

## Desenvolvimento de um modelo de regressão de uso do solo para as concentrações de *black carbon* medidas a bordo de bicicletas em Curitiba

## Development of a land use regression model for black carbon concentrations measured on bikes in Curitiba, Brazil.

**Yago Alonso Cipoli**

[yago.a.cipoli@gmail.com](mailto:yago.a.cipoli@gmail.com)

Estudante do curso de Engenharia Ambiental  
Universidade Tecnológica Federal do Paraná, Londrina, Paraná, Brasil.

**Admir Créso de Lima Targino**

[admirtargino@utfpr.edu.br](mailto:admirtargino@utfpr.edu.br)

Professor do Programa de Pós-Graduação em Engenharia Ambiental  
Universidade Tecnológica Federal do Paraná, Londrina, Paraná, Brasil.

**Patricia Krecl**

[patriciak@utfpr.edu.br](mailto:patriciak@utfpr.edu.br)

Professora do Programa de Pós-Graduação em Engenharia Ambiental  
Universidade Tecnológica Federal do Paraná, Apucarana, Paraná, Brasil.

### RESUMO

A qualidade do ar urbano apresenta uma grande variabilidade espacial em microescala, para poluentes oriundos do tráfego veicular, como o black carbon (BC). Devido aos efeitos adversos das partículas de BC sobre a saúde humana e o clima, o conhecimento da sua variabilidade espaço-temporal é relevante para gerenciar a qualidade do ar e para melhor diagnosticar a exposição da população a esse poluente. O estudo foi realizado dentro do marco da cooperação bilateral Sueco-Brasileira (Projeto ParCur), e foram medidas as concentrações de BC no centro de Curitiba com monitores a bordo de bicicletas em horários de pico de trânsito em agosto de 2016. Simultaneamente foram coletados dados de BC numa estação fixa afastada 13 km do centro. A modelagem por regressão linear múltipla identificou a taxa de tráfego de veículos pesados (ônibus + caminhões) e a velocidade do vento como as melhores variáveis preditoras de concentrações de BC móveis, mas explicou apenas 19% da variabilidade observada. O estudo inovador no Brasil provou ser uma abordagem efetiva para mapear concentrações de poluentes atmosféricos, como no caso do BC. Além disso, é possível localizar com maior precisão áreas que oferecem riscos à população, o que não seria possível com os tradicionais monitoramentos fixos que cobrem pequenas áreas da cidade.

**PALAVRAS-CHAVE:** Poluição do ar. Poluente climático de vida curta. Monitoramento móvel. Regressão linear múltipla.

### ABSTRACT

The urban air quality presents a large spatial variability at microscale, particularly for pollutants emitted by vehicular traffic, such as black carbon (BC). Due to the adverse effects of BC particles on human health and climate, knowledge of their spatio-temporal variability is relevant for air quality management and to better diagnose the population's exposure to this pollutant. The study was carried out within the framework of the Brazilian-Swedish bilateral cooperation (ParCur Project), and BC concentrations were monitored with instruments on-board bikes in the center of Curitiba at peak traffic times in August 2016. Simultaneously, BC was measured at a fixed site 13 km away from the center. Multiple linear regression identified the traffic rate of heavy-duty vehicles and wind speed as the best predictors of mobile BC concentrations, but explained only 19% of the observed variability. This innovative study in Brazil proved to be effective for mapping BC concentrations. In addition, it is possible to more accurately locate areas that pose risks to the population, which would not be possible with the traditional fixed monitoring that cover small areas of the city.

**KEYWORDS:** Air pollution. Short-lived climate pollutant. Mobile sampling. Multiple linear regression.

**Recebido:** 29 ago. 2018.

**Aprovado:** 04 out. 2018.

#### Direito autorial:

Este trabalho está licenciado sob os termos da Licença Creative Commons-Atribuição 4.0 Internacional.



## INTRODUÇÃO

A qualidade do ar urbano apresenta uma grande variabilidade espacial em microescala para poluentes atmosféricos oriundos do tráfego veicular, como o *black carbon* (BC) (KRECL et al., 2014; TARGINO et al., 2016; TARGINO et al., 2018). O BC é uma fração do material particulado que é emitido pela queima incompleta de combustíveis fósseis e biomassa (BOND et al., 2013), e está associado a vários efeitos adversos a saúde humana e ao clima (WHO, 2012).

Múltiplos estudos da exposição a poluição do ar mostram que as concentrações dos poluentes estão diretamente relacionadas ao uso de solo e às atividades circundantes (e.g., BRIGGS, 2005; KOLOVOS et al., 2010). A Regressão do Uso de Solo (*Land Use Regression* em inglês, LUR) é um método muito utilizado para vincular as concentrações do poluente de interesse (variável dependente) com variáveis como trânsito, topografia e meteorologia (variáveis independentes) através de um modelo de regressão múltipla (e.g., KRECL et al., 2014; HANKEY et al., 2015; BOSSCHE et al., 2018).

