

## AVALIAÇÃO ESPACIAL ENTRE POLUIÇÃO DO AR E SAÚDE EM ÁREAS COM LIMITAÇÃO DE DADOS

*Spatial evaluation between air pollution and health in areas with limitation of data*

Weeberb João Réquia<sup>1</sup>

Henrique Llacer Roig<sup>1</sup>

Universidade de Brasília, Instituto de Geociências, Brasília, CEP 70910-900, DF, Brasil<sup>1</sup>  
weeberb@gmail.com; roig@unb.br

### **Resumo:**

A poluição do ar é um grave problema de saúde pública a nível mundial. Os estudos que investigam a relação entre poluição atmosférica e saúde humana são a base para a gestão que visa promover o desenvolvimento urbano e qualidade de vida. Nesse sentido, a disponibilidade de dados é uma premissa inicial para esses estudos, sobretudo, para os que têm o enfoque na avaliação espacial. O problema é que muitos centros urbanos ainda carecem de um sistema de armazenamento, consolidação e disponibilização dos dados. Diante desse cenário, este artigo teve como objetivo propor um método para avaliação espacial entre poluição do ar e saúde em áreas urbanas que têm limitações na disponibilidade de dados. O método proposto foi baseado em procedimentos de orientação a objetos para integração de um banco de dados geográficos, considerando dados de internações e inventário de poluição do ar. Posteriormente, foi realizada uma análise de correlação e regressão espacial - *Ordinary Least Square* (OLS). Os resultados mostraram que o método proposto é uma alternativa viável para as áreas com limitações de dados. As análises de correlação e regressão apresentaram uma relação significativa ( $p < 0,05$ ) entre poluição e saúde.

**Palavras-chaves:** Banco de dados geográficos, Saúde humana, Poluição do ar.

### **Abstract**

Air pollution is a serious public health problem worldwide. Studies that investigate the relationship between air pollution and human health are fundamental for management that aims to promote the urban development and life quality. Data availability is an initial premise for these studies, especially, for it that have focus in the spatial evaluation. The problem is that many urban centers do not have a system to consolidate and storage data. Thus, this paper aimed to propose a method for spatial evaluation between air pollution and health in urban areas that have limitation in data availability. The method proposed was based on object orientation for geographic information system, considering hospital admissions data and air pollution inventories. Also, was applied a correlation analysis and a spatial regression – *Ordinary Least Square* (OLS). Results showed that the method proposed is an alternative for area with data

availability. Correlations analysis and regression showed a significant relationship ( $p < 0.05$ ) between air pollution and health.

**Keywords:** Geographic database, Human Health, Air pollution.

## 1. Introdução

A elevada concentração de gases e partículas na atmosfera é um grave problema para a saúde humana (Ashworth et al., 2013). O ar poluído pode causar doenças, por exemplo, no sistema respiratório (Nandasena, Wickremasinghe, and Sathiakumar 2012) e circulatório (Mortimer et al. 2012), sobretudo nas crianças (Buonanno, Marks, and Morawska, 2013) e nos idosos (Wai et al., 2013).

A Organização Mundial de Saúde (OMS) destaca que a poluição atmosférica foi a causa de 223 mil mortes por câncer de pulmão em todo o planeta no ano de 2010 (OMS, 2013). Solomon et al. (2011) mostram que a diminuição de  $10 \text{ mg/m}^3$  do material particulado presente na atmosfera com até  $2,5 \mu\text{m}$  representaria um aumento em 1,5 à expectativa de vida das pessoas.

Nesse contexto, os estudos que buscam entender a relação entre poluição do ar e saúde (estudos em saúde ambiental) direcionam as tomadas de decisões com o objetivo de minimizar os efeitos da poluição sobre a população. Como exemplo desse direcionamento, pode-se citar a implementação de políticas públicas em saúde, meio ambiente, transporte e planejamento urbano (Yerramilli, Dodla, and Yerramilli, 2011; Bateman et al., 2013).

A disponibilidade de dados para os estudos em saúde ambiental é uma premissa inicial, especialmente para os estudos com enfoque epidemiológico (Beevers et al., 2013). No caso específico entre poluição do ar e saúde humana, os dados comumente utilizados são decorrentes das estações de monitoramento de poluição atmosférica (concentração do poluente) e dos órgãos de gestão em saúde (número de óbitos, internações), respectivamente.

