





Condicionantes das internações por doenças respiratórias: evidências espaciais a partir do desmatamento na Amazônia Legal

Deforestation drives extensive hospitalizations for respiratory diseases: spatial evidence in the Brazilian Amazon

José Alex do Nascimento Bento¹ , Jair Andrade de Araujo¹ , Francisco José Silva Tabosa¹ , Wellington Ribeiro Justo² 

¹Programa de Pós-graduação em Economia Rural, Universidade Federal do Ceará (UFC), Fortaleza (CE), Brasil. E-mails: josealex18@yahoo.com.br; jairandrade@ufc.br; franzetabosa@ufc.br

²Programa de Pós-graduação em Economia Regional e Urbana, Universidade Regional do Cariri (URCA), Crato (CE), Brasil. E-mail: justowr@yahoo.com.br

Como citar: Bento, J. A. N., Araujo, J. A., Tabosa, F. J. S., & Justo, W. R. (2024). Condicionantes das internações por doenças respiratórias: evidências espaciais a partir do desmatamento na Amazônia Legal. *Revista de Economia e Sociologia Rural*, 62(2), e274678. <https://doi.org/10.1590/1806-9479.2023.274678>

Resumo: Este estudo avalia os condicionantes das internações por doenças respiratórias para a região da Amazônia Legal, no âmbito municipal, no período 2000-2019, com o emprego de modelos abordando a dependência espacial. Os resultados da Análise Exploratória de Dados Espaciais sugerem a existência de *clusters* em um padrão Alto-Alto na região do Arco do Desmatamento e na parte nordeste da referida região. Os resultados indicaram a ocorrência de efeitos não observados nas internações por doenças respiratórias, sendo adequada a estimação pelo modelo *Spatial Autocorrelation Model* (SAC). As variáveis desmatamento, densidade populacional, emissão de Gases do Efeito Estufa (GEE) e crédito rural influenciaram positivamente, ao passo que razão capital-trabalho e precipitação afetaram de maneira negativa as internações por doenças respiratórias.

Palavras-chave: doenças respiratórias, desmatamento, modelos espaciais, Amazônia Legal.

Abstract: This study evaluates the conditioning factors of hospitalizations for respiratory diseases for the Legal Amazon, at the municipal level, in the period 2000-2019, using models addressing spatial dependence. The results of the Exploratory Spatial Data Analysis suggest the existence of "clusters" in a High-High pattern in the Arc of Deforestation region and in the northeastern part of that region. The econometric results indicated the presence of unobserved effects, being more adequate the estimation by the Spatial Autocorrelation Model (SAC). The variables deforestation, population density, Greenhouse Gases (GHG) emissions and rural credit had a positive impact, while the capital-labor ratio and precipitation had a negative impact.

Keywords: respiratory diseases, deforestation, spatial models, Legal Amazon.

1 INTRODUÇÃO

Todos os biomas brasileiros tiveram perdas em sua cobertura florestal, no período de 2000 a 2018, totalizando cerca de 500 mil km². Especificamente, o bioma Amazônia, nesse período, foi o que apresentou maior perda, de 269,8 mil km², correspondendo a 8% de sua cobertura florestal, colaborando para que em 2018 sua área florestal representasse 75,7% de sua área original (Instituto Brasileiro de Geografia e Estatística, 2018).

Durante o referido período, observou-se a desaceleração das taxas de desmatamento no País. Infelizmente, essa tendência mudou drasticamente nos últimos anos, e o aumento do desmatamento começou gradativamente (Silva et al., 2020, 2021). A classe de vegetação florestal deu lugar, sobretudo, a áreas de pastagem com manejo (50,2%), que passaram de 248.794 km² em 2000 para 426.424 km² em 2018, um crescimento de 71,4%, e de mosaico de



ocupações, que representou 31% das conversões observadas, evidenciando uma fragmentação da paisagem na região. Em relação à área agrícola, o crescimento foi de 17.073 km², em 2000, para 66.350 km², em 2018, o que representou 288,6% de aumento (Instituto Brasileiro de Geografia e Estatística, 2018).

