

ASSOCIAÇÃO ENTRE A POLUIÇÃO DO AR E A SAÚDE DA POPULAÇÃO BRASILEIRA: UMA ABORDAGEM ESPACIAL¹

Gabriel Ferreira²
Vinícius Halmenschlager³
Pedro Henrique Soares Leivas⁴
Gibran da Silva Teixeira⁵

Área 4: Economia Agrária e Ambiental

Resumo: A poluição do ar está associada a diversos efeitos negativos na saúde da população. Por isso, este trabalho tem como objetivo analisar as possíveis associações entre a poluição do ar com os índices de internações e mortalidades nos municípios do Brasil nos anos de 2005 até 2016 para quatro grupos de doenças: doenças respiratórias, doenças cardiovasculares, câncer de pulmão e condições neonatais. Para isso, foram utilizadas metodologia de dados em painel espacial, que permitem capturar possíveis efeitos de transbordamento entre os municípios vizinhos. Os resultados mostram que o tipo de doença que possui a maior associação com a poluição são as doenças respiratórias, nas internações e na mortalidade, e em menor escala, as doenças cardiovasculares e o câncer de pulmão. Além disso, as estimativas também mostraram que a poluição dos vizinhos tem uma influência sobre os índices de internação e mortalidade.

Palavras-chave: Econometria Espacial; Poluição do ar; Saúde Pública.

Abstract: Air pollution is associated with several negative effects on the health of the population. Therefore, this work aims to identify the possible associations between air pollution with hospitalizations and mortality in Brazilian municipalities from 2005 to 2016 for four groups of diseases: respiratory diseases, cardiovascular diseases, lung cancer and neonatal conditions. For this, spatial panel data models were used, which allow capturing possible spillover effects between neighboring municipalities. The results show that disease group most associated with air pollution are the respiratory diseases, in hospitalizations and mortality, and to a lesser extent, cardiovascular diseases and lung cancer. In addition, the estimates also showed that pollution from neighbors has influence on hospitalization and mortality rates.

Keywords: Spatial Econometrics; Air Pollution; Public Health.

Classificação JEL: Q53. I18. R11.

¹ Esta pesquisa contou com o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES).

² Mestrando do Programa de Pós-Graduação em Economia Aplicada da Universidade Federal do Rio Grande.

³ Professor da Universidade Federal do Rio Grande do Sul.

⁴ Professor da Universidade Federal do Rio Grande.

⁵ Professor da Universidade Federal do Rio Grande.

1 INTRODUÇÃO

A preocupação das instituições internacionais a respeito das mudanças climáticas teve como marco inicial a criação da Convenção-Quadro das Nações Unidas sobre Mudança do Clima (UNFCCC), com o início de suas atividades em 1994. A UNFCCC tem como objetivo facilitar as negociações intergovernamentais sobre mudanças climáticas, realizar análises das informações providas pelos países membros e manter o registro das Contribuições Nacionalmente Determinadas (NDC), estabelecidas pelo Acordo de Paris (UNFCCC, 2021). O Acordo de Paris entrou em vigor no dia 04 de novembro de 2016 e foi adotado por 196 países (incluindo o Brasil) e busca reduzir os efeitos do aquecimento global, limitando o aumento da temperatura média do planeta para níveis entre 1,5°C e 2°C comparado aos níveis pré-industriais (UNFCCC, 2015).

O Acordo de Paris é organizado em um ciclo de 5 anos onde cada país elabora sua NDC, com o objetivo de reduzir a emissão de gases do efeito estufa (GEE). A NDC brasileira prevê uma redução das emissões líquidas de 37% até 2025, e de 43% até 2030, comparadas aos valores de 2005 (UNFCCC, 2020). Além da NDC, o estado brasileiro elaborou a Política Nacional sobre Mudança do Clima (PNMC) em 2009, que busca reduzir as emissões de GEE entre 36,1% e 38,9% projetadas até 2020 (BRASIL, 2009).

Segundo dados da *Climate Watch* (2021), o país que mais emitiu GEE em 2018 foi a China, aproximadamente 11,7 bilhões de toneladas de CO₂e⁶ correspondendo a 24% das emissões do mundo, o Brasil foi o sétimo maior emissor com 1,4 bilhões de toneladas de CO₂e. Junto com a Índia, a China apresentou o maior crescimento de emissões no período entre 2000 e 2018, 123,38% e 175,45%, respectivamente. Entre os maiores emissores de gases do efeito estufa, apenas quatro países sofreram reduções nas suas emissões entre 2000 e 2018: Brasil, União Europeia⁷, Estados Unidos e Japão. A redução das emissões brasileiras fez com que o país deixasse de ser o terceiro maior emissor per capita em 2000, com 10,34 toneladas de CO₂e, para oitavo maior emissor em 2018, com 6,78 toneladas de CO₂e por habitante.

Entretanto, as emissões brasileiras tiveram um aumento de 28% no período de 2010 até 2016, passando de aproximadamente 1,7 bilhão de toneladas de CO₂e em 2010 para cerca de 2,1 bilhões de toneladas de CO₂e em 2016, segundo dados do Sistema de Estimativas de Emissões e Remoções de Gases de Efeito Estufa (SEEG). Devido ao aumento das emissões de GEE, o país segue um comportamento contrário ao cumprimento da NDC de 2025 (ALBUQUERQUE et al., 2020). O setor que mais emite poluentes é o de Mudanças do Uso da Terra é o setor que mais emite poluentes com aproximadamente 44,45% das emissões. Em seguida estão os setores de Agropecuária e Energia, com 26,83% e 20,13% das emissões, respectivamente. Por fim, o setor industrial (4,57%) e de resíduos (4,03%) possui pouca participação na poluição do ar no Brasil.

Riscos ambientais, como a poluição do ar, podem levar a um aumento no número de vários tipos de doenças, segundo relatório publicado pela OMS, elaborado por Prüss-Üstün et al. (2016), 22,7% das mortes que ocorreram no mundo em 2012 são atribuídas a riscos ambientais. Neste sentido, a poluição do ar aumenta o risco da população de desenvolver diversos tipos de doenças, como doenças respiratórias (GUAN et al., 2021; KARR et al., 2006; MEDINA-RAMÓN; ZANOBETTI; SCHWARTZ, 2006), cardiovasculares (POPE et al., 2004), câncer de pulmão (DOCKERY et al., 1993; HOEK et al., 2002; POPE et al., 1995, 2002) e condições neonatais (PEDERSEN et al., 2013; SEO et al., 2010).

O aumento da incidência de doenças causa diversos problemas à sociedade, afetando o bem-estar da população e aumentando o peso fiscal do sistema de saúde. Portanto, a principal

⁶ CO₂e é uma medida que converte as emissões de gases do efeito estufa (como CO₂, CH₄, NO₂ e outros HFCs) em termos de CO₂, considerando o impacto de cada gás no aquecimento global (WRIGHT; KEMP; WILLIAMS, 2011).

⁷ Contém 27 países: Áustria, Alemanha, Bélgica, Bulgária, Chipre, Croácia, Dinamarca, Eslováquia, Eslovênia, Espanha, Estônia, Finlândia, França, Grécia, Hungria, Irlanda, Itália, Letônia, Lituânia, Luxemburgo, Malta, Países Baixos, Polônia, Portugal, Romênia, Suécia e Tchêquia.

contribuição deste trabalho é estimar a associação entre a poluição do ar com os índices de saúde dos municípios brasileiros, controlando os efeitos espaciais e, também, identificar possíveis externalidades da poluição.

O objetivo deste trabalho é identificar uma possível associação entre a poluição do ar e os índices de internação e mortalidade dos municípios brasileiros entre os anos de 2005 e 2016 para quatro grupos de doenças (doenças respiratórias, doenças cardiovasculares, condições neonatais e câncer de pulmão), através da estimação de modelos econométricos espaciais. A utilização de econometria espacial permite controlar a presença de dependência espacial que pode surgir quando os dados se referem a unidades localizadas no espaço (LESAGE; PACE, 2009). Além disso, essa metodologia possibilita identificar possíveis externalidades que municípios altamente poluidores possam gerar na incidência de doenças nos municípios vizinhos.

Para estimar os modelos foram utilizados dados de diversas fontes. Os índices de internações e mortalidade foram obtidos do Ministério da Saúde do Brasil e os dados de emissão foram retirados do SEEG. Como variáveis de controle foram incluídas seis variáveis: número de médicos per capita, gastos com saúde per capita, índice IFDM nos critérios Emprego e Renda, Educação e Saúde e, por fim, densidade populacional.

As estimações realizadas mostram que existe uma correlação entre as emissões de GEE com as taxas de internações e óbitos. Entre os grupos de doenças, as doenças respiratórias, cardiovasculares e câncer de pulmão apresentaram uma associação positiva com as emissões de poluentes, na qual as doenças respiratórias possuem a maior correlação com a variável de emissões. Além disso, os resultados mostram que a poluição emitida por municípios vizinhos é relevante para os índices de internações e mortalidade.