No entanto, a modelagem LUR é um desafio complexo devido à alta variabilidade espaço-temporal das concentrações de poluentes na escala local e a necessidade de um grande conjunto de dados. Por exemplo, Hoek et al. (2008) recomendam de 40 a 80 locais de amostragem para obter-se um modelo urbano adequado. Nesse caso, o monitoramento móvel de poluentes atmosféricos é ideal porque permite medir concentrações com uma cobertura espacial maior e com menor custo de operação que as redes de estações fixas (e.g., KRECL et al., 2014).

No presente trabalho, desenvolvemos um modelo LUR para as concentrações de BC medidas com instrumentos a bordo de bicicletas no centro de Curitiba nos horários de pico de trânsito. Primeiramente avaliamos as concentrações de BC dentro da malha estudada com alta resolução espaço-temporal, e depois combinamos algumas variáveis de uso de solo em um LUR para identificar os melhores preditores de BC na região de estudo.

## METODOLOGIA

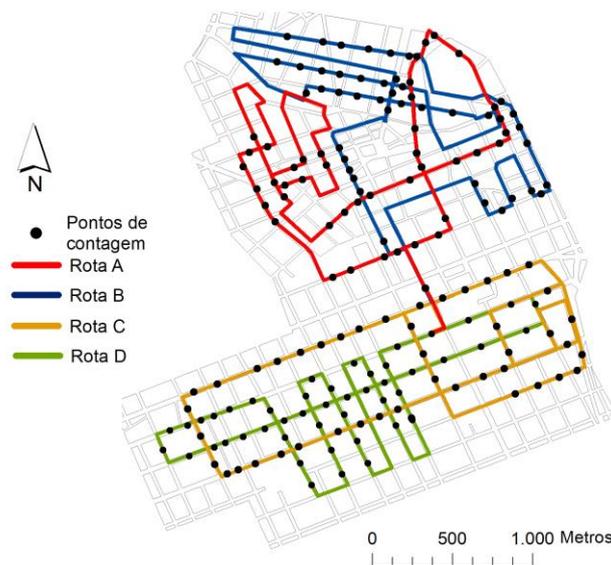
### MEDIÇÕES MÓVEIS E FIXAS

As concentrações de BC foram monitoradas com microaetalômetros AE51 (AethLabs, EUA) instalados em bicicletas que percorreram quatro rotas no centro de Curitiba (Fig. 1). Os dados foram georreferenciados com receptores de GPS (GlobalSat, Taiwan). As coletas foram realizadas em oito dias de semana (duas rotas por vez) em turnos da manhã e tarde (7-9h e 16-18h) no período 01-14 de agosto de 2016, e com alta resolução temporal (dados de BC a cada 10s e GPS a cada 1s). As rotas foram projetadas para abranger vários níveis de tráfego, diferentes usos de solo e para cobrir a maior área dentro das delimitações, evitando sobreposições e recuos por trajetos já realizados, seguindo o desenho experimental de Targino et al. (2016).

Simultaneamente, um monitor AE51 mediu a cada 1 min a concentração de BC em um ponto fixo no bairro Sítio Cercado (13 km do centro) que foi utilizado como estação urbana de referência com pouco impacto veicular. Além disso, foram usadas variáveis meteorológicas medidas no campus da Universidade Federal do Paraná (UFPR) pelo Instituto Nacional de Meteorologia (INMET). Dados de contagens horárias de trânsito (por categoria de veículo) do

centro foram fornecidos pelo Instituto de Pesquisa e Planejamento Urbano de Curitiba (IPPUC).

Figura 1 – Mapa do centro de Curitiba com as quatro rotas de amostragem e os pontos de contagem de tráfego (círculos pretos).



Fonte: Autoria própria (2018).

## ANÁLISE ESTATÍSTICA E TRATAMENTO DE DADOS

As emissões veiculares são uma fonte importante de BC nas cidades, onde também podem existir contribuições esporádicas de outras fontes locais ou regionais (TARGINO e KRECL, 2015; KRECL et al., 2016). Para salientar a contribuição das emissões veiculares e diminuir as contribuições esporádicas, as medições feitas em bicicleta foram ajustadas seguindo a metodologia de DONS et al. (2012). A correção está baseada nas variações da concentração de BC medida numa estação de referência (neste caso, o Sítio Cercado) que sofre pouca influência de fontes locais.

