em porcentagem. O cálculo obedeceu à formulação disposta na Figura 4.

Figura 4 – Equação da diferença relativa de emissões de CO_2

$$\Delta E(\%) = \left[\frac{E_{2020} - E_{2019}}{E_{2019}}\right] \times 100$$

Fonte: Elaborado pelos autores (2026).

A análise dessa variação foi decomposta em dimensões horárias, diárias (dia da semana) e espaciais (por classe da via), permitindo mapear as alterações nos padrões de emissão no espaço urbano de Curitiba. Além da análise das diferenças relativas, foi elaborado um mapa de variação espacial das emissões. Esse produto representa, para cada segmento da malha viária de Curitiba, a diferença absoluta entre as emissões totais de CO_2 estimadas para março de 2020 e março de 2019 (2020–2019). A espacialização dessa diferença permite identificar a distribuição das mudanças na carga emissora, destacando os principais corredores com maiores reduções associadas às restrições de mobilidade, bem como trechos que apresentaram estabilidade ou aumento das emissões no início da pandemia.

3. DESENVOLVIMENTO

3.1. Desempenho do modelo

O modelo Random Forest apresentou desempenho elevado para a estimativa do fluxo de veículos em março de 2019, com R^2 = 0,92, RMSE = 160 veículos e MAE = 94 veículos (Figura 5). Em março de 2020, observou-se redução no ajuste (R^2 = 0,78; RMSE = 99 veículos; MAE = 66 veículos), refletindo maior instabilidade dos padrões de tráfego no início do período pandêmico.

Figura 5 – Dispersão entre valores observados e estimados de fluxo veicular para março de 2019 (a) e março de 2020 (b).

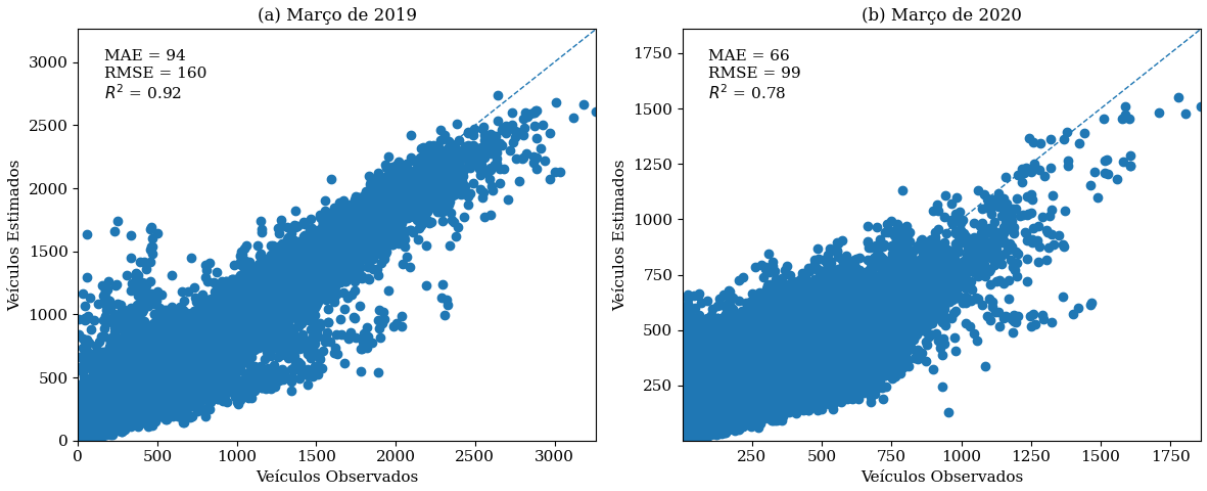

Fonte: Elaborado pelos autores (2026).

Para a velocidade média (Figura 6), o desempenho em março de 2019 foi de R^2 = 0,86 e RMSE = 2,99 km/h, com queda mais acentuada em março de 2020 (R^2 = 0,72; RMSE = 5,08 km/h), associada, possivelmente, à compressão da variância das velocidades observadas em contexto de mobilidade reduzida.

Figura 6 – Dispersão entre valores observados e estimados de velocidade média para março de 2019 (a) e março de 2020 (b).