Além desta introdução, este trabalho apresenta mais cinco seções, a primeira discute os efeitos da poluição do ar na saúde da população, indicando as doenças afetadas. Em seguida é apresentado os dados utilizados na pesquisa e é realizado uma análise exploratória espacial dos dados. A quarta seção apresenta a metodologia de econometria espacial e a estratégica empírica utilizada. A quinta seção apresenta os resultados das estimações a respeito dos efeitos da emissão de poluentes nas internações e nos óbitos. Por fim, é apresentada as considerações finais deste trabalho.

2 EFEITOS DA POLUIÇÃO DO AR NA SAÚDE

Esta seção apresenta trabalhos que analisaram os efeitos que a poluição do ar causa na saúde da população. Com o objetivo de identificar como as doenças são afetadas pelo meio ambiente, Prüss-Üstün et al. (2016) faz uma estimativa relacionando o efeito que o meio ambiente tem sobre a ocorrência de 133 doenças e lesões⁸. O relatório utiliza uma combinação de estimativas quantitativas do impacto do meio ambiente na ocorrência de doenças utilizando de uma combinação de métodos como: avaliação comparativa de risco (CRA), caminhos de transmissão, dados epidemiológicos e pesquisas de especialistas. De 133 doenças e lesões analisadas, 101 tiveram conexões com o meio ambiente e 92 doenças tiveram o impacto quantificado, pelo menos parcialmente e metade foram estimadas utilizando métodos CRA. Segundo os autores a poluição do ar afeta cinco grupos de doenças: doenças respiratórias, doenças cardiovasculares, condições neonatais, câncer de pulmão e derrame.

⁸ Os fatores ambientais incluído no estudo foram: Poluição do ar (incluindo consumo passivo de tabaco), agentes químicos ou biológicos presentes no solo e na água; radiação ultravioleta e ionizante; campos eletromagnéticos; barulhos excessivos; riscos relacionados ao trabalho (incluindo físico, químico, biológico e psicossocial); ambientes de construção (incluindo residências, ambientes de trabalho, uso da terra e rodovias); métodos utilizados na agricultura; mudanças no ecossistema causadas pelo homem; comportamentos relacionados a fatores ambientais (por exemplo: disponibilidade de água potável para lavar as mãos e atividade física promovida pela melhora da organização urbana).

Os fatores ambientais que aumentam os riscos de ocorrência de doenças do sistema respiratório são a poluição do ar ambiental e das residências, o consumo passivo de cigarro e riscos laborais. As infecções respiratórias inferiores (pneumonia, bronquite e bronquiolite), as infecções respiratórias superiores (faringite, laringite e sinusite) e as doenças pulmonares obstrutivas crônicas, são afetadas pela poluição do ar em 8, 24 e 9% das EVCIs, respectivamente. Em 2012, o câncer de pulmão causou quase 1,6 milhão de mortes, sendo o tipo de câncer que mais gerou mortes e a poluição do ar foi responsável por 14% das EVCIs causadas pela doença.

A poluição do ar no ambiente possui um impacto significativo nas EVCIs de doenças isquêmicas do coração, 24%, e derrame, 25%. O impacto dos fatores ambientais nas anomalias congênitas e nas condições neonatais, foi menor: 5 e 6%, respectivamente. Diversos fatores ambientais aumentam a incidências destas condições, como riscos laborais, produtos químicos, poluição do ar, consumo passivo de cigarro e condições inadequadas de saneamento. As anomalias congênitas incluem condições cromossômicas, como síndrome de Down e de Edward, e condições não cromossômicas, como defeitos congênitos dos órgãos enquanto que as condições neonatais incluem baixo peso de nascimento, prematuridade e morte do bebê.

Alguns trabalhos econométricos buscaram estimar os efeitos da poluição do ar nas internações hospitalares de doenças respiratórias. Janke (2014) utilizou um modelo de dados em painel para estimar a relação entre os níveis diários de dois gases, NO₂ e O₃, e internações causadas por dois tipos de doenças respiratórias, infecção respiratória aguda e asma, de crianças e adolescentes entre 5 e 19 anos da Inglaterra. O artigo também investiga possíveis vieses nas estimações, causados por uma possível mudança no comportamento da população em dias de maior nível de poluição. O governo do Reino Unido possui um sistema que faz a previsão de como vai ser o nível de poluição, com isso, é esperado que a população evite sair de casa em dias no qual o ar esteja mais poluído.

Os resultados encontrados pela autora indicam que aumento de 10% nos níveis de NO₂ ou O₃ resultam em um aumento de 1% nas internações de crianças e adolescentes para as duas doenças. Os avisos de poluição afetam apenas as internações por asma, com uma redução de 8% nas internações. Entretanto, apesar de possuir efeito direto sobre os resultados, a omissão dos avisos de poluição não gera subestimação dos efeitos da poluição do ar nas internações causadas pela asma. A autora conclui que o custo para evitar exposição de poluição pelos asmáticos é baixa, que pode responder a maiores níveis de poluição carregando seu inalador e ajustando a dose de seus remédios. O custo de prevenção de infecções respiratórias é maior, exigindo que as crianças e seus pais fiquem em ambientes fechados.

Com o objetivo de estimar os efeitos da qualidade do ar nos gastos com doenças respiratórias em Taiwan, Liu e Ao (2021) utilizaram um modelo de mínimos quadrados de dois estágios utilizando como instrumento da qualidade do ar a ocorrência de inversões térmicas. A inversão térmica é um fenômeno no qual uma camada de ar mais quente se assenta entre duas camadas de ar frio e, conseqüentemente, impede que a poluição se dissipe, aumentando a concentração de poluentes no ar. Os resultados mostraram que a redução de uma unidade do índice de qualidade do ar (AQI⁹) reduz a despesa com atendimento ambulatorial de doenças respiratórias por paciente diariamente em aproximadamente NT\$ 0,39, esta redução anualmente é de NT\$ 2,3 bilhões (aproximadamente US\$ 74 milhões), o número de atendimentos ambulatorial encontrado gerado pela qualidade do ar são de 12 milhões de visitas por ano.

Utilizando econometria espacial, Feng et al. (2019) encontraram externalidades negativas da poluição do ar na saúde pública da China, onde a concentração de poluentes no ar (PM_{2,5}, PM₁₀ e SO₂) aumenta de forma significativa o número de pessoas que recebem tratamentos em hospitais, o número de exames médicos em hospitais e o número de internações. A influência

⁹ O AQI é determinado pela combinação dos cinco materiais mais poluentes: material particulado (incluindo PM₁₀ e PM_{2,5}), ozônio, dióxido de enxofre, monóxido de carbono e dióxido de nitrogênio (CHENG et al., 2007).

da poluição na saúde foi mais significativa nas regiões central e oriental da China, onde estas regiões possuem um número maior de indústrias e são mais desenvolvidas economicamente.

Os principais trabalhos brasileiros se concentram em analisar o impacto da poluição na saúde de diferentes municípios brasileiros individualmente. Dapper, Spohr e Zanini (2016) identificaram diversos trabalhos que encontram uma associação entre poluição e a saúde da população nos municípios do estado de São Paulo. Além disso, diversos estudos utilizaram modelos de séries de tempo que uma correlação positiva entre os níveis de poluição e os índices de saúde nos seguintes municípios: Belo Horizonte (GOUVEIA et al., 2019); Cubatão (NARDOCCI et al., 2013); Rio de Janeiro e São Paulo (GOUVEIA et al., 2003) e Vitória (FREITAS et al., 2016). Ao contrário da grande parte dos estudos realizados no Brasil, este trabalho realiza uma pesquisa de abrangência nacional com dados de 5.546 municípios brasileiros, adotando uma estratégia pouco utilizada na literatura nacional sobre o tema.

3 DADOS

As variáveis dependentes utilizadas neste trabalho são as internações e óbitos, nos anos de 2005 a 2016, causadas por quatro grupos de doenças: doenças respiratórias, doenças cardiovasculares, câncer de pulmão e condições neonatais, além disso foi incluída a soma dos quatro grupos. Os dados de internações e óbitos foram retirados da plataforma DATASUS do Ministério da Saúde do Brasil.

O Apêndice A apresenta as doenças presentes em cada grupo, assim como suas classificações na décima versão do Cadastro Internacional de Doenças (CID). A seleção das doenças para a estimação foi baseada em evidências presentes na literatura, como a compilação feita por Prüss-Üstün et al. (2016), publicada pela OMS.

A variável independente de interesse são as emissões de CO₂e de 5.564 municípios brasileiros nos anos de 2005 até 2016. Esta variável é composta pelo valor agregado de quatro setores poluidores (Agropecuária, Energia, Indústria e Mudanças do Uso da Terra¹⁰) e foram obtidas através das estimativas feitas pelo SEEG¹¹.