Posteriormente, aplicou-se uma regressão linear múltipla com método de busca sequencial (estimação *stepwise*) que examina a relação entre uma variável dependente (concentração de BC móvel) e variáveis independentes (Tabela 1), que são adicionadas sequencialmente se contribuem pelo menos com 1% para o aumento do  $R^2$  ajustado. Essas variáveis também devem atender às suposições de normalidade, linearidade, homoscedasticidade e não apresentar multicolinearidade.

Para cada um dos 196 pontos de contagem de veículos sobre as rotas percorridas, foram criados *buffers* com raio de 30 metros (evitando sobreposições e intersecções de ruas) e calculou-se o valor médio de cada variável dentro de cada *buffer*. Como algumas variáveis (BC e NV) não apresentaram distribuição normal nem homoscedasticidade, foram aplicadas transformações logarítmicas para remediar a situação. Para a análise de linearidade e multicolinearidade, foi calculada a matriz de coeficientes de correlação de Pearson (R) das variáveis independentes e dependente. Se duas variáveis independentes forem altamente correlacionadas entre si ( $R > 0,95$ ), a

variável que apresentou menor correlação com a variável dependente é excluída. Em um segundo passo, identificou-se a variável com a maior correlação com a variável dependente para cada subcategoria. Se outras variáveis na mesma subcategoria estiverem correlacionadas ( $R > 0,6$ ) com a variável mais altamente classificada, elas foram removidas.

Tabela 1 – Variáveis candidatas a predictoras

Variáveis independentes (Siglas)	Medições
Black carbon (BC <sub>SC</sub> )	Sítio Cercado
Velocidade bicicleta (VB)	GPS acoplado na bicicleta
Temperatura (T <sub>H</sub> ) e umidade (UR <sub>H</sub> )	Equipamento (HOBO) acoplado na bicicleta
Temperatura (T)	
Umidade (UR)	
Pressão atmosférica (P)	Estação meteorológica (INMET – UFPR)
Velocidade do vento (VV)	
Direção do vento (DV)	
Número total de veículos (NV)	
Carros + Motos (NV <sub>leve</sub> )	
Caminhões + Ônibus (NV <sub>pesado</sub> )	Centro (IPPUC), valores horários nos períodos 7-9h e 16-18h
Carros (N <sub>carro</sub> ), Motos (N <sub>moto</sub> )	
Ônibus (N <sub>ônibus</sub> ), Caminhões (N <sub>cam</sub> )	

Fonte: Autoria própria (2018).

## RESULTADOS E DISCUSSÃO

Para todos os dados estatísticos considerados, as concentrações de BC móveis foram sempre superiores às da estação de referência e apresentaram uma maior variabilidade como esperado para uma área impactada pelo tráfego veicular (Tabela 2). As concentrações médias de BC por rota variaram entre  $6,2 \mu\text{g m}^{-3}$  e  $8,5 \mu\text{g m}^{-3}$ , sendo a rota D a mais poluída. As maiores diferenças entre as concentrações de BC das rotas se deram para o perfil 95 do que para o perfil 5:  $8,4 \mu\text{g m}^{-3}$  e  $0,5 \mu\text{g m}^{-3}$ , respectivamente.

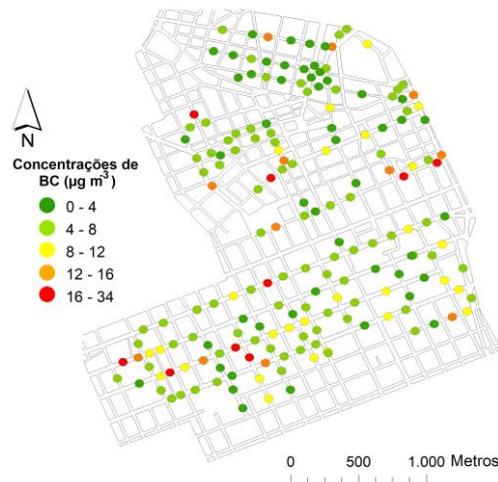
Tabela 2 – Estatísticas descritivas por rota para todos os dias juntos (10s), juntamente com valores do monitoramento fixo (1min)

BC [ $\mu\text{g m}^{-3}$ ]	Rota A	Rota B	Rota C	Rota D	Sítio Cercado
Média	6,7	6,2	7,7	8,5	2,2
Mediana	3,9	3,3	4,8	4,2	1,5
Máximo	309,0	921,1	426,4	353,2	10,1
Percentil 95	18,9	17,1	21,6	25,5	5,3
Percentil 5	1,4	1,4	1,8	1,9	0,4
Desvio padrão	12,4	23,3	14,1	20,5	1,6
Número de amostras	3553	1854	2688	986	9081

Fonte: Autoria própria (2018).

A estratégia de usar BC médio por *buffer* aumenta o poder de predição do modelo LUR, já que valores extremos diminuem com o cálculo de médias (Fig. 2).