Nesse sentido, é um desafio o desenvolvimento dos estudos em saúde ambiental em algumas áreas onde os dados possuem limitações ou até mesmo estão indisponíveis. Essa é a realidade de muitas áreas urbanas brasileiras. O desafio é maior quando se buscar avaliar as relações espaciais entre poluição e saúde (Madsen et al., 2011).

Por exemplo, quanto aos dados de poluição do ar no Brasil, Alves et al. (2014) mostram que do total de 5.570 municípios, apenas 1,7% possuem monitoramento da qualidade do ar. Há no país um total de 252 estações de monitoramento. Porém, o problema se agrava, pois nem toda estação monitora os poluentes mínimos exigidos pelo Conselho Nacional do Meio Ambiente (Conama 1990), que são particulados de até  $10 \mu\text{c}$  ( $\text{PM}_{10}$ ), particulados de até  $2,5 \mu\text{c}$  ( $\text{PM}_{2,5}$ ), ozônio ( $\text{O}_3$ ), dióxido de enxofre ( $\text{SO}_2$ ), dióxido de nitrogênio ( $\text{NO}_2$ ) e monóxido de carbono ( $\text{CO}$ ).

E quanto aos dados de saúde, a dificuldade é quanto à acurácia, precisão e integração de banco de dados. Por exemplo, os endereços residenciais das pessoas que compareceram aos hospitais brasileiros muitas das vezes são incompletos. Essa é uma informação importante nos estudos epidemiológicos com enfoque espacial (Hoffman et al., 2012; Su, Jerrett, and Beckerman, 2009). E quando algum endereço apresenta uma melhor precisão, o problema passa a ser para a integração em um banco de dados geográfico.

Diante desse cenário, o qual é a realidade de muitos centros urbanos, sobretudo brasileiros, este artigo tem como objetivo propor um método para avaliação espacial entre poluição do ar e saúde em áreas urbanas que têm limitações na disponibilidade de dados. Destaca-se que a limitação de dados considerada neste estudo é baseada em quatro características de centros urbanos: a) quando não possui uma rede de monitoramento da qualidade do ar; b) quando a rede de monitoramento da qualidade do ar é incompleta ou não representativa, conforme o Conama (1990); c) quando os dados de saúde não são integrados a um Sistema de Informações Geográficas (SIG); d) quando os dados de saúde não são diretamente relacionados com outras bases de dados.

## **2. Métodos**

### **2.1. Área de estudo**

O estudo foi realizado para a região do Distrito Federal (DF). A região foi escolhida pois apresenta três (b, c, d) das quatro características definidas neste estudo como um área com limitação de dados.

A rede de monitoramento de poluição atmosférica do DF ainda é incompleta e pouco representativa (Réquia Júnior, Roig, and Koutrakis, 2015). A rede é composta por sete estações fixas que monitoram Particulados Totais em Suspensão (PTS), o que resulta em uma relação de 1,38 estações por 1.000 km<sup>2</sup> e 0,32 estações para cada 100 mil habitantes. Comparando com redes consideradas eficientes, segundo Alves et al. (2014), só nos Estados Unidos e na Europa (áreas significativamente maiores que o DF) possuem 0,5 e 1,7 estações por 1.000 km<sup>2</sup>, respectivamente; e respectivos valores de 16 e 14,8 estações para cada 100 mil habitantes. E quanto ao sistema de saúde do DF, especificamente quanto ao banco de dados dos pacientes, não são integrados a um SIG e não são relacionados com outras bases de dados, tais como, transporte, meio ambiente ou dados socioeconômicos.


### **2.2. Dados**

Foram utilizados neste estudo quatro conjuntos de dados: inventário de poluição, saúde, endereçamento residencial e setor censitário. Quanto aos dados de inventário, o objetivo é mostrar que é um dado alternativo no caso de áreas que não possuem uma rede de monitoramento, ou quando a rede ainda é ineficiente. Os dados utilizados se referem a um cálculo de inventário espacial que tomou como base o número de veículos circulantes nas principais vias do DF. O inventário foi feito para os seguintes poluentes: óxidos de enxofre (NO<sub>x</sub>), hidrocarbonetos (NMHC), PTS, dióxido de carbono (CO<sub>2</sub>), monóxido de carbono (CO) e metano (CH<sub>4</sub>). Informações mais detalhadas desse estudo de inventário são encontradas no trabalho de Réquia Júnior et al. (2015).