Como variáveis de controle foram selecionadas características dos municípios que possuem alguma influência nos índices de internação e mortalidade. Como indicadores do sistema de saúde dos municípios foram utilizadas duas variáveis: o número de médicos per capita e os gastos com saúde per capita. O número de médicos atuantes foi obtido através da Relação Anual de Informações Sociais (RAIS) do Ministério do Trabalho e Previdência e os gastos com saúde foram obtidos da Secretaria do Tesouro Nacional do Ministério da Economia. Como indicadores socioeconômicos foi utilizado o Índice FIRJAN de Desenvolvimento Municipal (IFDM), este índice monitora a situação socioeconômica dos municípios brasileiros a partir de três áreas: Emprego e Renda, Educação e Saúde. O indicador varia entre 0 e 1, e quanto mais próximo de 1, maior é o desenvolvimento socioeconômico do município (FIRJAN, 2018). Por fim, foi incluída a densidade populacional, retirados do Instituto Brasileiro de Geografia e Estatística (IBGE).

As estatísticas descritivas das variáveis utilizadas neste trabalho estão presentes na Tabela 1. As estatísticas mostram que os municípios apresentam nos anos de 2005 a 2016 uma média de 7,96 internações a cada 1000 habitantes causadas por doenças respiratórias e

¹⁰ O setor de Resíduos foi excluído da amostra por apresentarem valores negativos em algumas observações.

¹¹ O SEEG é uma iniciativa do Observatório do Clima que realiza estimativas anuais das emissões de gases de efeito estufa do Brasil. As estimativas são obtidas a partir do Inventário Brasileiro de Emissões e Remoções Antrópicas de Gases do Efeito Estufa, elaborado pelo Ministério da Ciência, Tecnologia e Inovação e de informações obtidas em relatórios governamentais, institutos, centro de pesquisas, entidades setoriais e organizações não governamentais (SEEG, 2021). A estimação das emissões municipais passou a ser incluída na oitava coleção do relatório e abrange o período de 2000 até 2018.

uma mortalidade média de 0,27 óbitos por 1000 habitantes, sendo o grupo de doença com maior média de internações e óbitos no período. Em seguida estão as doenças cardiovasculares com uma média de 2,03 internações por 1000 habitantes e 0,20 óbitos. Em relação as emissões de poluentes, a média total foi de aproximadamente 304 mil tCO₂eq e o valor máximo foi de 67,2 milhões de tCO₂eq.

Tabela 1 – Estatísticas Descritivas

Variável	Média	Erro Padrão	Mínimo	Máximo
Internações – Câncer	0,0824922	0,180691	0	3,6323
Internações – Cardiovascular	2,0349	1,5446	0	22,74583
Internações - Neonatais	0,5873	0,4273	0	8,4657
Internações - Respiratórias	7,9609	7,1813	0	121,2834
Internações – Agregado	10,6657	7,7675	0	122,6738
Óbitos – Câncer	0,01824	0,0579	0	1,2165
Óbitos – Cardiovascular	0,2014	0,2078	0	2,7435
Óbitos - Neonatais	0,02862	0,0629	0	1,4706
Óbitos - Respiratórias	0,2707	0,2949	0	3,6496
Óbitos – Agregado	0,5190	0,4210	0	4,8662
Emissões Totais	304650,60	1126257	350,4322	6,72e07
Nº de Médicos	1,9256	1,7604	0	74,2857
Gastos em Saúde	492,1333	601,438	0	36935,85
IFDM - Educação	0,6828	0,1481	0,1327	1
IFDM – Emprego e Renda	0,5239	0,1345	0,1019	0,95234
IFDM – Saúde	0,6827	0,1736	0,0334	1
Densidade Populacional	111,0422	587,4095	0,0768	13595,4

Fonte: Elaboração própria.

Em média, cada município possui um gasto em saúde per capita de aproximadamente R\$ 492,33 e 1,93 médicos por habitante. Os índices de desenvolvimento IFDM possuem um valor médio de 0,68 no critério Educação, 0,52 em Emprego e Renda, e 0,68 no índice de Saúde. A densidade populacional média no período foi de 111,04 habitantes por km².

3.1 ANÁLISE EXPLORATÓRIA ESPACIAL DOS DADOS

Como os dados utilizados pertencem a unidades localizadas no espaço, é necessário verificar se as observações possuem algum tipo de efeito espacial entre si. Segundo Anselin (1996) existem dois tipos de efeitos espaciais: a dependência espacial e a heterogeneidade espacial. A dependência espacial ocorre quando as observações estão espacialmente agrupadas, ou seja, os dados geográficos não são independentes, gerando um conflito com o pressuposto estatístico de que as observações são independentes entre si. O segundo efeito espacial está relacionado a diferenciação regional dos efeitos espaciais, provenientes das especificidades de cada local.

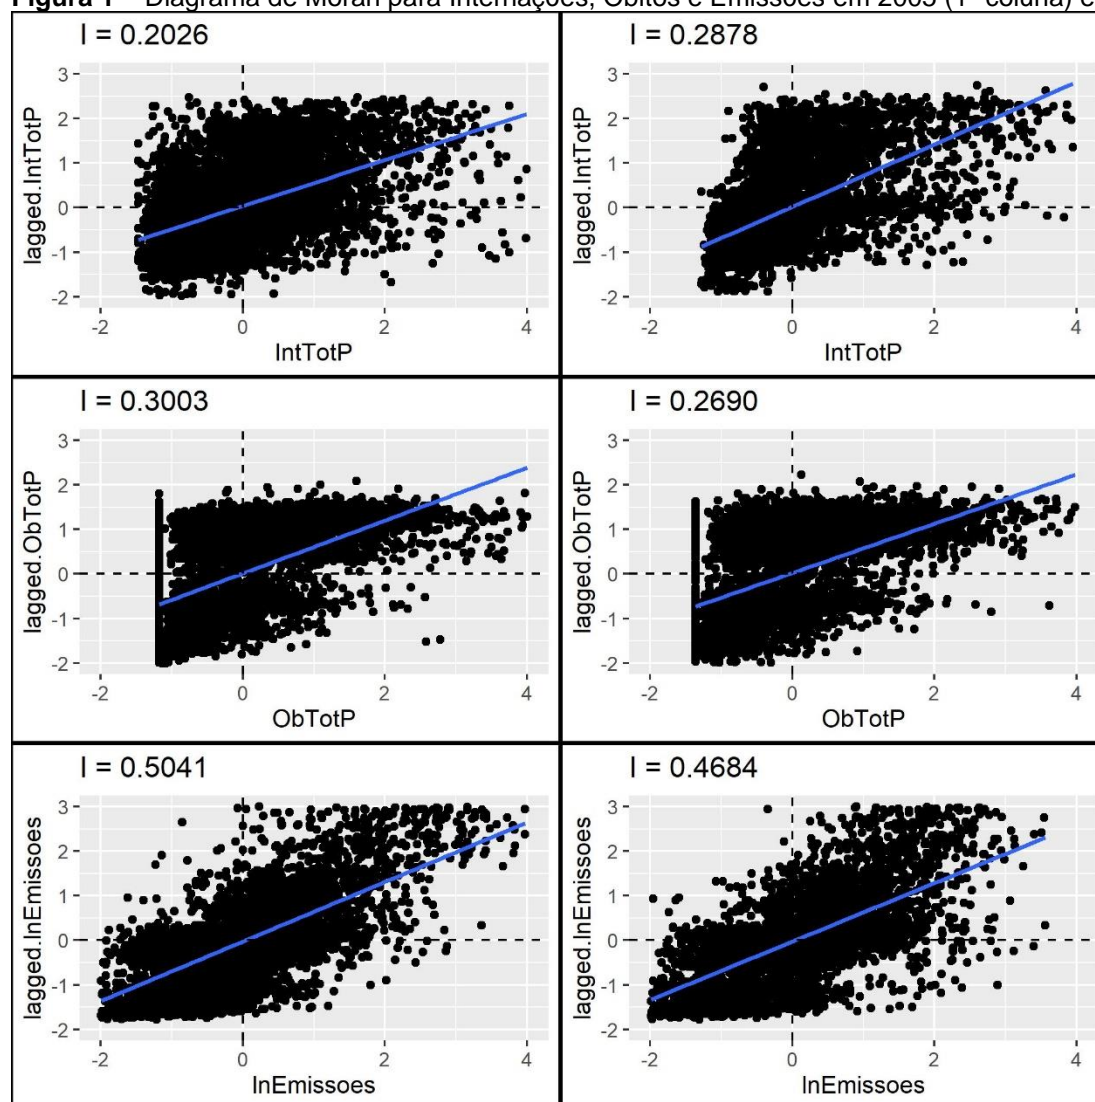
A forma mais comum de medir associação espacial entre as observações é através da estimação de uma matriz de pesos espaciais W . Segundo LeSage e Pace (2009), a matriz de pesos espaciais possui dimensão n por n e indica a associação entre as observações no espaço. Existem diversos métodos para a estimação da matriz de pesos espaciais, entre eles a matriz de contiguidade e a matriz de distância inversa. A matriz de contiguidade assume que caso uma região i for vizinha de primeira ordem da região j o valor de $W_{i,j} = 1$, e se i não for vizinha de primeira ordem de j : $W_{i,j} = 0$. A matriz de distância inversa é composta pela distância inversa entre as unidades, ou seja, quanto mais perto a região i é da região j , maior será o peso atribuído ao termo $W_{i,j}$ (DRUKKER et al., 2013). Por definição, os elementos da diagonal principal de W são nulos. A matriz de pesos espaciais pode ser normalizada através da soma das linhas de cada observação e divididas pelo número vizinhos (LESAGE, 2008). Este trabalho utiliza a matriz de distância inversa, pois como a poluição por CO₂eq se propaga pelo ar (LAI; BRIMBLECOMBE,

2021), a distância entre os municípios se torna um fator mais determinante nos efeitos de transbordamento do que o fato destes municípios serem vizinhos. Além disso, a matriz de contiguidade considera como vizinhos apenas aqueles que possuem limites terrestres, excluindo ilhas da estimação, o que não ocorre na matriz de distância inversa.