Além de causar danos à biodiversidade (fragmentação de florestas, extinção de espécies etc.), aos solos e aos recursos hídricos, o desflorestamento também contribui para o efeito estufa, especialmente quando associado às queimadas. A destruição de florestas e outras modalidades de vegetação nativa são responsáveis por mais de 75% das emissões líquidas de dióxido de carbono (CO_2) para a atmosfera do Brasil, colocando o País entre os dez maiores emissores mundiais de Gases do Efeito Estufa (GEE) (Instituto Brasileiro de Geografia e Estatística, 2012); precisamente em sétimo lugar (2,9% do total mundial de emissões) em 2018, tendo China (26%), Estados Unidos (17,74%) e Rússia (13,79%), em primeiro, segundo e terceiro maiores emissores, respectivamente (Observatório do Clima, 2019).

Além disso, outro problema, ligado ao desmatamento, são as emissões de Material Particulado fino – conhecido como MP – de incêndios que se concentra na atmosfera, principalmente em períodos secos (Artaxo et al., 2013). Assim, a inalação de MP de incêndios tem impactos adversos na saúde humana, incluindo aumento das internações hospitalares e mortalidade prematura (Jacobson et al., 2014; Human Rights Watch, 2020).

Nesse sentido, uma análise sobre a relação entre desmatamento e doenças pode evidenciar custos, que muitas vezes, têm sido negligenciados no esforço de valoração do capital natural. A literatura especializada aponta que diversas doenças podem ter sua incidência aumentada com o desmatamento, sugerindo, ainda, até mesmo uma relação de aumento de doenças em geral.

A Amazônia é o mais extenso dos biomas predominantemente florestais do Território brasileiro. Desse modo, essa região está sujeita a diversos fatores que contribuem para o desmatamento, de tal modo a ser possível presumir que tais fatores sejam predominantemente mais intensos em certas áreas do que em outras. A isso chama-se de processo desigual de desmatamento. Em que áreas, porém, há mais desmatamento? E, conseqüentemente, será que existem mais internações por doenças respiratórias e quais são as causas dessas internações? As respostas a essas indagações se revelam importantes, pois eventuais medidas ou políticas que tenham o objetivo de controlar ou combater o desmatamento devem levar em conta tais desigualdades para serem efetivas, bem como políticas de saúde voltadas a mitigar os problemas decorrentes do processo de desmatamento e queimadas. Portanto, entender essas tendências em termos de qualidade ambiental é importante para os indivíduos e os projetos de desenvolvimentos. Pode-se, ainda, traduzir em sucesso ou fracasso das políticas ambientais implantadas.

Para este efeito, análises espaciais explícitas são cada vez mais utilizadas para resolver os problemas derivados da autocorrelação espacial. Assim, o objetivo deste artigo consiste em analisar os condicionantes das doenças respiratórias na região da Amazônia Legal, decorrentes do processo de desmatamento e queimadas. Este estudo será, certamente, útil para o gerenciamento da saúde na região Norte, cuja vulnerabilidade social é a maior do País – o que amplifica o impacto dos desequilíbrios ambientais sobre a saúde. Desse modo, a estratégia empírica foi baseada no uso de dados em painel, que permitem controlar efeitos não observados no plano municipal. Para isto, utilizou-se a abordagem de econometria espacial, recorrendo aos 772 municípios da Amazônia Legal, no período de 2000 a 2019, período amostral selecionado pela disponibilidade de dados.

Observou-se que metodologias considerando efeitos espaciais, para a análise de doenças respiratórias, não são recorrentes na Amazônia, apenas em estudos centralizados no desmatamento (Oliveira et al., 2011; Santos et al., 2021).

Além desta introdução, a segunda seção descreve a literatura relacionada. A área de estudo, base de dados e métodos econométricos utilizados são descritos na terceira seção, enquanto os principais resultados são exibidos na quarta, enquanto as considerações finais são discutidas no quinto segmento.