Em relação aos dados de saúde, foram fornecidos pelo Ministério da Saúde - Datasus por meio de solicitação formal. Os dados são referentes às pessoas atendidas e internadas nos hospitais do DF durante o período de 2008 a 2013 (com informações diárias) por motivo de doenças do sistema respiratório e circulatório. Os dados fornecidos apresentaram a classificação pessoal de

cada paciente quanto à idade, ao sexo e ao endereço residencial. Especificamente quanto ao endereço, não foram fornecidos o exato endereço com vista à preservação da integridade dos pacientes. Destaca-se que os dados fornecidos pelo Ministério se apresentam em formato de planilha eletrônica.

Quanto aos dados de endereçamento residencial, foram fornecidos pela Secretaria de Estado de Habitação Regularização e Desenvolvimento Urbano do Distrito Federal (SEDHAB). Os dados têm o formato espacial vetorial do tipo polígono, são referentes ao ano de 2012 e são sobre o sistema de endereçamento de todo o DF. Não há no DF uma padronização de endereçamento para toda área urbana. Mas em geral, o endereçamento é classificado segundo a seguinte ordem hierárquica: regiões administrativas (RA), setores, quadras, conjuntos e lotes, conforme apresentado pela Figura 1.




**Figura 1:** Padrão de endereçamento adotado na maior parte das áreas urbanas no DF.

E em relação aos dados do setor censitário, foram obtidos pelo Instituto Brasileiro de Geografia e Estatística (IBGE). Os dados utilizados se referem ao número de pessoas classificados por idade que vivem em cada setor censitário. Essa base de dados tem o formato espacial vetorial do tipo polígono e se refere ao ano de 2010.

### 2.3. Procedimentos e análises

Inicialmente, o dado original sobre a ocorrência de doenças foi relacionado com a base de dados espacial da SEDHAB. O objetivo desse processo foi criar o banco de dados geográfico (BDGeo). O endereço dos pacientes foi o parâmetro base para a criação desse banco de dados. Destaca-se que o endereço estava disponível em ambas as fontes, Ministério da Saúde (endereço dos pacientes) e SEDHAB (endereço oficial de todo o DF). Porém, a definição de endereçamento entre o Ministério da Saúde e a SEDHAB não são correlacionáveis, o que necessitou a padronização das informações para posterior sincronização das bases de dados.

Em seguida, os dados de saúde do BDGeo foram normalizados usando como referência a população residente de cada nível de endereçamento considerado (dados do IBGE). Os dados normalizados foram então integrados (relacionamento espacial) junto com os dados de poluição (inventário). Essa integração permitiu estimar a quantidade de poluente em cada endereço de paciente. Por fim, foi avaliada a relação entre o local de residência de cada paciente com a poluição atmosférica. A Figura 2 apresenta o fluxo dos procedimentos realizados no estudo.



**Figura 2:** Fluxograma do estudo.

Destaca-se que os dados de inventário do estudo de Réquia Júnior et al. (2015) se referem a cada segmento de via estudado. Para o presente estudo, foi necessário estimar uma superfície de poluição identificada pelo inventário. Para isso, usou-se o método de interpolação conhecido como IDW – *inverse distance weighting*. O IDW estima os valores em função da distância e magnitude dos pontos adjacentes amostrados (PHILIP, 1982 apud ESRI, 2008). A Equação 1 apresenta a formulação algébrica utilizado pelo IDW.

$$Z_j = \frac{\sum Z_i / d_{ij}^\beta}{\sum 1 / d_{ij}^\beta} \quad (1)$$

Em que,  $Z_j$  é o ponto a ser interpolado,  $d_{ij}$  a distância de  $Z_j$  a amostra  $Z_i$ , e  $\beta$  é o peso estipulado.

E quanto à avaliação da relação entre saúde e poluição, foi utilizado o teste de correlação de Pearson e uma análise de regressão espacial OLS – *Ordinary Least Squares*. Como o objetivo do presente estudo não foi criar um modelo que represente a ocorrência de doenças do sistema cardiorrespiratório, o método OLS foi utilizado somente com o intuito de verificar a direção e significância do coeficiente  $\beta$  de cada variável preditora (poluição do ar).

Por fim, destaca-se que foram utilizados no presente artigo como ferramenta operacional o programa ArcGIS v.10.2 e R v.3.13.


### 3. Resultados

#### 3.1. Método para criação do banco de dados em SIG

O método foi dividido em duas partes. A primeira relacionada à criação do banco de dados geográfico e a segunda para a normalização.