Uma forma de identificar uma possível dependência espacial entre as observações é o teste de autocorrelação espacial global através da estatística I de Moran global. O I de Moran global indica a associação linear entre um vetor dos valores observados y e uma média ponderada dos valores dos vizinhos Wy , também conhecido como lag espacial (ANSELIN, 1996).

A hipótese nula do teste indica a presença de dependência espacial nas variáveis. Para identificar uma possível dependência espacial foi realizado o teste I de Moran para as variáveis dependentes e a variável independente de interesse $lnEmissoes$ em todos períodos da amostra (Apêndice B). A hipótese nula de presença de dependência espacial não foi rejeitada em todas as variáveis para todos os períodos.

Figura 1 – Diagrama de Moran para Internações, Óbitos e Emissões em 2005 (1ª coluna) e 2016 (2ª coluna).



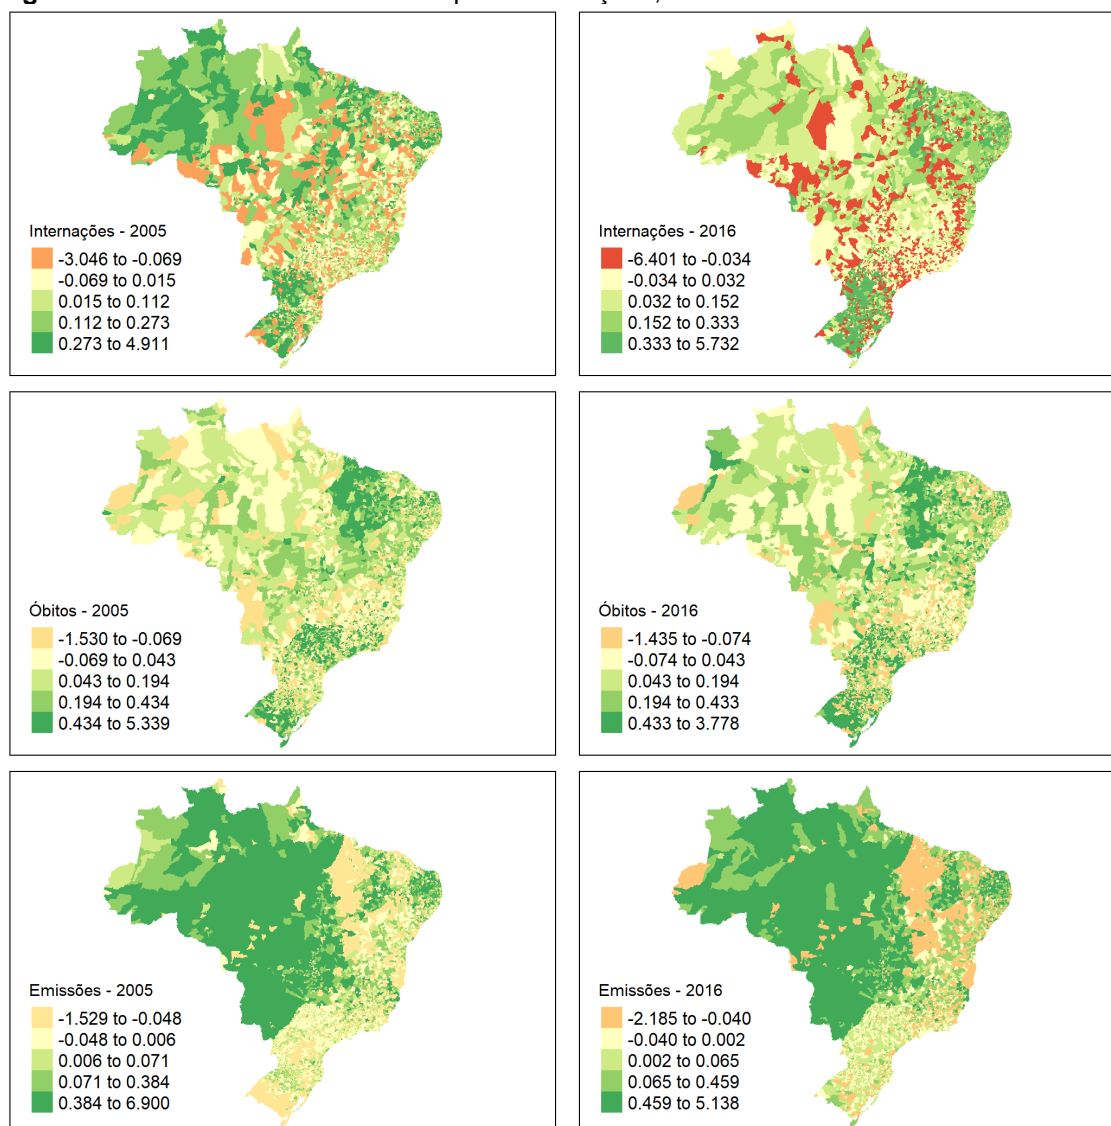
Fonte: Elaboração própria.

Uma forma de visualizar a relação linear de uma y com Wy é através do diagrama de dispersão de Moran, desenvolvido por Anselin (1996). Como y é medido em desvios da média, I é equivalente ao coeficiente da regressão de Wy em y . O diagrama pode ser melhorado com a inclusão de uma regressão linear com a inclinação igual a I . A Figura 1 apresenta os diagramas de dispersão de Moran para os valores agregados de internação e óbitos e para a variável

independente de interesse. Por limitação de espaço serão apresentados o primeiro (2005) e o último (2016) período da amostra.

Os quatro quadrantes do diagrama representam tipos diferentes de relações entre o valor de y e o valor de W_y . O primeiro e o terceiro quadrantes do plano cartesiano indicam uma relação positiva entre o valor de uma dada localidade com os valores de seus vizinhos, ou seja, quando o valor de y for elevado na localidade, o valor de W_y é elevado (relação alto-alto) e quando o valor de y for baixo, o valor de seus vizinhos também é baixo (relação baixo-baixo). O segundo e quarto quadrantes indicam relações negativas: valores baixos estão cercados de valores altos no segundo quadrante e valores altos estão cercados por valores baixos no quarto quadrante. A densidade relativa de cada quadrante indica qual tipo de relação espacial, positiva ou negativa, é predominante. Para todas as variáveis analisadas a relação espacial predominante é a positiva, ou seja, municípios com altos (baixos) índices de internações, óbitos e emissões de poluentes estão cercados por municípios com altos (baixos) índices de internações, óbitos e poluição.

Figura 2 – Estatística do Moran Local para Internações, Óbitos e Emissões – 2005 e 2016.



Fonte: Elaboração própria.

A presença de variáveis onde as observações possuem uma relação positiva com seus vizinhos pode indicar a presença de *clusters* e *outliers* espaciais. Uma forma de identificar essa relação entre as observações é através da estatística local de Moran sugerida por Anselin (1995). A soma das estatísticas locais do Moran resulta na obtenção do I de Moran global.

A partir da obtenção dos I de Moran local é possível identificar a presença de possíveis *clusters* nas variáveis de interesse. A Figura 2 apresenta as estatísticas do Moran local dos municípios brasileiros nos anos de 2005 e 2016 das internações totais, dos óbitos totais e das emissões de poluentes. Os valores positivos indicam que o município possui valores semelhantes com seus vizinhos (relação alto-alto e baixo-baixo), os valores negativos indicam que dado município possui valores opostos à de seus vizinhos (relação alto-baixo e baixo-alto) e valores próximos de zero indicam a ausência de relação espacial.

Para as três variáveis foi encontrada a presença de correlação espacial entre as observações, com destaque para a variável de emissão de poluentes na qual as regiões Norte e Centro-Oeste possuem a maior parte de seus municípios cercados por vizinhos com níveis de poluição semelhantes. As internações apresentaram estatísticas altas em 2005, mas em 2016 as estatísticas do Moran foram menores. Por fim, os óbitos apresentaram valores próximos de zero em algumas regiões do país, principalmente na região Norte. Com as evidências obtidas a partir dos testes de autocorrelação espacial global e autocorrelação espacial global, pode-se concluir que estes dados possuem dependência espacial, portanto deve-se utilizar modelos econométricos que incluem a dependência espacial em sua especificação (FENG et al., 2019; WANG; YANG, 2019).