2 FUNDAMENTAÇÃO TEÓRICA

Nos parágrafos a seguir são delineados alguns dos principais trabalhos sobre a análise econométrica dos fatores que culminam nas internações por doenças respiratórias, tanto na Amazônia quanto em outros países, sem se ter a pretensão de esgotá-los. Vale ressaltar que esses experimentos são importantes, na medida em que orientam e justificam a escolha das variáveis que compõem o modelo econométrico proposto e estimado neste artigo.

Com efeito, a literatura mostra que desequilíbrios ambientais, principalmente relacionados ao desmatamento, aumentam a incidência de doenças. As queimadas no Estado da Califórnia, nos Estados Unidos, e no sudeste do Continente Asiático exprimem evidências empíricas desta relação.

A fumaça de qualquer origem produz efeitos negativos na saúde humana, principalmente, doenças respiratórias. Estudos experimentais, epidemiológicos e clínicos constituem a base do conhecimento dos efeitos adversos dos poluentes atmosféricos para a saúde humana (Böhm et al., 1989; Saldiva et al., 1994; Saldiva et al., 1995). Essas pesquisas, com base em diversos ramos do conhecimento, como a toxicologia, a análise de risco, a epidemiologia e a bioestatística, acumularam muitas informações sobre essa temática. Em adição a elas, nas últimas duas décadas (2000-2020), uma abordagem bastante utilizada coincide com os estudos epidemiológicos de séries temporais (Carmo & Hacon, 2013).

O Estado da Califórnia registrou mais da metade dos incêndios florestais nos Estados Unidos ao largo do século XX (Fried et al., 2004). Por esse motivo, diversos estudos avaliam os impactos na saúde humana associados às queimadas. Jacobs et al. (1997) apontaram que as queimadas de resíduos de plantações de arroz na região de Butte, California, durante os anos de 1983 a 1992, estavam associadas com as internações de asma. Utilizando regressão em séries temporais, mostraram que o aumento de um acre no total de área queimada aumentaria em 23% as internações de asma. Outro estudo em San Diego, Califórnia, com dados de séries temporais, em período diário, de setembro a outubro de 2003, mostrou que os incêndios florestais aumentaram significativamente os atendimentos de emergência por asma e problemas respiratórios diversos (Viswanathan et al., 2006).

A Ásia exibiu diversos episódios de grandes queimadas de longa duração, principalmente na região sudeste. Em sua história recente, os incêndios mais severos ocorreram nos anos de 1997/98, relacionados ao fenômeno climático *El Niño*, que resultaram na destruição de 11,7 milhões de hectares de floresta, propriedades e outros tipos de vegetação (Tacconi et al., 2007; Field & Shen, 2008). Os impactos na saúde humana associados a este grande evento de queimada foram documentados. Conforme Sastry (2002), dados mensais, de janeiro de 1996 a dezembro de 1997, na Malásia, apontaram que o aumento de MP estava relacionado com o aumento da mortalidade para idosos. Por fim, Mott et al. (2005) com dados mensais de séries temporais, de janeiro de 1995 a dezembro de 1998, na Malásia, observaram um aumento nas internações por asma, causas respiratórias e cardiovasculares durante o período de queimadas.

Na literatura nacional, cabe destacar o papel do Laboratório de Poluição Atmosférica Experimental da Faculdade de Medicina da Universidade de São Paulo, que, desde 1979, desenvolve estudos sobre poluição atmosférica e saúde (André et al., 2012). E, desde 1992,

são feitos estudos de monitoramento de aerossóis na região Amazônica pelo Experimento de Larga Escala da Biosfera-Atmosfera da Amazônia (LBA) do Grupo de Estudos de Poluição do Ar (GEPA), pertencente ao Instituto de Física da Universidade de São Paulo (IF-USP).