Quanto à primeira parte, o processo iniciou com o tratamento dos dados fornecidos pelo Ministério da Saúde. A planilha eletrônica dos dados de saúde apresentou um total de 10.901 pacientes. Considerou-se a partir desse número o descarte, que nesse estudo foi de 3.129 (~30%). Esse descarte foi realizado para aqueles endereços que se apresentavam de forma incompleta, sendo impossível identificar o local da residência. Os motivos do endereço incompleto podem ser, por exemplo, o erro de preenchimento da ficha cadastral pelo funcionário no momento que o paciente compareceu ao hospital. Não se rejeita também a possibilidade do paciente ocultar informações do endereço residencial no preenchimento da ficha, com o intuito de agilizar o atendimento.

Com os endereços validados, criou-se o BDGeo. Esse banco foi composto por quatro níveis de endereçamento – lotes, conjuntos, quadras e setores (os quatro primeiros níveis de endereço do DF). Essa diferenciação foi devido ao nível de endereçamento disponível na planilha original do Ministério da Saúde. Por exemplo, para os pacientes que tinham informação do setor, quadra, conjunto e lotes, foram consolidados no banco dos lotes (65 lotes, 571 pacientes). Para os pacientes que tinham informação do setor, quadra e conjuntos, foram consolidados no banco dos conjuntos (1.084 conjuntos, 2.938 pacientes). Para os pacientes que tinham informação do setor e quadras, foram consolidados no banco das quadras (361 quadras, 3.038 pacientes). E para os pacientes que tinham informação somente dos setores, foram consolidados no banco dos setores (37 setores, 1.225 pacientes). Por fim, optou-se por consolidar todas as informações em um único nível de endereçamento. Para isso, utilizou-se a inteligência do banco de dados geográficos (orientação a objeto – pai e filho), em que as informações dos polígonos internos (filhos) eram agrupadas e transferidas para os polígonos envoltórios (pais). Esse processo gerou uma perda de 706 observações, no qual esse relacionamento espacial não pode ser mantido. Como resultado final, obteve-se 169 feições geográficas, e um total de 7.066 pacientes, cobrindo toda a área urbana do DF. A Figura 3 apresenta o fluxo de todo o processo para a primeira parte do método.




**Figura 3:** Fluxo dos processos para a primeira parte do método.

Em relação à segunda parte o método, referiu-se à normalização dos dados de saúde contidos no banco de dados em SIG. O cálculo da normalização foi caracterizado pela relação do número de pacientes em cada feição geográfica entre o total de pessoas residentes na respectiva feição geográfica.

A feição geográfica do dado sobre a quantidade de pessoas residentes - setor censitário, Figura 4 (A.1) - não coincide com a feição geográfica do dado de saúde - Figura 3, agregado final. Portanto, assumiu-se que há uma relação linear entre a quantidade de pessoas por área.

Dessa forma, inicialmente foram relacionados os dados do setor censitário (Figura 4 – A.2) com os dados do banco de dados em saúde (Figura 3, agregado final). Esse relacionamento foi possível usando as Regiões Administrativas (RA) do DF como fator chave. Como resultado, foi possível ter a informação sobre a quantidade de pacientes e informações do setor censitário por cada RA do DF (Figura 4 – B). Por fim, procedeu-se com a normalização dos dados, conforme apresentado pela Figura 4 – C.






**Figura 4:** Fluxo dos processos para a segunda parte do método.

Nota: (A.1) – Mapa dos setores censitários do DF, classificados por RA; (A.2) – Tabela de atributos do mapa dos setores censitários; (B) – Tabela de atributos após o relacionamento com os dados do setor censitário; (C) – Procedimento final para a normalização dos dados.

O comportamento da distribuição espacial referente ao número de pacientes de todas as idades nos grupos de endereços do DF pode ser observado na Figura 5, sendo o primeiro mapa (A) para os dados sem normalização, conforme a primeira parte do método apresentado pela Figura 3; e o segundo mapa (B) para os dados normalizados, conforme a segunda parte do método apresentado pela Figura 4.





**Figura 5:** Distribuição espacial do número de pacientes de todas as idades no DF.

Nota: (A) – Número de pacientes sem normalização; (B) – Número de pacientes normalizados.

### 3.2. Avaliação da relação entre saúde e poluição

O grupo etário dos pacientes de até 5 anos e dos pacientes com mais de 59 anos foram os únicos que apresentaram significância. Sendo que o grupo dos pacientes de até 5 anos apresentou significância somente para o poluente CO<sub>2</sub> e o CH<sub>4</sub>. Além disso, encontrou-se significância na

correlação quando a análise foi para todas as idades. Os valores significantes de  $r$  (coeficiente de Pearson) variaram entre 0,2 e 0,3, conforme apresentado pela Tabela 1.