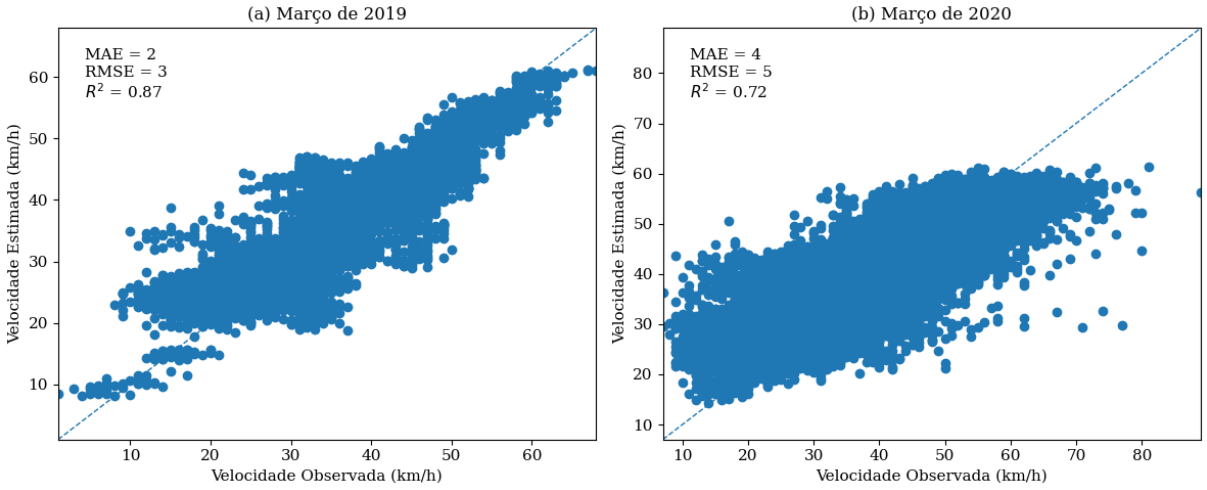

Fonte: Elaborado pelos autores (2026).

3.2. Padrão horário e semanal das emissões de CO_2

As emissões horárias médias de CO_2 em março de 2019 (Figura 7) apresentaram comportamento bimodal típico de ambientes urbanos, com pico matinal entre 7h e 9h e pico vespertino entre 16h e 18h, atingindo valores máximos da ordem de 230–260 t/h. Os valores mínimos ocorreram durante a madrugada (0h a 5h), abaixo de 50 t/h, configurando uma variação superior a cinco vezes entre os extremos do ciclo diário.

Figura 7 – Distribuição horária das emissões médias de CO_2 para março de 2019 e março de 2020.

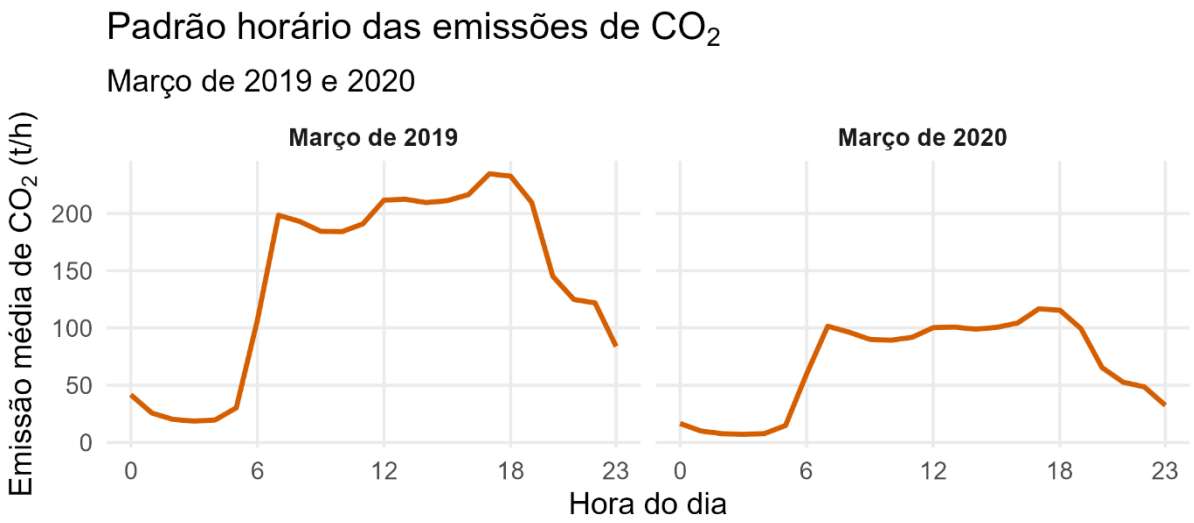

Fonte: Elaborado pelos autores (2026).

Em março de 2020, o padrão bimodal foi preservado, porém com reduções expressivas na magnitude das emissões. Os picos horários situaram-se em torno de 100–130 t/h, representando quedas entre 50% e 65% nos horários de maior intensidade de tráfego em relação ao mesmo período de 2019. Nos horários intermediários do dia (10h–15h), as reduções foram menos acentuadas, entre 30% e 45%, sugerindo a manutenção parcial de deslocamentos essenciais durante a pandemia.

No que tange ao padrão semanal das emissões médias de CO_2, março de 2019 caracterizou-se por apresentar valores mais elevados nos dias úteis, com emissões diárias entre 140 e 170 t/dia de segunda a sexta-feira, e redução expressiva aos domingos, quando os valores recuaram para cerca de 100–105 t/dia.

Figura 8 – Distribuição semanal das emissões totais de CO_2 para março de 2019 e março de 2020.