4 ESTRATÉGIA EMPÍRICA

Para obter os efeitos da poluição do ar sobre as taxas de internações e óbitos nos municípios brasileiros foram estimadas regressões onde as variáveis dependentes do modelo serão as internações e os óbitos de cada um dos grupos de doenças selecionados (doenças respiratórias, cardiovasculares, câncer de pulmão e condições neonatais), além de uma variável com a soma de todas as doenças. As estimações apresentam seguinte forma funcional:

$$y_{it} = \beta_1 \log Em_{it} + \beta_k X_{it} + \varepsilon_{it} \quad (1)$$

onde y_{it} são as variáveis dependentes de internações e óbitos causados por cada grupo de doença no município i e no ano t . A variável $\log Em_{it}$ é o logaritmo natural das emissões do município i no ano t . X_{it} é uma matriz com as variáveis de controle: número de médicos per capita, gastos com saúde per capita, índices IFDM nos critérios Educação, Emprego e Renda e Saúde e densidades populacionais. Por fim, ε_{it} é o termo de erro da regressão.

A metodologia utilizada neste trabalho será a da estimação de dados em painel espacial, esta metodologia permite controlar a dependência espacial entre as observações, que são comuns com observações coletadas de pontos ou regiões localizadas no espaço. Os métodos de regressões convencionais de análise *cross-section* e de painel assumem que os membros da amostra são independentes entre si, entretanto este pressuposto é difícil de ser assumido para observações localizados no espaço (LESAGE, 2008). Por exemplo, a poluição emitida pelo município i possivelmente afeta a população do município j , podendo causar efeitos na saúde da população deste município, ocorrendo um efeito de transbordamento entre as observações.

Seguindo a estratégia empírica apresentada por Elhorst (2012a), inicialmente é estimado um modelo de Durbin Espacial (SDM) e, em seguida, é realizado uma comparação entre o SDM com duas outras especificações: o modelo espacial autorregressivo (SAR) e o modelo de erro espacial (SEM). O modelo SDM inclui um *lag* espacial da variável dependente e das variáveis independentes, apresentando a seguinte forma funcional:

$$y_{it} = \rho W y_{it} + \beta_k X_{it} + \theta W X_{it} + \varepsilon_{it} \quad (2)$$

onde y_{it} é a variável dependente do modelo e X_{it} é um vetor de variáveis independentes. A expressão $\rho W y_{it}$ indica o impacto que a variável dependente dos vizinhos possui sobre a variável

dependente de um dado município, o coeficiente ρ é um escalar que indica o tamanho da influência as observações vizinhas possuem sobre a variável dependente e W é a matriz de pesos espaciais. A expressão θWX_{it} , por sua vez, indica o impacto das variáveis independentes de observações vizinhas possuem na variável dependente de um dado município. O termo de erro ε apresenta média zero e variância constante σ^2 .

O modelo SAR é um modelo simplificado do SDM e apenas incorpora um *lag* espacial entre as variáveis dependentes do modelo. Por fim, o modelo SEM apresenta a dependência espacial no termo de erro e ao contrário dos modelos SAR e SDM não apresenta a variável explicada como uma resposta direta da relação espacial (CARVALHO; ALBUQUERQUE, 2010).

Segundo LeSage e Pace (LESAGE; PACE, 2009), uma vantagem na utilização de modelos SDM, em comparação com os modelos SAR e SEM, é que esta especificação não produz viés de variável omitida caso as variáveis independentes possuam dependência espacial. Em casos onde o processo gerador dos dados seja um modelo SAR, o modelo de erros espaciais será enviesado devido à ausência da variável dependente defasada espacialmente, no caso do modelo de Durbin espacial a estimação não apresentará estimadores enviesados e dispersão dos valores dos coeficientes estarão corretos. E, se o modelo correto for um SEM os modelos SAR e SDM produzirão coeficientes não enviesados, mas a estimação será ineficiente.

Cabe salientar que a interpretação direta dos coeficientes das variáveis independentes defasadas espacialmente como efeitos de transbordamento é incorreta, a identificação deve-se obtida ao calcular os efeitos diretos e indiretos (LESAGE; PACE, 2009). Os efeitos diretos e indiretos são obtidos através da matriz das derivadas parciais do valor esperado de y em relação a todas as variáveis explicativas do modelo, onde os elementos da diagonal principal indicam os efeitos diretos e os elementos restantes indicam os efeitos indiretos. E, caso uma das variáveis explicativas alterar de valor (efeito direto), não apenas a variável dependente em uma unidade em particular mudará, mas as variáveis dependentes em outras unidades também terão seu valor alterado (efeito indireto) (ELHORST, 2014).

A estratégia empírica para definição da melhor especificação foi baseada na estratégia descrito por Elhorst (2012), utilizada em diversos trabalhos empíricos sobre poluição¹². Inicialmente serão feitas estimações sem considerar a dependência espacial, com a seleção do melhor modelo através do teste de Hausman. Em seguida, se as variáveis apresentarem dependência espacial nos testes de autocorrelação global e local, serão estimados os modelos espaciais na qual a escolha entre o modelo de efeitos fixos espacial ou modelo de efeitos aleatórios espacial é definida a partir do resultado do teste de Hausman feita no modelo que não considera a dependência espacial (WANG; YANG, 2019).

A seleção do melhor modelo espacial é feita a partir da comparação de um modelo SDM com estimações alternativas. Serão realizados dois testes de hipótese para definir se o SDM é melhor ajustado que os modelos SAR e SEM. A primeira hipótese é se $\theta = 0$ (equação 2), que examina se as variáveis independentes defasadas espacialmente são conjuntamente iguais a zero, se esta hipótese for rejeitada o modelo SDM é melhor ajustado que o SAR. A segunda hipótese é se $\theta + \beta\rho = 0$ (equação 2), caso a hipótese seja rejeitada o modelo espacial de Durbin é preferível ao modelo de erro espacial.

5 RESULTADOS

Esta seção apresenta os resultados deste trabalho. A primeira estimação realizada foi a de painel sem considerar a presença de dependência espacial para cada variável dependente (internações e óbitos para cada grupo de doenças e internações e óbitos para soma dos quatro grupos), a tabela 2 apresenta os resultados. As variáveis independentes incluídas nos modelos

¹² Ver Burnett, Bergstrom e Dorfman (2013); Dorfman et al. (2019); Kang, Zhao e Yang (2016); Wang e Yang (2019); Zhou, Ye e Ge (2017)

são a variável de interesse *InEmissoes* e seis variáveis de controle: números de médicos per capita, gastos com saúde per capita, índice IFDM nas categorias Educação, Saúde, Emprego e Renda e Saúde e, por fim, a Densidade Populacional.

Tabela 2 – Resultados de *InEmissoes* em cada variável dependente ignorando efeitos espaciais.

Variável Dependente	FE	RE	Hausman
Int. Respiratórias	0,113** (0,0552)	0,222*** (0,0416)	222,69***
Int. Cardiovasculares	0,0573*** (0,0129)	-0,0264*** (0,00847)	1843,59***
Int. Câncer	0,00396* (0,00238)	-0,00321*** (0,000853)	445,27***
Int. Neonatais	0,0150*** (0,00534)	-0,0162*** (0,00224)	1710,37***
Int. Totais	0,190*** (0,05587)	0,218*** (0,0446)	383,69***
Ob. Respiratórias	0,0141*** (0,00330)	-0,00393*** (0,00149)	1472,67***
Ob. Cardiovascular	0,00358 (0,00265)	-0,00839*** (0,00104)	310,87***
Ob. Câncer	0,00219*** (0,000822)	-4,94e-05 (0,000228)	185,64***
Ob. Neonatais	0,00123 (0,000915)	-0,00110*** (0,000233)	128,22***
Ob. Totais	0,0211*** (0,00450)	-0,0106*** (0,00220)	1405,09***
Observações	66.768	66.768	-
Variáveis de Controle	Sim	Sim	-
Efeito Fixo de Ano	Sim	Sim	-

Obs: Erros-padrão em parênteses. *** 1% de significância; ** 5% de significância; * 10% de significância.

Fonte: Elaboração própria.

A escolha entre o melhor modelo entre o de efeitos fixos e efeitos aleatórios é feita através do teste de Hausman, em todas as especificações o modelo indicado pelo teste foi o de efeitos fixos. Os resultados dos painéis de efeito fixo para as internações mostram que existe uma correlação positiva entre a emissão de poluentes e as internações em todos os grupos de doenças, com destaque para as doenças respiratórias onde um aumento de 1% das emissões está associado a um aumento de 0,0011 casos por mil habitantes, seguido por doenças cardiovasculares, condições neonatais e câncer de pulmão: crescimento de 0,000573, 0,000015 e 0,0000396 nas internações a cada mil habitantes, respectivamente. Em termos agregados, um aumento de 10% da poluição do ar está correlacionado a um crescimento de 0,0019 das internações a cada mil habitantes.