**Tabela 1:** Matriz de correlação entre saúde e poluentes inventariados (valores de coeficiente de Pearson).

Poluentes	Até 5 anos	Entre 6 e 17 anos	Entre 18 e 59 anos	Acima de 59 anos	Todas as idades
NO <sub>x</sub>	0,14	0,07	0,12	0,25*	0,21*
NMHC	0,16	0,09	0,14	0,27*	0,22*
PTS	0,16	0,06	0,15	0,27*	0,22*
CO <sub>2</sub>	0,23*	0,09	0,13	0,29*	0,27*
CO	0,16	0,08	0,08	0,26*	0,25*
CH <sub>4</sub>	0,23*	0,12	0,12	0,31*	0,29*

\* correlação significativa ( $p \leq 0,01$ ).

Quanto à análise de regressão espacial, em todos os casos os valores dos coeficientes foram positivos, confirmando uma relação positiva entre o aumento da quantidade de poluente e o aumento de pacientes. Somente para o grupo etário de pacientes entre 6 e 17 anos não encontrou significância do coeficiente  $\beta$ , conforme apresentado pela Tabela 2.

**Tabela 2:** Resultado da análise de regressão espacial OLS.

Variável dependente	Variável preditora	Coefficiente	Coefficiente (valor)	Erro padronizado	Estatística -t	Probabilidade	
Pacientes até 5 anos	NO <sub>x</sub>	Intercepto	1,299	0,170	7,644	0,000*	
		β	0,296	0,136	2,173	0,031*	
	NMHC	Intercepto	1,269	0,169	7,488	0,000*	
		β	0,329	0,134	2,454	0,014*	
	PTS	Intercepto	1,270	0,169	7,481	0,000*	
		β	0,326	0,134	2,430	0,016*	
	CO <sub>2</sub>	Intercepto	1,063	0,196	5,415	0,000*	
		β	0,368	0,115	3,182	0,001*	
	CO	Intercepto	1,213	0,170	7,119	0,000*	
		β	0,353	0,122	2,891	0,004*	
	CH <sub>4</sub>	Intercepto	1,120	0,178	6,279	0,000*	
		β	0,377	0,112	3,347	0,001*	
	Pacientes entre 6 e 17 anos	NO <sub>x</sub>	Intercepto	0,179	0,058	3,099	0,002*
			β	0,071	0,046	1,533	0,127
NMHC		Intercepto	0,171	0,057	2,959	0,003*	
		β	0,080	0,045	1,756	0,080	
PTS		Intercepto	0,180	0,058	3,096	0,002*	
		β	0,069	0,046	1,518	0,130	
CO <sub>2</sub>		Intercepto	0,168	0,068	2,469	0,014*	
		β	0,053	0,040	1,335	0,183	
CO		Intercepto	0,172	0,058	2,930	0,003*	
		β	0,071	0,042	1,691	0,092	
CH <sub>4</sub>		Intercepto	0,146	0,061	2,375	0,018*	
		β	0,082	0,039	2,106	0,036*	
Pacientes entre 18 e 59 anos		NO <sub>x</sub>	Intercepto	0,995	0,150	6,628	0,000*
			β	0,310	0,120	2,574	0,010*
	NMHC	Intercepto	0,975	0,149	6,511	0,000*	
		β	0,329	0,118	2,784	0,005*	
	PTS	Intercepto	0,970	0,149	6,473	0,000*	
		β	0,334	0,118	2,822	0,005*	
	CO <sub>2</sub>	Intercepto	0,855	0,175	4,880	0,000*	
		β	0,302	0,103	2,935	0,003*	
	CO	Intercepto	0,990	0,152	6,504	0,000*	
		β	0,278	0,109	2,550	0,011*	
	CH <sub>4</sub>	Intercepto	0,864	0,158	5,467	0,000*	
		β	0,343	0,100	3,435	0,000*	
	Pacientes acima de 59 anos	NO <sub>x</sub>	Intercepto	0,879	0,139	6,299	0,000*
			β	0,346	0,112	3,088	0,002*
NMHC		Intercepto	0,861	0,139	6,193	0,000*	
		β	0,361	0,110	3,286	0,001*	
PTS		Intercepto	0,853	0,139	6,132	0,000*	
		β	0,370	0,110	3,369	0,000*	
CO <sub>2</sub>		Intercepto	0,697	0,161	4,316	0,000*	
		β	0,356	0,095	3,746	0,000*	
CO		Intercepto	0,860	0,141	6,099	0,000*	
		β	0,323	0,101	3,199	0,001*	
CH <sub>4</sub>		Intercepto	0,781	0,147	5,294	0,000*	
		β	0,340	0,093	3,643	0,000*	
Pacientes de todas as idades		NO <sub>x</sub>	Intercepto	1,829	0,188	9,700	0,000*
			β	0,405	0,151	2,675	0,008*
	NMHC	Intercepto	1,802	0,188	9,587	0,000*	
		β	0,431	0,148	2,898	0,004*	

\* p&lt;0,01.