Assim, encontra-se uma série de estudos que aponta os impactos na saúde humana por distintas tipologias de fontes de emissões, tais como: queima de combustíveis fósseis para geração de energia no transporte (Andrade et al., 2017; Vormittag et al., 2018); processos industriais (Spektor et al., 1991; Braga et al., 2007); atividades agrossilvopastoris associadas às queimadas, incêndios florestais e movimentação do solo (Cançado et al., 2006; Arbex et al., 2014), além de queimadas nas regiões Norte e Centro-Oeste (Reddington et al., 2015; Silva et al., 2016; Alves, 2020), contribuindo para o acúmulo de conhecimentos nessa temática e evidências para embasar ações de controle da poluição e gestão da qualidade do ar.

Especificamente na Amazônia subequatorial, os estudos sobre a poluição do ar, em decorrência de incêndios foram iniciados em 1998 pelo LBA, mas foi somente em 2007 que as primeiras descobertas, sugerindo uma associação entre as doenças respiratórias e do ar circundante foram publicadas em Ignotti et al. (2007), Rosa et al. (2008), Mascarenhas et al. (2008).

Mascarenhas et al. (2008), em um estudo no Estado do Acre, em setembro de 2005, apontaram que as queimadas estavam associadas com o atendimento ambulatorial por doenças respiratórias. Utilizando regressão em séries temporais, mostraram que essa associação foi significativa. Carmo et al. (2010), com dados mensais de séries temporais de janeiro de 2004 a dezembro de 2005, em Alta Floresta, Município do Mato Grosso, apontaram que, com aumentos de 10 $\mu\text{g}/\text{m}^3$ nos níveis de MP, havia aumentos de 2,9% e 2,6% nos atendimentos por doenças respiratórias de crianças com 6º e 7º dias subsequentes à exposição. Por fim, Ignotti et al. (2010), com dados mensais de séries temporais de janeiro a dezembro de 2005, em Alta Floresta e Tangará da Serra, Municípios do Estado de Mato Grosso, observaram que aumentos de 10 $\mu\text{g}/\text{m}^3$ nos níveis de MP estavam associados a aumentos de até 6% nas internações por doenças respiratórias de crianças e de 6,8% dos idosos.

Machin et al. (2019) estudaram o custo da poluição do ar para o sistema de saúde e a aplicabilidade de um modelo matemático para estimar a concentração ambiental de poluentes atmosféricos, com dados ecológicos de série temporal e de internações por doenças respiratórias em pessoas de mais de 60 anos, residentes em Cuiabá, Brasil, no ano de 2012. Como resultados, apontaram para o aumento do risco de hospitalização em 31,8%, quando existe aumento de 3,5 $\mu\text{g} / \text{m}^3$ nas concentrações de $\text{MP}_{2,5}$, com gasto anual total de mais de US\$ 96.000,00 para o sistema público de saúde brasileiro.

No relatório *O Ar é Insuportável*, as conclusões indicaram que as queimadas associadas ao desmatamento na Amazônia tiveram um impacto negativo significativo na saúde pública na região em 2019. Isso incluiu 2.195 internações devido a doenças respiratórias atribuíveis às queimadas. Destas internações, 467 (21%) foram de bebês de zero a 12 meses de idade e 1.080 (49%) foram de pessoas idosas, com 60 anos ou mais. O estudo descobriu que os pacientes passaram um total de 6.698 dias no hospital em 2019 em decorrência da exposição à poluição do ar decorrente das queimadas (Human Rights Watch, 2020).

3 METODOLOGIA

3.1 Área de Estudo

A Amazônia Legal, na Figura 1, é uma área que corresponde a 59% do Território brasileiro e engloba a totalidade de oito estados (Acre, Amapá, Amazonas, Mato Grosso, Pará, Rondônia,

Roraima e Tocantins) e parte do Estado do Maranhão (ao oeste do meridiano de 44°W), perfazendo 5,0 milhões de km². Nessa área, moram cerca 56% da população indígena brasileira. O conceito de Amazônia Legal foi instituído em 1953 e seus limites territoriais decorrem da necessidade de planejar o desenvolvimento econômico da Região e, por isso, não se resumem ao ecossistema de selva úmida, que ocupa 49% do Território nacional e se estende, também, pelo território de oito países vizinhos. Os limites da Amazônia Legal foram alterados várias vezes, em consequência de mudanças na divisão política do País (Instituto Brasileiro de Geografia e Estatística, 2012).