O aumento da poluição apresentou correlação positiva com o número de óbitos em dois grupos de doenças: doenças respiratórias e câncer de pulmão, aumento de 0,00014 e 0,000022 dos óbitos por mil habitantes, respectivamente. Enquanto que um aumento de 1% das emissões de poluentes está associado a um crescimento de 0,00021 óbitos por mil habitantes quando se utiliza a soma dos quatro grupos de doenças.

Como as variáveis apresentaram dependência espacial no teste de autocorrelação espacial global e no teste de autocorrelação local, a estimação de modelo sem um componente espacial é enviesada, logo deve-se estimar um modelo espacial. Como o teste de Hausman indicou o modelo de efeitos fixos, todos os modelos espaciais estimados serão de efeitos fixos (WANG; YANG, 2019). Seguindo a estratégia de Elhorst (2012), o primeiro modelo a ser estimado é o SDM, a tabela 3 apresenta os resultados da estimação por máxima verossimilhança.

A seleção do melhor modelo espacial entre o SDM, SAR e SEM é feita através de dois testes de hipótese (Tabela 4). O primeiro, $\theta = 0$, na qual a hipótese nula testa se o SDM é melhor ajustado que o SAR e o segundo, $\theta + \beta\rho = 0$, onde a hipótese nula verifica se o SDM é preferível

ao SEM. As duas hipóteses nula foram rejeitadas em todos os modelos, logo o modelo mais ajustado para todas as especificações é o SDM.

Tabela 3 – Resultados de *InEmissoes* em cada variável dependente ignorando efeitos espaciais.

Variável Dependente	InEmissoes	Wd*InEmissoes	$\theta = 0$	$\theta + \beta\rho = 0$
Int. Respiratórias	0,1249* (0,05897)	-3,3572*** (0,65108)	227,05***	138,05***
Int. Cardiovasculares	0,0353** (0,01383)	-0,5106*** (0,15294)	278,21***	227,50***
Int. Câncer	-0,0016 (0,00260)	0,0577** (0,02880)	23,76***	23,44***
Int. Neonatais	0,0097* (0,00579)	-0,0790 (0,06389)	39,78***	33,91***
Int. Totais	0,1788*** (0,06270)	-4,39011*** (0,69260)	337,86***	154,27***
Ob. Respiratórias	0,0041 (0,00360)	0,1087*** (0,03970)	105,75***	116,06***
Ob. Cardiovascular	0,0033 (0,00290)	0,0458 (0,03193)	53,76***	63,45***
Ob. Câncer	0,0007 (0,00090)	0,0175* (0,00999)	66,94***	66,83***
Ob. Neonatais	0,0007 (0,00100)	0,0126 (0,01106)	29,92***	24,22***
Ob. Totais	0,0089* (0,00491)	0,1772*** (0,05423)	66,57***	78,20***
Observações	66.768	66.768	-	-
Variáveis de Controle	Sim	-	-	-
Efeito Fixo de Ano	Sim	-	-	-

Obs: Erros-padrão em parênteses. *** 1% de significância; ** 5% de significância; * 10% de significância.
Fonte: Elaboração própria.

Para obter os efeitos da poluição de vizinhos nos municípios é calculado os efeitos diretos, indiretos e total da variável *InEmissoes* (Tabela 4). Os resultados indicam que um aumento de 1% nas emissões de poluentes é associado com um aumento total de 0,015 internações por mil habitantes na soma de todas as doenças, a maior parte do efeito total é composta pelo efeito indireto, 0,013, ou seja, a poluição emitida pelos vizinhos tem um efeito maior nas internações do que a poluição produzida pelo próprio município. O efeito da poluição é ainda maior nos óbitos, com efeito total de 0,0285 e um efeito indireto de 0,0284.

Entre os grupos de doenças, apenas as doenças respiratórias e cardiovasculares tiveram efeitos significativos para a variável de poluição no qual as doenças respiratórias apresentaram maior sensibilidade a poluição com um efeito total nas internações a cada mil habitantes de 0,015, um efeito direto de 0,0013 e um efeito indireto de 0,0102 após um aumento de 1% nas emissões de poluentes. Assim como nos valores agregados o efeito nos óbitos por mil habitantes causados por doenças respiratórias foi maior, efeito total de 0,0162 e efeito indireto de 0,0161 devido a um aumento de 1% nas emissões.

Ao comparar os coeficientes dos modelos que ignoram o efeito espacial com os resultados obtidos pelos modelos espaciais, percebe-se que a primeira especificação subestima a correlação entre as emissões de poluentes e os índices de internação e óbitos. Por exemplo, os resultados das variáveis agregadas de internações e óbitos no modelo em painel convencional encontram uma correlação positiva de 0,0019 para as internações e de 0,00021 de óbitos com um aumento de 1% nas emissões. Por outro lado, no modelo espacial a correlação total associada a um aumento de 1% nas emissões foi de 0,0149 e 0,0285 para as internações e óbitos, respectivamente. Esta diferença acontece devido a importância que a poluição emitida pelos municípios vizinhos possui sobre os indicadores de saúde de dado município.

Tabela 4 – Efeitos Diretos e Indiretos de *InEmissoes* em cada variável dependente.

Variável Dependente	Efeito Direto	Efeito Indireto	Efeito Total
Int. Respiratórias	0,1272** (0,05902)	1,020*** (0,21109)	1,1474*** (0,22322)
Int. Cardiovasculares	0,0347** (0,01381)	0,1610*** (0,05800)	0,1957*** (0,06078)
Int. Câncer	-0,0016 (0,00260)	-0,2016* (0,10952)	-0,2032* (0,11027)
Int. Neonatais	0,0095* (0,00575)	0,0604 (0,06079)	0,0699 (0,06226)
Int. Totais	0,1821*** (0,06277)	1,314*** (0,22454)	1,4958*** (0,23746)
Ob. Respiratórias	0,0045 (0,00356)	1,6146** (0,70593)	1,6191** (0,70517)
Ob. Cardiovascular	0,0034 (0,00287)	0,6536 (0,45541)	0,6570 (0,45464)
Ob. Câncer	0,0007 (0,00090)	0,0319* (0,01776)	0,0326* (0,01746)
Ob. Neonatais	0,0007 (0,00010)	0,0433 (0,03699)	0,0440 (0,03667)
Ob. Totais	0,0095* (0,00486)	2,8432** (1,13269)	2,8526** (1,31180)

Obs: Erros-padrão em parênteses. *** 1% de significância; ** 5% de significância; * 10% de significância.

Fonte: Elaboração própria

O fato de os efeitos indiretos de *InEmissoes* serem maiores que os efeitos diretos acontece porque o efeito indireto é a soma do efeito que a variável independente de todas as unidades vizinhas geram na variável dependente de uma unidade (LESAGE; PACE, 2009). O efeito direto é apenas o impacto da variável independente desta unidade na variável dependente da mesma unidade e, por isso, os efeitos na variável explicada gerados pelas variáveis explicativas dos vizinhos podem ser maiores que os efeitos gerados pelas variáveis explicativas da própria região.

A presença de efeitos da poluição do ar nos casos de doenças respiratórias vão de encontro a outros trabalhos (HALES; BLAKELY; WOODWARD, 2012; JANKE, 2014; LIU; AO, 2021; ZANOBETTI; SCHWARTZ, 2009). Em menor escala, foram encontrados efeitos da poluição nas internações por doenças cardiovasculares e nos óbitos por câncer de pulmão, assim como em evidências encontradas por diversos trabalhos como Pope et al. (2004) e Toren et al. (2007) para as doenças cardiovasculares e por Dockery et al. (1993) e Hoek et al. (2002) para o câncer de pulmão.

6 CONSIDERAÇÕES FINAIS

O objetivo deste trabalho é estimar a associação entre poluição do ar com os índices de internações e óbitos para quatro grupos de doenças, doenças respiratórias, doenças cardiovasculares, câncer de pulmão e condições neonatais, no Brasil no período entre 2005 e 2016. Para isso foi estimado um modelo de painel espacial que possibilitou identificar o quanto que a poluição emitida por municípios vizinhos está associada com as internações e óbitos de dado município.

A categoria de doença que possui a maior associação pela emissão de poluentes são as doenças respiratórias, com valores significativos para as internações e para os óbitos. Em relação aos outros grupos de doenças, as internações por doenças cardiovasculares e os óbitos causados por câncer de pulmão também apresentaram significância estatística. Apenas as condições neonatais não apresentaram nenhuma significância para as internações e os óbitos. Além disso, um importante resultado obtido foi a de que a soma da emissão de poluentes proveniente de municípios vizinhos possui um impacto maior nas internações e óbitos do que a

poluição do próprio município. Por isso, a redução da poluição só será efetiva na redução dos índices de saúde se acontecerem em conjunto entre os municípios.