#### 4. Discussão e conclusões

O primeiro desafio deste trabalho foi a organização e consolidação da base de dados de saúde. Sugere-se, portanto, que os dados de saúde estejam consolidados e facilmente disponíveis como os dados do setor censitário - IBGE. Dessa forma, o método proposto por este trabalho poderia ser adaptado para uma escala regional ou até mesmo nacional, como já foi feito, por exemplo, para as áreas com a escala da cidade de Roma (Rosenlund et al., 2008) e para os Estados Unidos, escala nacional (Zou et al., 2014).

Especificamente quanto aos Estados Unidos, destaca-se o sistema de endereçamento. É um sistema que possibilita uma melhor acurácia, precisão e, sobretudo uma integração com diversos dados, como o de saúde. Já há uma cultura entre a população de que o número do CEP residencial é uma informação primordial para as atividades do dia-dia, tais como ir ao museu ou comparecer ao hospital para um atendimento. Além disso, o sistema de endereçamento americano segue uma padronização nacional. Diferente do Brasil, que cada cidade e região possuem um padrão distinto. No DF, por exemplo, a ordem hierárquica entre lotes, quadras, conjuntos, setores e RA nem sempre é obedecida em todo o estado. Em muitos casos, não há conjuntos, por exemplo. Esse é um dos motivos que gerou descarte e perda de observações nas operações de criação do banco de dados.

Quanto ao processo adotado para a normalização dos dados, sugere-se para os próximos estudos uma tentativa de melhorar a precisão do método. Pois, não é uma regra de que em todos os casos haverá uma relação linear entre a população residente e a respectiva área ocupada. Dessa forma, futuros estudos podem testar a aplicação da técnica de modelos dasimétricos, como já foi feito por Poulsen e Kennedy (2004), Freitas et al. (2012), Maantay et al. (2013).

Os resultados do teste de correlação e de regressão OLS mostraram que há uma relação espacial significativa de causa e efeito entre poluição do ar e saúde humana, sobretudo para as crianças e para os idosos. Essa relação, em especial para esse grupo etário, já foi identificada anteriormente por Réquia e Abreu (2011), os quais avaliaram com base nos dados regionais do Datusus (não específico por endereços residenciais) e com base nas estações de monitoramento do DF. Além do DF, as crianças e os idosos também já foram identificados como os grupos mais vulneráveis em outras áreas, tais como, Curitiba (Bakonyi et al., 2004), Amazonas (de Oliveira et al., 2012), São Paulo (Arbex et al., 2012; Renata Jasinski, Pereira, and Braga, 2011).

Sugere-se para estudos futuros no DF a avaliação espacial de outras variáveis, tais como temperatura, umidade, renda, educação, uso do solo, fontes de poluição. O BDGeo proposto pelo presente artigo comporta facilmente a importação de dados de outros temas. A introdução dessas variáveis é importante em estudos epidemiológicos, pois são consideradas como variáveis controles (Singhe and Jamal, 2012; Zou et al., 2014; Wang et al., 2013; Robaa, 2011). Dessa forma, seria possível sugerir um modelo espacial para predizer a ocorrência de doenças no DF, o que não foi o objetivo do presente estudo. A ausência dessas variáveis controles pode ter sido o motivo dos valores baixos de  $r$  da correlação de Pearson e dos coeficientes da regressão linear, identificados pelo presente estudo.

Este foi um estudo inicial que objetivou mostrar que há meios alternativos para avaliar a relação entre saúde e poluição nas áreas urbanas com limitação na disponibilidade de dados. Nesse caso, dados de inventário é uma opção para suprir os dados de estações de monitoramento. E uma base geográfica de endereçamentos juntamente com os dados do censo é alternativa para espacializar os dados de saúde.