Figura 2 – Mapa do centro com as concentrações médias de BC para cada *buffer*.



Fonte: Autoria própria (2018).

Após descartar algumas variáveis por multicolinearidade, o método de estimação *stepwise* foi iniciado com cinco variáveis independentes ( $\log(BC_{Sc})$ ,  $\log(NV_{\text{pesado}})$ , VB, VV, e VD) sendo que só duas variáveis foram escolhidas como importantes na predição de  $\log(BC_{\text{ajustado}})$  com indicado na Eq. (1):

$$\log(BC_{\text{ajustado}}) = 1,201 + 0,235 \cdot \log(NV_{\text{pesados}}) - 0,171 \cdot VV. \quad (1)$$

A variável independente com maior contribuição foi o número de veículos pesados, seguida pela velocidade do vento. Porém, a velocidade do vento teve uma contribuição negativa para as concentrações de BC, como descrito na Eq. 1. Um estudo realizado por Krecl et al. (2014) com medições móveis de BC em Estocolmo (Suécia) também identificou uma variável de trânsito (NV) e VV como as variáveis de predição importantes durante o dia (06-18h), quando aplicado o método *stepwise*.

## CONCLUSÃO

Uma grande variabilidade espacial das concentrações de BC foi observada no centro de Curitiba nos horários de pico de trânsito em relação com uma área suburbana com pouco impacto veicular. Em média, as concentrações de BC foram até quatro vezes maiores no centro em relação com a área suburbana.

Mesmo com um modelo explicando somente 19% da variância observada nas concentrações de BC móveis, foi possível identificar as melhores variáveis preditoras. A contribuição positiva para as concentrações de BC se dá com o aumento do número de veículos pesados (principais fontes de emissão de BC em centros urbanos). Por outro lado o aumento da velocidade do vento diminui as concentrações de BC, devido aos efeitos de diluição e dispersão. O modelo proposto não é efetivo para fins de previsão, porém permitiu explicar em parte as contribuições para a distribuição espaço-temporal derivada das concentrações de BC.



## REFERÊNCIAS

BRIGGS, D. The role of GIS: coping with Space (and time) in air pollution exposure assessment. **Journal of Toxicology and Environmental Health, Part A**, v. 68, n. 13-14, p.1243-1261, 2005.

BOND, T. C. et al. Bounding the role of black carbon in the climate system: A scientific assessment. **Journal of Geophysical Research: Atmospheres**, v. 118, n. 11, p.5380-5552, 2013.

BOSSCHE, J. V. D. et al. Development and evaluation of land use regression models for black carbon based on bicycle and pedestrian measurements in the urban environment. **Environmental Modelling & Software**, v.99, p.58-69, 2018.

DONS, E. et al. Personal exposure to black carbon in transport microenvironments. **Atmospheric Environment**, v.55, p.392-398, 2012.

HANKEY, S.; MARSHALL, J. D. Land use regression models of on-road particulate air pollution (particle number, black carbon, PM<sub>2.5</sub>, particle size) using mobile monitoring. **Environmental Science & Technology**, v.49, n.15, p.9194-9202, 2015.

HOEK, G. et al. A review of land-use regression models to assess spatial variation of outdoor air pollution. **Atmospheric Environment**, v.42, n.33, p.7561-7578, 2008.

KRECL, P. et al. A feasibility study of mapping light-absorbing carbon using a taxi fleet as a mobile platform. **Tellus B: Chemical and Physical Meteorology**, v.66, n. 1, p.23533, 2014.

KOLOVOS, A. et al. Multi-perspective analysis and spatiotemporal mapping of air pollution monitoring data. **Environmental Science & Technology**, v.44, n.17, p.6738-6744, 2010.

TARGINO, A. C. et al. Hotspots of black carbon and PM<sub>2.5</sub> in an urban area and relationships to traffic characteristics. **Environmental Pollution**, v.218, p.475-486, 2016.

TARGINO, A. C. et al. Commuter exposure to black carbon particles on diesel buses, on bicycles and on foot: a case study in a Brazilian city. **Environmental Science and Pollution Research**, v.25, n.2, p.1132-1146, 2017.

WORLD HEALTH ORGANIZATION (European Office). Health Effects of Black Carbon. Copenhagen, Denmark: WHO, 2012.



## AGRADECIMENTOS

Ao CNPq pela cessão da bolsa de Iniciação Tecnológica e pelo financiamento de equipamentos (CNPq 404146/2013-9), à Prefeitura de Curitiba pelo apoio logístico, à Guarda Municipal pelo respaldo nas coletas, ao IPPUC e INMET pelo fornecimento de dados, e ao *Swedish Meteorological Hydrological Institute* pelo financiamento dos trabalhos em campo.