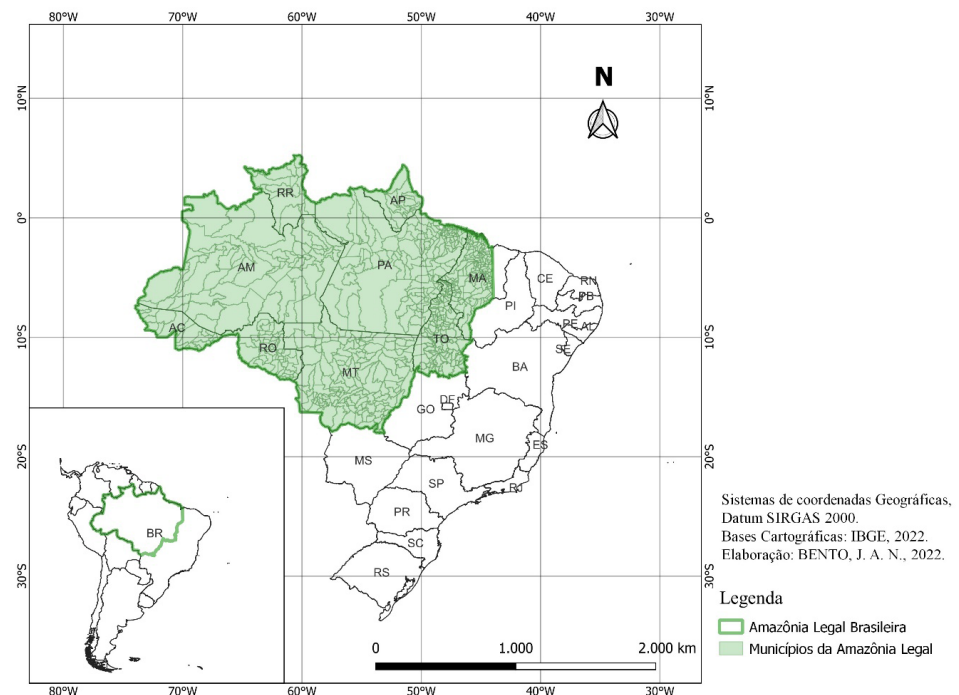


Figura 1 – Amazônia Legal brasileira e amostra de referência.

Fonte: Elaborada pelos autores (2022).

3.2 Base de dados

Foram analisados os 772 municípios brasileiros pertencentes à região da Amazônia Legal, durante os anos de 2000 a 2019, e fazendo uso de variáveis de acordo com a literatura. O Quadro 1 contém as variáveis utilizadas na pesquisa, seu possível impacto esperado e fonte, sendo descritas a seguir.

A variável dependente DOENÇA considera as internações relacionadas com todas as patologias respiratórias (códigos J00-J99), obtidas do Departamento de Tecnologia da Informação do SUS em sua plataforma que disponibiliza dados de sistemas públicos de saúde via internet (Brasil, 2022). São as causas de hospitalização registradas de acordo com a Classificação Internacional de Doenças, considerando sua 10ª revisão (CID-10).

Vale ressaltar que a porcentagem da população urbana, URBAN, em decorrência das informações serem encontrada apenas nos censos de 2000 e 2010, foi elaborada uma *proxy* para os demais anos calculados como um acréscimo da média dos anos 2000 a 2010. Para o período de 2010 a 2019, foi considerada a mesma média (2000 a 2010), porém dividida por 2, porque levou na devida conta o fato de que a porcentagem da população urbana cresce em taxas menores.