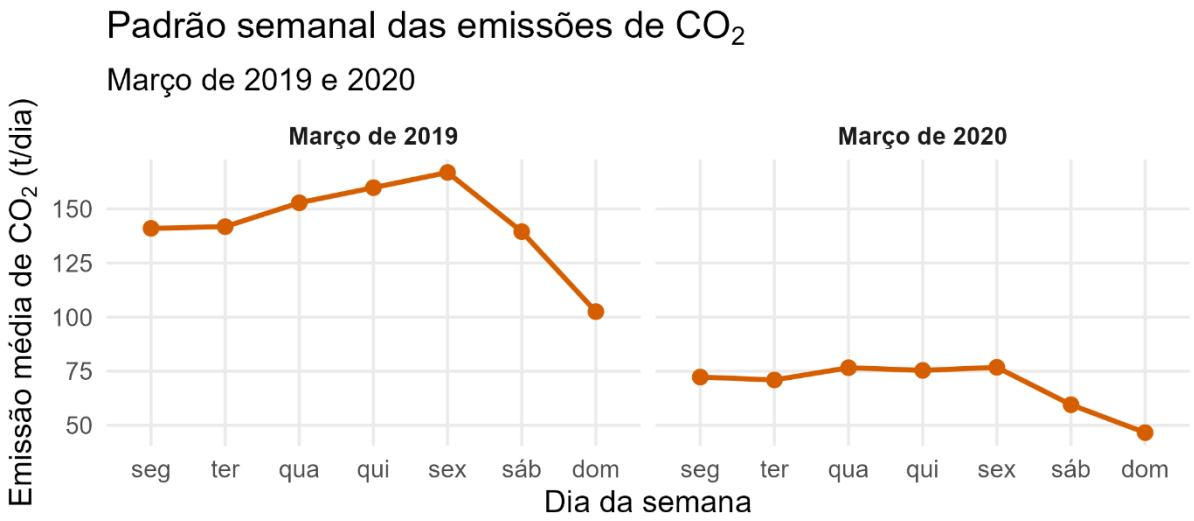

Fonte: Elaborado pelos autores (2026).

Em março de 2020, embora os níveis absolutos tenham sido significativamente menores, a hierarquia semanal entre dias úteis e finais de semana foi preservada. As emissões médias nos dias úteis situaram-se entre 70 e 90 t/dia, enquanto os domingos registraram valores em torno de 45–55 t/dia. As diferenças relativas entre os dois anos foram sistematicamente negativas ao longo de toda a semana, com reduções variando entre -35% e -60% nos dias úteis e atingindo até -65% nos finais de semana.

Ao analisar as emissões totais de CO_2 entre os dois meses, observa-se uma redução expressiva entre março de 2019 e março de 2020 (Figura 9). Em termos absolutos, as emissões passaram de aproximadamente 106,2 kt em março de 2019 para 50,5 kt em março de 2020, correspondendo a uma diminuição de cerca de 55,8 kt, representando uma redução de 52,5% nas emissões totais.

Figura 9 – Comparação das emissões totais de CO_2 entre março de 2019 e março de 2020.

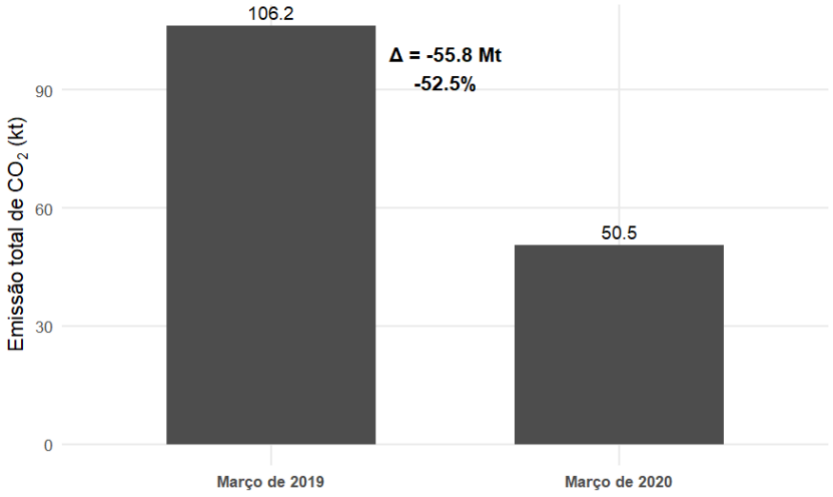

Fonte: Elaborado pelos autores (2026).

3.3. Análise espacial das emissões

A distribuição, apresentada na Figura 10, evidencia uma forte assimetria positiva, com média de 80,42 tCO_2 e mediana inferior (56,86 tCO_2), indicando concentração de valores em faixas mais baixas e a presença de uma cauda longa à direita. Esse comportamento reflete a estrutura hierarquizada da rede viária, na qual a maior parte dos segmentos apresenta baixos níveis de emissão, enquanto uma parcela reduzida, associada aos principais corredores de tráfego em classes como *trunk, motorway* e *primary*, concentra os maiores volumes emissores.

Figura 10 – Distribuição das emissões de CO_2 para março de 2019.