## AGRADECIMENTOS

Agradecemos à Capes pelo fornecimento da bolsa de estudo de doutorado do autor Weeberb João Réquia Júnior. Agradecemos também ao laboratório de Sensoriamento Remoto e Análise Espacial (LSRAE) do Instituto de Geociências (IG) da Universidade de Brasília (UnB), à Esri pela disponibilidade do pacote de ferramentas que compõem uma família ArcGis 10 por intermédio do contrato 2011 MLK 8733 e à Imagem pelo apoio e viabilidade da concretização do termo de uso entre o IG e a Esri.

## REFERÊNCIAS BIBLIOGRÁFICAS

Alves, E. M., Rodrigues C., Braga, A., Miranda, M., Nascimento, N. C., Saldiva, P. H. N. 2014. *Monitoramento Da Qualidade Do Ar No Brasil*. São Paulo: Instituto Saúde e Sustentabilidade.

Arbex, M. A., Santos, U. P., Martins, L. C., Saldiva, P. H. N., Alberto, L., Pereira, A., Luis, A., Braga, F. 2012. “Air Pollution and the Respiratory System.” *Journal Brazilian Pneumologic* 38 (5): 643–55.

Ashworth, C., Gary, W., Mireille, B. 2013. “Comparative Assessment of Particulate Air Pollution Exposure from Municipal Solid Waste Incinerator Emissions.” *Journal of Environmental and Public Health* 2013: 13.

Bakonyi, S. M. C., Moresco, I., Martins, L. C., Braga, A. L. F. 2004. “Poluição Atmosférica E Doenças Respiratórias Em Crianças Na Cidade de Curitiba , PR.” *Revista Saúde Pública* 38 (5): 695–700.

Bateman, I. J., Harwood, G. M., Mace, R. T., Watson, D. J., Abson, B., Andrews, A., Binner, E. 2013. “Bringing Ecosystem Services into Economic Decision-Making: Land Use in the United Kingdom.” *Science* 341 (6141): 45–50. doi:10.1126/science.1234379.

Beevers, S. D., Nutthida, K., Martin L., Frank, J. K., Ross, A., David, C. 2013. “Air Pollution Dispersion Models for Human Exposure Predictions in London.” *Journal of Exposure Science & Environmental Epidemiology*, February, 1–7. doi:10.1038/jes.2013.6.

Buonanno, G., Guy, M., Morawska, L. 2013. “Health Effects of Daily Airborne Particle Dose in Children: Direct Association between Personal Dose and Respiratory Health Effects.” *Environmental Pollution* 180 (September): 246–50. doi:10.1016/j.envpol.2013.05.039.

Conama. 1990. *Resolução Conama Número 003*. Edited by Ministério do Meio Ambiente. Brasília.

De Oliveira, B. F. A., Ignotti, E., Artaxo, P. 2012. “Risk Assessment of PM<sub>2.5</sub> to Child Residents in Brazilian Amazon Region with Biofuel Production.” *Environmental Health* 11 (64): 1–11. doi:10.1186/1476-069X-11-64.