A principal contribuição deste trabalho foi mostrar que além dos danos no meio ambiente, a poluição afeta negativamente diversos setores, como o setor de saúde, gerando aumentos nos índices de internação e mortalidade. O cumprimento das políticas de redução das emissões de poluentes, como as do Acordo de Paris, além de contribuir na preservação do meio ambiente, geram externalidades positivas para a saúde da população ao diminuir a ocorrência de doenças, especialmente doenças respiratórias.

O Brasil, no entanto, segue um caminho oposto ao da redução da poluição, na década de 2010 os índices de poluição aumentaram em 23%, com o aumento do setor de Mudança do Uso da Terra sendo o principal causador. Por isso, a principal forma de diminuir a emissão de GEE no país é o combate da poluição gerada por este setor, onde a causa é desmatamento da região Amazônica.

A principal limitação deste trabalho é a utilização de apenas variáveis relacionadas a hospitalização e mortalidade. A utilização de variáveis de atendimentos ambulatoriais e de uso de medicamentos podem encontrar resultados ainda mais significativos.

REFERÊNCIAS

- ALBUQUERQUE, I. et al. **Análise das Emissões brasileiras de gases de efeito estufa e suas implicações para as metas de clima do Brasil 1970-2019**. [s.l.] Sistema de Estimativas de Emissões e Remoções de Gases de Efeito Estufa (SEEG), 2020. Disponível em: <<http://seeg.eco.br/documentos-analiticos>>. Acesso em: 31 maio. 2021.
- ANALITIS, A. et al. Short-Term Effects of Ambient Particles on Cardiovascular and Respiratory Mortality: **Epidemiology**, v. 17, n. 2, p. 230–233, 2006.
- ANSELIN, L. Local Indicators of Spatial Association-LISA. **Geographical Analysis**, v. 27, n. 2, p. 93–115, 1995.
- ANSELIN, L. The Moran scatterplot as an ESDA tool to assess local instability in spatial association. Em: FISCHER, M.; SCHOLTEN, H.; UNWIN, D. (Eds.). **Spatial Analytical Perspectives on GIS**. 1996.
- BARNETT, A. G. et al. The Effects of Air Pollution on Hospitalizations for Cardiovascular Disease in Elderly People in Australian and New Zealand Cities. **Environmental Health Perspectives**, v. 114, n. 7, p. 1018–1023, 2006.
- BRASIL. 12.187. Lei nº 12.187, de 29 de dezembro de 2009. Institui a Política Nacional sobre Mudanças do Clima – PNMC e dá outras providências. . 2009.
- BURNETT, J. W.; BERGSTROM, J. C.; DORFMAN, J. H. A spatial panel data approach to estimating U.S. state-level energy emissions. **Energy Economics**, v. 40, p. 396–404, nov. 2013.
- CARVALHO, A. X. Y.; ALBUQUERQUE, P. H. M. **Tópicos em econometria espacial para dados cross-section**. [s.l.] Texto para Discussão, 2010. Disponível em: <<https://www.econstor.eu/handle/10419/91002>>. Acesso em: 4 jun. 2021.
- CHENG, W.-L. et al. Comparison of the Revised Air Quality Index with the PSI and AQI indices. **Science of The Total Environment**, v. 382, n. 2–3, p. 191–198, 2007.
- Climate Watch. Data explorer**, 2021. Disponível em: <<https://www.climatewatchdata.org/data-explorer/>>. Acesso em: 20 jun. 2021
- DAPPER, S. N.; SPOHR, C.; ZANINI, R. R. Poluição do ar como fator de risco para a saúde: uma revisão sistemática no estado de São Paulo. **Estudos Avançados**, v. 30, n. 86, p. 83–97, abr. 2016.
- DING, Y. et al. The environmental Kuznets curve for PM2.5 pollution in Beijing-Tianjin-Hebei region of China: A spatial panel data approach. **Journal of Cleaner Production**, v. 220, p. 984–994, maio 2019.

- DOCKERY, D. W. et al. An Association Between Air Pollution and Mortality in six U.S. Cities. **The New England Journal of Medicine**, v. 329, n. 24, p. 1753–1759, 1993.
- DOMINICI, F. et al. Fine Particulate Air Pollution and Hospital Admission for Cardiovascular and Respiratory Diseases. **JAMA**, v. 295, n. 10, p. 1127, 2006.
- DRUKKER, D. M. et al. Creating and Managing Spatial-Weighting Matrices with the Spmat Command. **The Stata Journal**, v. 13, n. 2, p. 242–286, 1 jul. 2013.
- ELHORST, J. P. Matlab Software for Spatial Panels. **International Regional Science Review**, v. 37, n. 3, p. 389–405, 2012.
- ELHORST, J. P. **Spatial Econometrics**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2014.
- FENG, Y. et al. Spatial Effects of Air Pollution on Public Health in China. **Environmental and Resource Economics**, v. 73, n. 1, p. 229–250, 2019.
- FIRJAN. **IFDM 2018 - Índice FIRJAN Desenvolvimento Municipal**. [s.l.] Federação das Indústrias do Estado do Rio de Janeiro, 2018. Disponível em: <https://www.firjan.com.br/data/files/67/A0/18/D6/CF834610C4FC8246F8A809C2/IFDM_2018.pdf>. Acesso em: 2 abr. 2022.
- FREITAS, C. U. DE et al. Air pollution and its impacts on health in Vitoria, Espírito Santo, Brazil. **Revista de Saúde Pública**, v. 50, n. 0, 2016.
- GOUVEIA, N. et al. Poluição do ar e efeitos na saúde nas populações de duas grandes metrópoles brasileiras. **Epidemiologia e Serviços de Saúde**, v. 12, n. 1, 2003.
- GOUVEIA, N. et al. Poluição do ar e impactos na saúde na Região Metropolitana de Belo Horizonte – Minas Gerais, Brasil. **Ciência & Saúde Coletiva**, v. 24, n. 10, p. 3773–3781, out. 2019.
- GUAN, Y. et al. Long-term health impacts attributable to PM2.5 and ozone pollution in China's most polluted region during 2015–2020. **Journal of Cleaner Production**, v. 321, p. 128970, out. 2021.
- HALES, S.; BLAKELY, T.; WOODWARD, A. Air pollution and mortality in New Zealand: cohort study. **Journal of Epidemiology and Community Health**, v. 66, n. 5, p. 468–473, 2012.
- HOEK, G. et al. Association between mortality and indicators of traffic-related air pollution in the Netherlands: a cohort study. **The Lancet**, v. 360, n. 9341, p. 1203–1209, 2002.
- JANKE, K. Air pollution, avoidance behaviour and children's respiratory health: Evidence from England. **Journal of Health Economics**, v. 38, p. 23–42, 2014.
- KANG, Y.-Q.; ZHAO, T.; YANG, Y.-Y. Environmental Kuznets curve for CO 2 emissions in China: A spatial panel data approach. **Ecological Indicators**, v. 63, p. 231–239, abr. 2016.
- KARR, C. et al. Effects of Subchronic and Chronic Exposure to Ambient Air Pollutants on Infant Bronchiolitis. **American Journal of Epidemiology**, v. 165, n. 5, p. 553–560, 2006.
- LAI, I.-C.; BRIMBLECOMBE, P. Long-range Transport of Air Pollutants to Taiwan during the COVID-19 Lockdown in Hubei Province. **Aerosol and Air Quality Research**, v. 21, n. 2, p. 200392, 2021.
- LESAGE, J. P. An Introduction to Spatial Econometrics. **Revue d'économie industrielle**, n. 123, p. 19–44, 2008.
- LESAGE, J.; PACE, R. K. Introduction to Spatial Econometrics. p. 331, 2009.
- LIU, Y.; AO, C. Effect of air pollution on health care expenditure: Evidence from respiratory diseases. **Health Economics**, v. 30, n. 4, p. 858–875, 2021.
- MCGOWAN, J. A. et al. Particulate air pollution and hospital admissions in Christchurch, New Zealand. **Australian and New Zealand Journal of Public Health**, v. 26, n. 1, p. 23–29, 2002.
- MEDINA-RAMÓN, M.; ZANOBETTI, A.; SCHWARTZ, J. The Effect of Ozone and PM10 on Hospital Admissions for Pneumonia and Chronic Obstructive Pulmonary Disease: A National Multicity Study. **American Journal of Epidemiology**, v. 163, n. 6, p. 579–588, 2006.
- NARDOCCI, A. C. et al. Poluição do ar e doenças respiratórias e cardiovasculares: estudo de séries temporais em Cubatão, São Paulo, Brasil. **Cadernos de Saúde Pública**, v. 29, n. 9, p. 1867–1876, set. 2013.