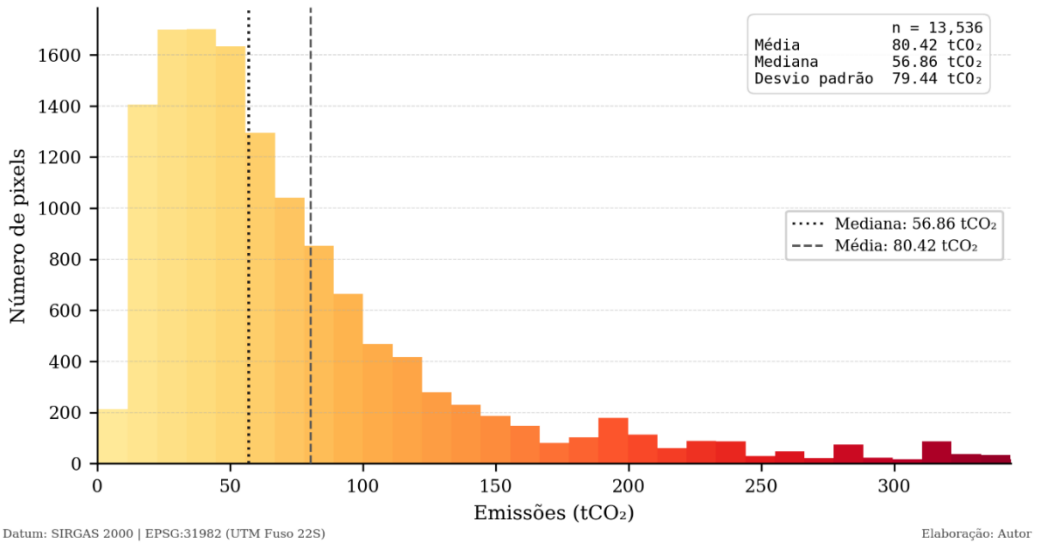

Fonte: Elaborado pelos autores (2026).

Espacialmente, observa-se que as maiores concentrações de emissões (Figura 11), acompanham os principais eixos estruturais de Curitiba, o corredor oeste, incluindo as vias de acesso à Região Metropolitana próximas ao Parque Barigui, e os eixos norte-sul, com destaque para a Linha Verde entre os bairros Capão Raso e Hauer, bem como a Avenida das Torres a leste com ligação para a cidade de São José dos Pinhais.

Figura 11 – Emissões em tCO_2 para março de 2019.

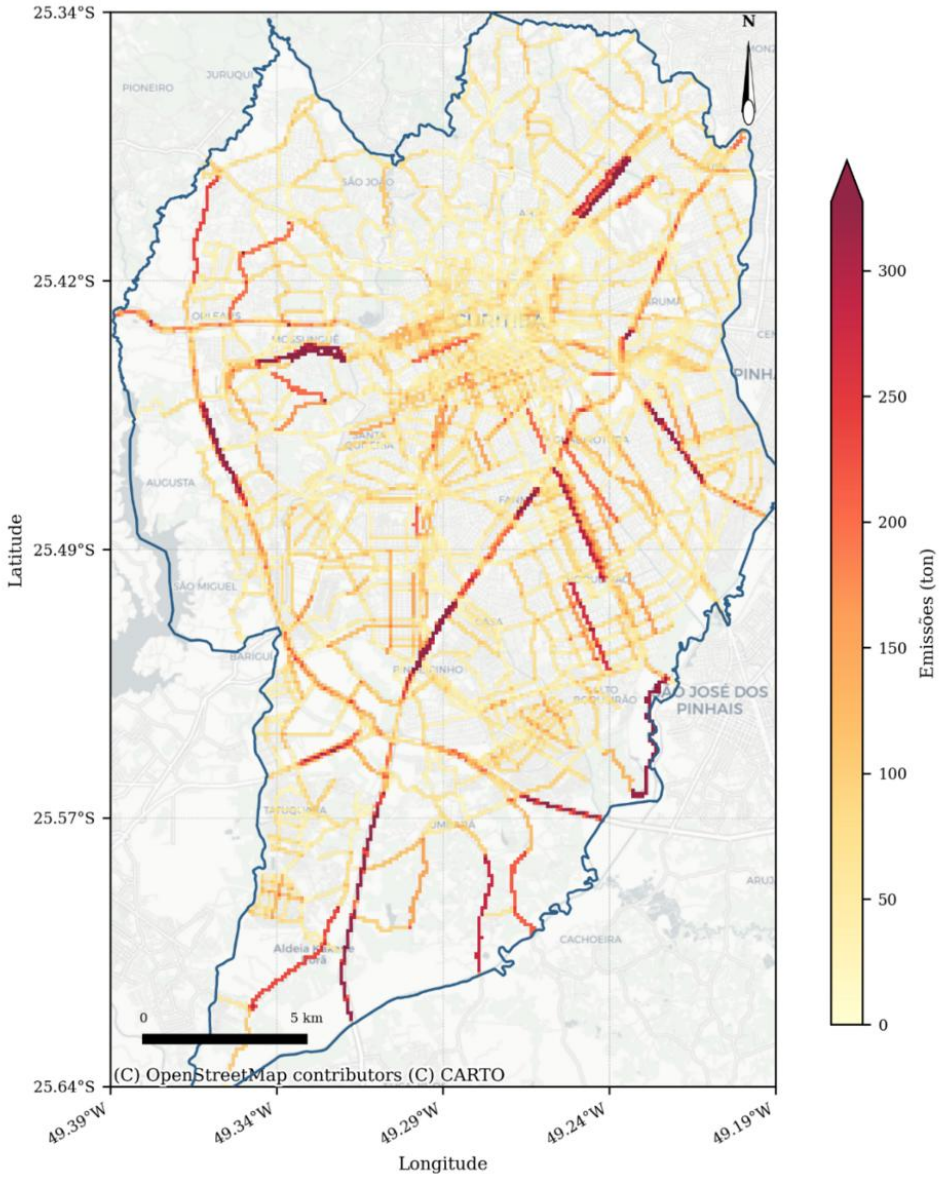

Datum: SIRGAS 2000 | EPSG:31982 (UTM Fuso 22S) Fonte: OpenStreetMap contributors | Elaboração: Autor

Fonte: Elaborado pelos autores (2026).