- Esri. 2013. "Programa de Computador." *Arc Gis (versão 10.2)*. Estados Unidos.
- Freitas, M. B. C., Sousa, A. M. X., Sousa, R. M. F. 2012. "Redistributing Agricultural Data by a Dasymetric Mapping Methodology." *Agricultural and Resource Economics Review* 3 (41): 351–66.
- Hoffman, K., Amy, E. K., Vieira, V. M., Julie, L. 2012. "The Spatial Distribution of Known Predictors of Autism Spectrum Disorders Impacts Geographic Variability in Prevalence in Central North Carolina." *Environmental Health* 11 (1): 80. doi:10.1186/1476-069X-11-80.
- Maantay, J. A., Andrew, R. M., Holly, P. M. 2013. "A New Method for Mapping Population and Understanding the Spatial Dynamics of Disease in Urban Areas: Asthma in the Bronx, New York." *Urban Geography* 29 (7): 724–38. doi:10.2747/0272-3638.29.7.724.
- Madsen, C., Ulrike, G., Siri, E. H. 2011. "Comparison of Land-Use Regression Models for Predicting Spatial NOx Contrasts over a Three Year Period in Oslo, Norway." *Atmospheric Environment* 45 (21): 3576–83. doi:10.1016/j.atmosenv.2011.03.069.
- Mortimer, K., Stephen, B. G., Surinder, K. J. 2012. "Household Air Pollution Is a Major Avoidable Risk Factor for Cardiorespiratory Disease." *Chest* 142 (5): 1308–15. doi:10.1378/chest.12-1596.
- Nandasena, S., Wickremasinghe, A., Nalini, S. 2012. "Respiratory Health Status of Children From Two Different Air Pollution Exposure Settings of Sri Lanka : A Cross-Sectional Study." *American Journal of Industrial Medicine*. doi:10.1002/ajim.22020.
- OMS. 2013. "Outdoor Air Pollution a Leading Environmental Cause of Cancer Deaths." Edited by OMS. Geneva. [http://www.iarc.fr/en/media-centre/iarcnews/pdf/pr221\\_E.pdf](http://www.iarc.fr/en/media-centre/iarcnews/pdf/pr221_E.pdf).
- Poulsen, E., Kennedy, L. W. 2004. "Using Dasymetric Mapping for Spatially Aggregated Crime Data." *Journal of Quantitative Criminology* 20 (3): 243–63.
- Jasinski, R., Amador, A. P., Braga, A. L. F. 2011. "Poluição Atmosférica E Interações Hospitalares Por Doenças Respiratórias Em Crianças E Adolescentes Em Cubatão, São Paulo, Brasil, Entre 1997 E 2004." *Caderno de Saúde Pública* 27 (11): 2242–52.
- Réquia Júnior, W. J., Abreu, L. M. 2011. "Poluição Atmosférica E a Saúde de Crianças E Idosos No Distrito Federal No Período de 2007 a 2009: Utilização Do Método de Correlação Com Time Delay." *Revista Brasileira de Geografia Médica E Da Saúde - Hygeia* 7 (13): 95–108.
- Réquia Júnior, W. J., Koutrakis, P., Roig, H. L. 2015. "Spatial Distribution of Vehicle Emission Inventories in the Federal District, Brazil." *Atmospheric Environment (NO PRELO)*.
- Réquia Júnior, W. J., Roig, H. L., Koutrakis, P. 2015. "A Spatial Multi-Criteria Model for Determining Air Pollution at Sample Locations." *Journal of the Air & Waste Management Association*.
- Robaa, S. M. 2011. "Effect of Urbanization and Industrialization Processes on Outdoor Thermal Human Comfort in Egypt." *Atmospheric and Climate Sciences* 01 (03): 100–112. doi:10.4236/acs.2011.13012.

Rosenlund, M., Forastiere, F., Stafoggia, M., Porta, D. 2008. “Comparison of Regression Models with Land-Use and Emissions Data to Predict the Spatial Distribution of Traffic-Related Air Pollution in Rome.” *Journal of Exposure Science & Environmental Epidemiology* 18 (2): 192–99. doi:10.1038/sj.jes.7500571.

Singhe, A. L., Jamal, S. 2012. “Assessing Vulnerability of Women to Indoor Air Pollution.” *Research Journal Fo Environmental and Earth Sciences* 4 (11): 982–89.

Solomon, P. A., Costantini, M., Grahame, T. J., Gerlofs-Nijland, F. R. Cassee, A. G. 2011. *Air Pollution and Health: Bridging the Gap from Sources to Health Outcomes: Conference Summary. Air Quality, Atmosphere & Health*. Vol. 5. USA: Air quality atmospheric health. doi:10.1007/s11869-011-0161-4.

Su, J. G., Jerrett, M., Beckerman, B. 2009. “A Distance-Decay Variable Selection Strategy for Land Use Regression Modeling of Ambient Air Pollution Exposures.” *The Science of the Total Environment* 407 (12): 3890–98. doi:10.1016/j.scitotenv.2009.01.061.

Wai, T., Wai, W., San, T., Ignatius, T., Sun, Y. 2013. “Developing a Risk-Based Air Quality Health Index.” *Atmospheric Environment* 76. Elsevier Ltd: 52–58. doi:10.1016/j.atmosenv.2012.06.071.

Wang, R., Henderson, S. B., Hind, S., Allen, R. W., Brauer, M. 2013. “Temporal Stability of Land Use Regression Models for Traffic-Related Air Pollution.” *Atmospheric Environment* 64: 312–19.

Yerramilli, A., Venkata, B. R. D., Sudha, Y.. 2011. “Air Pollution, Modeling and GIS Based Decision Support Systems for Air Quality Risk Assessment.” In *Advance Air Pollution*, edited by Farhand Nejadkoorki, 1st ed., 295–324. Croatia.

Zou, B., Fen, P., Neng, W., Keita, M., Gaines, J. W. 2014. “Spatial Cluster Detection of Air Pollution Exposure Inequities across the United States.” *PloS One* 9 (3). doi:10.1371/journal.pone.0091917.

Recebido em abril de 2015.

Aceito em janeiro de 2016.