Quadro 1 – Variáveis da Pesquisa, Amazônia Legal, 2000-2019

	Variável	Descrição	Unidade	Sinal esperado do coeficiente	Fonte
Variável dependente	DOENÇA	Internações anuais por doenças respiratórias	Número de internações	-	Brasil (2022)
Variáveis explicativas	PIB	PIB <i>per capita</i>	R\$ de 2019	Positivo ou negativo	Instituto Brasileiro de Geografia e Estatística (2022)
	FOR	Área de floresta	Km ²	Negativo	Instituto Nacional de Pesquisas Espaciais (2022)
	DESM	Desmatamento em Km ²	Km ²	Positivo	Instituto Nacional de Pesquisas Espaciais (2022)
	DPOP	Densidade populacional	número de habitantes/km ²	Positivo ou negativo	Instituto Brasileiro de Geografia e Estatística (2022)
	URBAN	População urbana	(% do total)	Positivo	Instituto Brasileiro de Geografia e Estatística (2022)
	CR	Crédito rural	R\$ de 2019	Positivo	IpeaData (2022)
	GASTOTRANS	Gasto público em transporte	R\$ de 2019	Positivo ou negativo	IpeaData (2022)
	IND	Estrutura Industrial (valor adicional bruto do PIB)	R\$ de 2019	Negativo	Instituto Brasileiro de Geografia e Estatística (2022)
	K/L	Razão capital-trabalho	R\$ de 2019	Negativo	IpeaData (2022) e Brasil (2020)
	EMISSÃO	Queima de combustível industrial, residencial e transporte	Toneladas	Positivo	Observatório do Clima (2022)
	TEMP	Temperatura média	° C	Positivo	National Aeronautics and Space Administration (2022)
	PRECIPITAÇÃO	Precipitação anual	Mm	Negativo	National Aeronautics and Space Administration (2022)

Fonte: Elaborado pelos autores (2022).

Já o crédito rural, CR, foi considerado o montante total de crédito rural obtido pelo município, sem levar em conta suas diversas modalidades. Para a variável EMISSÃO, considerando o impacto do consumo de energia no desenvolvimento econômico e na disponibilidade de dados do consumo urbano de energia, este artigo utilizou a quantidade em toneladas de GEE pela queima de combustíveis fósseis industriais, residências e de transportes. Os gases considerados foram C_2F_6 , CF_4 , CH_4 , CO, CO_2 , Compostos Orgânicos Voláteis não Metânicos (COVNM), N_2O e NO_x .

Por fim, todas as variáveis foram transformadas em logaritmo, exceto DPOP, URBAN, em formas percentuais, TEMP, em índice, e DESM, este último sendo normalizado, pois denota valores negativos, isto é, reflorestamento, impedindo sua linearização. Desse modo, a forma logaritma reduz o grau de assimetria de todas as variáveis consideradas, e tende-se a estabilizar sua variância amostral e a curtose da amostra. Todos os valores monetários, incluindo os gastos do Governo com transporte, PIB *per capita*, IND e crédito rural foram deflacionados pelo IGP-DI ano base 2000.

3.3 Métodos analíticos

A Análise Exploratória de Dados Espaciais (AEDE) auxilia no estudo de modelos econométrico-espaciais porque permite a identificação dos efeitos espaciais (dependência espacial e heterogeneidade espacial) nas variáveis de interesse (Almeida, 2012).

Em primeiro lugar, é preciso verificar se os dados espaciais exprimem ou não aleatoriedade espacial, isto é, se os valores de um atributo em uma região são independentes ou dependentes dos valores desse atributo nas regiões vizinhas. As estatísticas de autocorrelação espacial servem a este propósito. Com efeito, a estatística I de Moran é uma das mais difundidas e utilizadas, tratando-se de mensurar a autocorrelação espacial com suporte no produto dos desvios em relação à média.

Em casos no quais os padrões de associação espacial estejam concentrados em poucas regiões (*clusters* espaciais), uma estatística global é factível de não captar essa realidade. As associações espaciais locais são identificadas por meio de estatísticas locais de autocorrelação espacial, nesses casos, com a utilização do indicador LISA (*Local Indicator of Spatial Association*).

Feita essa introdução à análise espacial, a área da Econometria denominada de Econometria Espacial estuda a importância da questão espacial inerente à ciência regional, em particular, à economia regional. Além disso, trabalha com dados distribuídos no espaço que expressam dependência ou heterogeneidade em sua estrutura (Anselin, 1988).