Em março de 2020, a média de emissões por segmento recuou para 41,31 tCO_2 (Figura 12), correspondendo a uma redução de aproximadamente 48,63% em relação a 2019. O desvio padrão diminuiu de 79,44 tCO_2 para 49,22 tCO_2, indicando não apenas a redução dos volumes absolutos, mas também uma menor dispersão dos valores. Esse comportamento sugere uma relativa homogeneização da distribuição espacial das emissões, associada à diminuição da intensidade do tráfego nos principais eixos viários.

Figura 12 – Distribuição das emissões de CO_2 para março de 2020.

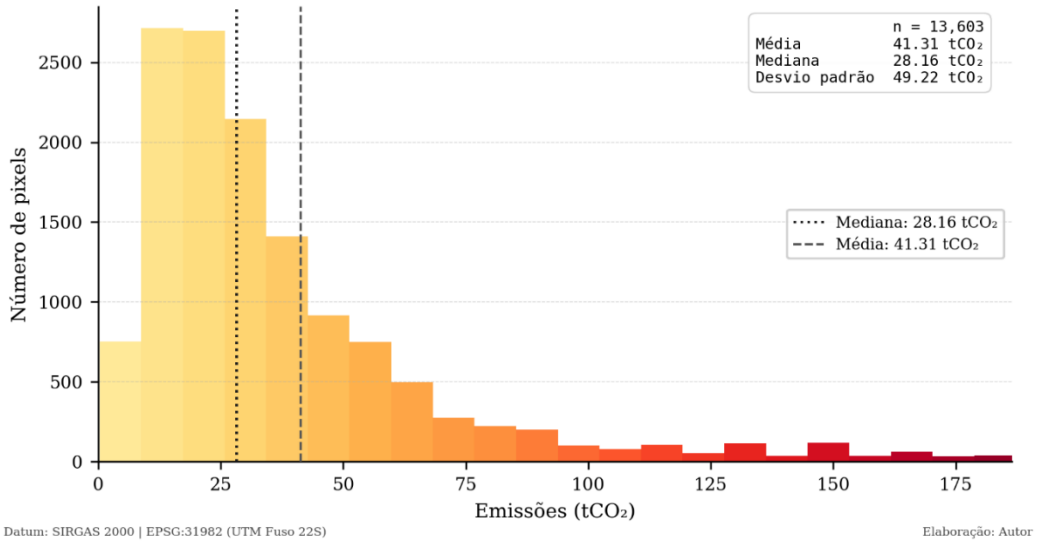

Fonte: Elaborado pelos autores (2026).

No mapa da Figura 13 é possível constatar que os núcleos de alta emissão remanescentes restringem-se ao eixo sul, na divisa com São José dos Pinhais, e a trechos isolados dos eixos estruturais, onde fluxos de transporte essencial e logística sustentaram patamares relativamente mais elevados durante o início das restrições. Vale destacar que, embora os mapas de 2019 e 2020 compartilhem estrutura semelhante, as legendas revelam ordens de grandeza distintas, com valores máximos para março de 2019 atingindo 300 tCO_2 por segmento, enquanto em março de 2020 esse teto recua para 160 tCO_2.

Figura 13 – Emissões em tCO_2 para março de 2020.