- PEDERSEN, M. et al. Ambient air pollution and low birthweight: a European cohort study (ESCAPE). **The Lancet Respiratory Medicine**, v. 1, n. 9, p. 695–704, 2013.
- POPE, C. A. et al. Particulate Air Pollution as a Predictor of Mortality in a Prospective Study of U.S. Adults. **American Journal of Critical Care Medicine**, v. 151, p. 6, 1995.
- POPE, C. A. et al. Lung Cancer, Cardiopulmonary Mortality, and Long-term Exposure to Fine Particulate Air Pollution. **JAMA**, v. 287, n. 9, p. 1132, 2002.
- POPE, C. A. et al. Cardiovascular Mortality and Long-Term Exposure to Particulate Air Pollution: Epidemiological Evidence of General Pathophysiological Pathways of Disease. **Circulation**, v. 109, n. 1, p. 71–77, 2004.
- POPE, C. A. et al. Ischemic Heart Disease Events Triggered by Short-Term Exposure to Fine Particulate Air Pollution. **Circulation**, v. 114, n. 23, p. 2443–2448, 2006.
- PRÜSS-ÜSTÜN, A. et al. **Preventing disease through healthy environments: a global assessment of the burden of disease from environmental risks**. Second edition ed. Geneva, Switzerland: World Health Organization, 2016.
- SAMOLI, E. et al. Acute effects of air pollution on pediatric asthma exacerbation: Evidence of association and effect modification. **Environmental Research**, v. 111, n. 3, p. 418–424, 2011.
- SEEG. Entenda as Estimativas**, 2021. Disponível em: <<http://seeg.eco.br/entenda-as-estimativas>>. Acesso em: 22 jul. 2021
- SEO, J.-H. et al. Population-attributable risk of low birthweight related to PM₁₀ pollution in seven Korean cities. **Paediatric and Perinatal Epidemiology**, v. 24, n. 2, p. 140–148, 2010.
- TOREN, K. et al. Occupational exposure to particulate air pollution and mortality due to ischaemic heart disease and cerebrovascular disease. **Occupational and Environmental Medicine**, v. 64, n. 8, p. 515–519, 2007.
- UNFCCC. About the Secretariat**, 2021. Disponível em: <<https://unfccc.int/about-us/about-the-secretariat>>. Acesso em: 28 ago. 2021
- UNITED NATIONS FRAMEWORK CONVENTION ON CLIMATE CHANGE (UNFCCC). The Paris Agreement. . 2015.
- UNITED NATIONS FRAMEWORK CONVENTION ON CLIMATE CHANGE (UNFCCC). Brazil First NDC (Updated Submission). . 2020.
- VRIJHEID, M. et al. Ambient Air Pollution and Risk of Congenital Anomalies: A Systematic Review and Meta-analysis. **Environmental Health Perspectives**, v. 119, n. 5, p. 598–606, 2011.
- WANG, H.; YANG, J. Total-factor industrial eco-efficiency and its influencing factors in China: A spatial panel data approach. **Journal of Cleaner Production**, v. 227, p. 263–271, ago. 2019.
- WRIGHT, L. A.; KEMP, S.; WILLIAMS, I. 'Carbon footprinting': towards a universally accepted definition. **Carbon Management**, v. 2, n. 1, p. 61–72, 2011.
- ZANOBETTI, A. et al. Fine particulate air pollution and its components in association with cause-specific emergency admissions. **Environmental Health**, v. 8, n. 1, p. 58, 2009.
- ZANOBETTI, A.; SCHWARTZ, J. The Effect of Fine and Coarse Particulate Air Pollution on Mortality: A National Analysis. **Environmental Health Perspectives**, v. 117, n. 6, p. 898–903, 2009.
- ZHOU, Z.; YE, X.; GE, X. The Impacts of Technical Progress on Sulfur Dioxide Kuznets Curve in China: A Spatial Panel Data Approach. **Sustainability**, v. 9, n. 4, p. 674, 24 abr. 2017.

APÊNDICE

Apêndice A – Grupos de Doenças

Doenças Respiratórias	CID 10
Faringite aguda e amigdalite aguda	J02-J03
Laringite e traqueíte agudas	J04
Pneumonia	J12-J18
Bronquite aguda e Bronquiolite aguda	J20-J21
Sinusite crônica	J32
Bronquite, enfisema e outras doenças do trato respiratório superior	J40-J44
Asma	J45-J46
Doenças Cardiovasculares	CID 10
Infarto agudo do miocárdio	I21-I22
Outras doenças isquêmicas do coração	I20, I23-I25
Acidente vascular cerebral, não especificado como hemorrágico ou isquêmico	I64
Acidentes vasculares cerebrais isquêmicos transitórios e síndromes correlatas	G45
Câncer de pulmão	CID 10
Neoplasia maligna da traqueia, dos brônquios e dos pulmões	C33-C34
Condições Neonatais	CID 10
Retardo de crescimento fetal, desnutrição fetal e transtornos relacionados à gestação curta e baixo peso ao nascer	P05-P07
Malformações congênitas, deformidades e anomalias cromossômicas	Q00-Q99

Fonte: Elaboração própria.

Apêndice B – I de Moran das Variáveis de Interesse.

Ano	Int. Res.	Int. Car.	Int. Can.	Int. Neo.	Int. Tot.	Ob. Res.	Ob. Car.	Ob. Can.	Ob. Neo.	Ob. Tot.	InEmissoes
2005	0,1843*** (118,30)	0,3554*** (228,13)	0,1160*** (74,66)	0,1074*** (69,09)	0,2026*** (130,03)	0,2569*** (164,90)	0,18423*** (118,28)	0,0368*** (23,84)	0,0334*** (21,55)	0,3003*** (192,67)	0,5041*** (323,27)
2006	0,1956*** (125,57)	0,3836*** (246,15)	0,1099*** (71,83)	0,0951*** (61,22)	0,2252*** (144,54)	0,2524*** (162,01)	0,1813*** (116,42)	0,0447*** (28,94)	0,0277*** (17,95)	0,3049*** (195,63)	0,4803*** (308,01)
2007	0,2027*** (130,14)	0,3737*** (239,74)	0,1335*** (86,04)	0,0953*** (61,40)	0,2954*** (147,31)	0,2564*** (164,60)	0,1794*** (115,16)	0,0437*** (28,37)	0,0181** (11,76)	0,3163*** (202,88)	0,4731*** (303,40)
2008	0,1705*** (109,56)	0,3883*** (249,09)	0,1488*** (95,86)	0,1161*** (74,62)	0,2072*** (133,07)	0,2326*** (149,34)	0,1386*** (88,98)	0,0459*** (29,87)	0,0146*** (9,50)	0,2834*** (181,87)	0,4443*** (284,92)
2009	0,1737*** (111,51)	0,3769*** (241,78)	0,1529*** (98,67)	0,1296*** (83,22)	0,2075*** (133,21)	0,2603*** (167,03)	0,1323*** (84,98)	0,0588*** (37,93)	0,0160*** (10,37)	0,2893*** (185,58)	0,4490*** (287,91)
2010	0,1741*** (111,83)	0,3823*** (245,27)	0,1597*** (103,03)	0,1263*** (81,31)	0,2114*** (135,74)	0,2604*** (167,12)	0,1365*** (87,68)	0,0491*** (31,80)	0,0191*** (12,40)	0,2935*** (188,33)	0,4285*** (274,79)
2011	0,1519*** (97,60)	0,3805*** (244,11)	0,1478*** (95,12)	0,1649*** (105,86)	0,1906*** (122,36)	0,2649*** (170,01)	0,1193*** (76,62)	0,0430*** (27,81)	0,0173*** (11,23)	0,2839*** (182,14)	0,4163*** (266,97)
2012	0,1505*** (96,74)	0,3824*** (245,29)	0,1320*** (85,01)	0,1319*** (84,74)	0,2043*** (131,23)	0,2580*** (165,58)	0,1157*** (74,32)	0,0468*** (30,21)	0,0232*** (14,99)	0,2728*** (175,03)	0,4206*** (269,73)
2013	0,1663*** (106,84)	0,3707*** (237,78)	0,1431*** (92,13)	0,1476*** (94,79)	0,2107*** (141,92)	0,2563*** (164,47)	0,0976*** (62,71)	0,0613*** (39,51)	0,0120*** (7,83)	0,2673*** (171,51)	0,4389*** (281,43)
2014	0,1626*** (104,51)	0,3757*** (241,05)	0,1418*** (92,73)	0,1458*** (93,68)	0,2222*** (142,72)	0,2380*** (152,74)	0,1045*** (67,12)	0,0712*** (45,88)	0,0198*** (12,80)	0,2556*** (163,98)	0,4288*** (274,95)
2015	0,1773*** (113,91)	0,3834*** (246,01)	0,1539*** (99,35)	0,1503*** (99,35)	0,2413*** (154,95)	0,2287*** (146,74)	0,1047*** (67,27)	0,0603*** (38,88)	0,0105*** (6,87)	0,2537*** (162,75)	0,4464*** (286,24)
2016	0,2084*** (134,09)	0,3962*** (254,21)	0,1426*** (91,95)	0,1577*** (101,24)	0,2878*** (184,92)	0,2598*** (166,73)	0,0876*** (56,31)	0,05429*** (35,07)	0,0188*** (7,74)	0,2690*** (172,59)	0,4684*** (300,33)

Obs. Erros Padrão entre parênteses. *** 1% de significância; ** 5% de significância; * 10% de significância.

Fonte: Elaboração própria.