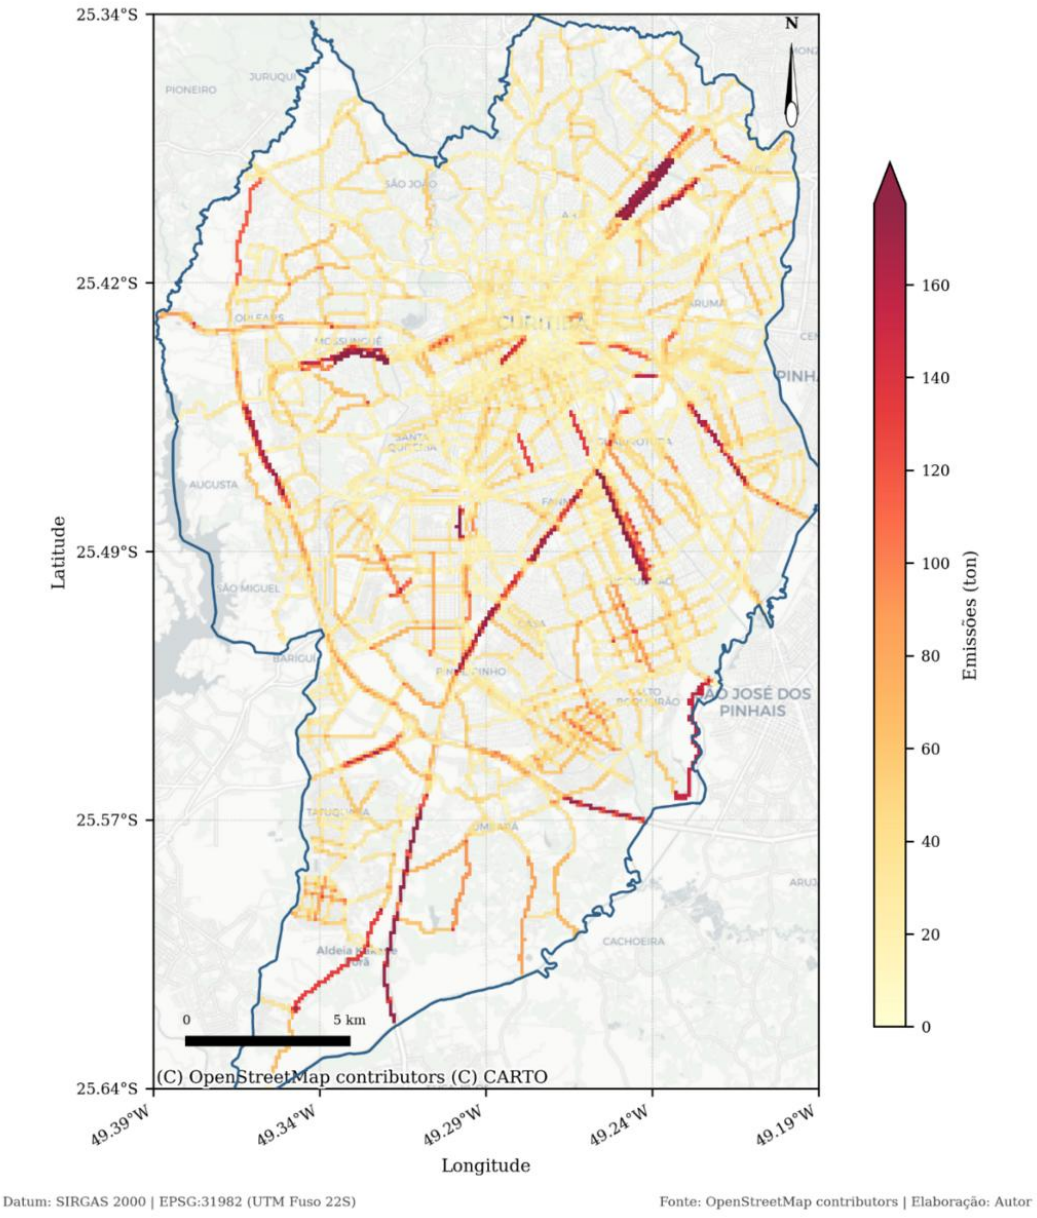

Fonte: Elaborado pelos autores (2026).

O histograma da variação das emissões apresenta assimetria negativa (Figura 14), com média de −39,05 tCO_2, mediana de −26,07 tCO_2 e desvio padrão de 43,39 tCO_2. A diferença entre média e mediana evidencia a influência de valores extremos associados aos segmentos com maiores reduções, sobretudo os principais eixos estruturais, que deslocam a média para valores mais negativos. Esse padrão indica que, embora a maior parte da rede tenha experimentado reduções moderadas, uma parcela restrita concentrou quedas mais intensas nas emissões.

Figura 14 – Distribuição da diferença de emissões de tCO_2, março 2020 − março 2019.

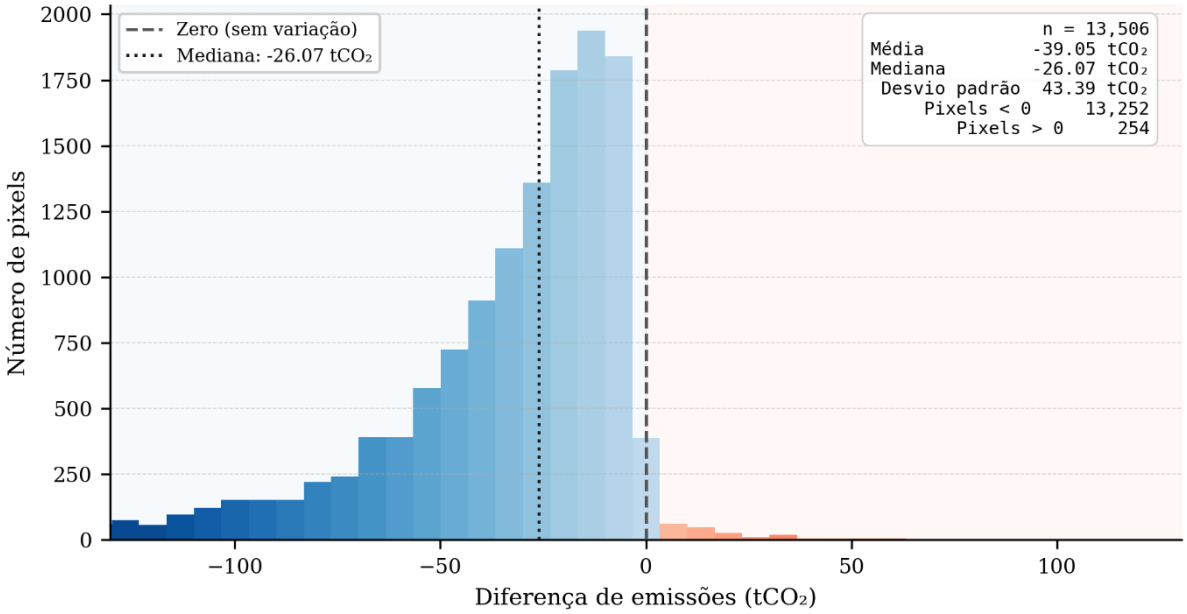

Fonte: Elaborado pelos autores (2026).

A dominância quase absoluta de valores negativos confirma que a redução foi o padrão predominante em praticamente toda a malha viária (Figura 15). Os segmentos com maior queda concentram-se exatamente nos corredores que em 2019 apresentavam os maiores volumes emissores. Essa coincidência espacial entre os segmentos de maior emissão em 2019 e os de maior redução em 2020 reflete que foram justamente os eixos de maior dependência do tráfego pendular os mais afetados pelas restrições de mobilidade.

Chama atenção, contudo, a presença de focos pontuais em vermelho no mapa, indicando aumento de emissões em 2020, distribuídos de forma dispersa sobretudo em vias de menor hierarquia nos quadrantes centro-norte e centro-sul, os quais possivelmente refletem o redirecionamento de rotas logísticas e a concentração de atividades essenciais em determinados corredores durante o início da pandemia.

Figura 15 – Diferença de emissões de tCO_2, março 2020 − março 2019.

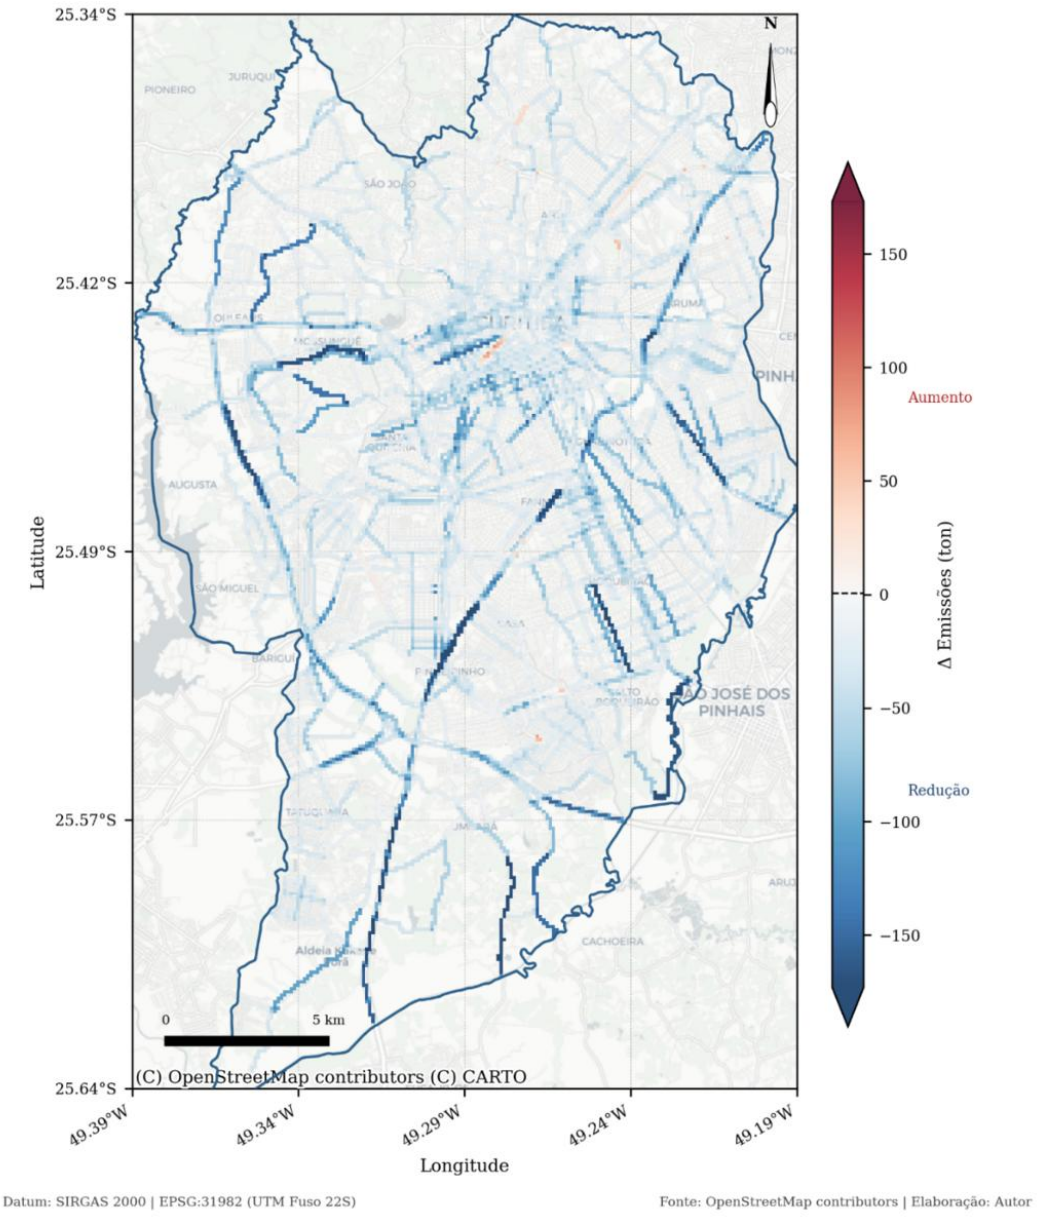

Fonte: Elaborado pelos autores (2026).

4. CONSIDERAÇÕES FINAIS

O estudo demonstrou que a combinação entre modelos de *machine learning* e a abordagem *bottom-up* de estimativa de emissões constitui uma alternativa eficaz e replicável para a construção de inventários veiculares com alta resolução espaço-temporal em cidades brasileiras. O modelo *Random Forest* apresentou elevado desempenho em condições normais de tráfego (R^2 = 0,92 para o volume em março de 2019), com degradação esperada e

interpretável no início do período pandêmico, funcionando como um indicador da magnitude da perturbação imposta à dinâmica urbana.

A análise comparativa entre março de 2019 e março de 2020 evidenciou reduções generalizadas nas emissões de CO_2, com quedas horárias entre 50% e 65% nos períodos de pico. Apesar disso, a estrutura temporal das emissões, caracterizada por ciclos diários bimodais e pelo contraste entre dias úteis e finais de semana, foi preservada, indicando que as restrições de mobilidade afetaram principalmente a magnitude dos deslocamentos, e não sua organização temporal. Esse resultado sugere que reduções expressivas de emissões dependem de intervenções sobre o volume e a distribuição espacial dos fluxos, mais do que sobre sua distribuição ao longo do tempo.

Do ponto de vista espacial, a pandemia promoveu uma redução de emissões seletiva, com as maiores quedas absolutas concentradas nos principais eixos estruturais de Curitiba, que em 2019 apresentavam os maiores níveis de emissão. Esse padrão indica que os corredores associados ao tráfego pendular foram os mais sensíveis às restrições de mobilidade. Por outro lado, a identificação de incrementos pontuais em vias de menor hierarquia sugere processos de redistribuição do tráfego, possivelmente relacionados à manutenção de atividades essenciais e ao escoamento logístico.

Em conjunto, os resultados fornecem subsídios relevantes para o planejamento urbano e a formulação de políticas de mobilidade orientadas territorialmente, contribuindo para a compreensão das relações entre infraestrutura viária, padrões de deslocamento e emissões atmosféricas, tanto em contextos de normalidade quanto em situações de perturbação sistêmica.

REFERÊNCIAS

ANJOS, Max; MEIER, Fred. Zooming into Berlin: tracking street-scale CO2 emissions based on high-resolution traffic modeling using machine learning. **Frontiers in Environmental Science**, v. 12, p. 1461656, 2025.

BRASIL. Ministério da Infraestrutura. Secretaria Nacional de Trânsito. **Frota de veículos - 2020**. Brasília, DF: Ministério da Infraestrutura, 2020. Disponível em: https://www.gov.br/transportes/pt-br/assuntos/transito/conteudo-Senatran/frota-de-veiculos-2020. Acesso em: 9 jun. 2025

BREIMAN, Leo. Random forests. **Machine learning**, v. 45, n. 1, p. 5-32, 2001.

CASTELHANO, Francisco Jablinski. **Qualidade do ar no AUC (aglomerado urbano de Curitiba/PR) - configuração atual e perspectivas no âmbito das mudanças climáticas globais**. 2019. Tese (Doutorado em Geografia) – Universidade Federal do Paraná, Curitiba, 2019.

CETESB, **Poluição do Ar: Gerenciamento e Controle de Fontes** – 2017. Disponível em: https://cetesb.sp.gov.br/posgraduacao/wp-content/uploads/sites/33/2017/11/Apostila-Poluição-do-Ar-Gerenciamento-e-Controle-de-Fontes.pdf. Acesso em 01 maio. 2025.

COZZI, Laura et al. World energy outlook 2020. **Energy**, v. 2019, p. 30, 2020.

DANCHO, Matt; VAUGHAN, Davis; DANCHO, Maintainer Matt. **Package 'timetk'**. 2022.

DANNI-OLIVEIRA, I.M, **A cidade de Curitiba e a Poluição do ar**, Tese de doutorado, USP, 2000.

GURNEY, K. R. *et al.* Indianapolis flux experiment (INFLUX): Reconciling top-down and bottom-up approaches. **Elementa: Science of the Anthropocene**, v. 5, p. 21, 2017.

IBARRA-ESPINOSA, Sergio *et al.* VEIN v0. 2.2: an R package for bottom–up vehicular emissions inventories. **Geoscientific Model Development**, v. 11, n. 6, p. 2209-2229, 2018.

IPCC. *Climate Change 2023: Synthesis Report*. Contribution of Working Groups I, II and III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. Geneva: Intergovernmental Panel on Climate Change, 2023.

KUHN, Max *et al.* Applied predictive modeling. **New York: Springer**, 2013.

KUHN, Max; WICKHAM, Hadley. **Package 'recipes'**. 2022.

LE QUÉRÉ, Corinne *et al.* Temporary reduction in daily global CO2 emissions during the COVID-19 forced confinement. **Nature climate change**, v. 10, n. 7, p. 647-653, 2020.

PADGHAM, Mark *et al.* osmdata. **Journal of Open Source Software**, v. 2, n. 14, 2017.

SCHMITZ, Lisana Katia; DE ASSIS MENDONÇA, Francisco. Reestruturação urbana e conforto térmico: cenários de modelização em Curitiba-PR após a copa de 2014. **Revista Brasileira de Climatologia**, v. 8, 2011.

VORMITTAG, Evangelina da Motta PA de Araújo *et al.* Análise do monitoramento da qualidade do ar no Brasil. **Estudos Avançados**, v. 35, n. 102, p. 7-30, 2021.

WRIGHT, Marvin N.; ZIEGLER, Andreas. ranger: **A fast implementation of random forests for high dimensional data in C++ and R**., 2015.