A heterogeneidade espacial em um modelo econométrico refere-se à instabilidade estrutural, proveniente de características espacialmente diferenciadas, ou de variâncias não constantes dos termos de erro (heterocedasticidade) no espaço (Anselin, 1988).

A dependência espacial, por sua vez, significa que o valor de uma variável em um determinado lugar depende do valor dessa mesma variável em outros pontos no espaço, isto é, “[...] a existência de uma relação funcional entre o que acontece num certo ponto no espaço e o que acontece em outro lugar” (Anselin, 1988, p. 11).

Na evolução de seus estudos de construção de testes para modelos de painel espacial, no entanto, Anselin (2013) evidenciou que os testes baseados na estimação de Máxima Verossimilhança (ML), o teste de razão de probabilidade ou *Likelihood Ratio* (LR) e o LM robusto são os mais apropriados para testar se há autocorrelação espacial nos erros. Esses testes foram, também, adaptados para testar os modelos defasados espacialmente. Ademais,

segundo Belotti et al. (2017), os testes de Wald e LR são assintoticamente quase equivalentes e basicamente chegam à mesma conclusão.

Para identificar a autocorrelação espacial nas variáveis da pesquisa, foi utilizada a estatística I de Moran, para a variável interações de doenças respiratórias. Além disso, as medidas de autocorrelação espacial local ou LISA univariada também foram adotadas.

Primeiramente, foi estimado o modelo econométrico para as interações por doenças respiratórias na Amazônia Legal, sem considerar os efeitos espaciais, com a seguinte especificação, na modalidade empilhada (modelo básico):

$$\begin{aligned} \ln DOENCA_t = & \alpha_1 + \alpha_2 ZDESM_t + \beta_1 \ln PIB_t + \beta_2 \ln FOR_t + \beta_3 DPOP_t + \\ & \beta_4 URBAN_t + \beta_5 \ln CR_t + \beta_6 \ln GASTOTRANS_t + \beta_7 \ln IND_t + \beta_8 \ln K / L_t + \\ & + \beta_9 \ln EMISSÃO_t + \beta_{10} TEMP_t + \beta_{11} \ln PRECIPITAÇÃO_t + \tau D_t + \mu + u_t \end{aligned} \quad (1)$$

Onde: t é o subscrito para o painel de dados corresponde ao ano observado $t=1, 2, \dots, T$, para cada um dos i municípios da região da Amazônia Legal, sendo $i = 1, 2, 3, \dots, 772$; e $t=2000, 2001, \dots, 2019$. Adicionalmente, μ são os efeitos individuais (relacionadas a características do município, praticamente invariantes no tempo, tais como topografia, áreas protegidas, distância a mercados, e outras), D_t é uma variável *dummy* anual para captar os efeitos temporais, u_t é o termo de erro aleatório, α_1 e α_2 e $\beta_1, \dots, \beta_{11}$ são parâmetros a serem estimados.

O modelo sem correção para efeitos espaciais especificado acima (modelo básico – Equação 1) será estimado pelo método de efeitos fixos e efeitos aleatórios, e por MQO com dados combinados (*pooled*). Os critérios de avaliação serão os testes de Breusch-Pagan, F e Hausman.

Para verificar se há efeitos de dependência espacial, bem como descrever estes efeitos no modelo econométrico, seguindo Anselin (1988), é necessário definir, previamente, uma matriz de pesos espaciais, conhecida como W . Isto é, W é uma matriz simétrica em que cada elemento W_{ij} é igual a 1 se i e j são vizinhos e iguais a zero no caso contrário. Por convenção, os elementos diagonais são iguais a zero, ou seja, $W_{ij} = 0$.

Desse modo, a matriz de pesos espaciais W será escolhida com base na avaliação da autocorrelação espacial dos resíduos do modelo básico, seguindo o procedimento de Almeida (2012), que sugere que a escolha da matriz espacial seja sobre aquela capaz de captar maiores efeitos espaciais nos resíduos. Assim, a comparação é feita pela estatística I de Moran obtida com o uso das matrizes de ponderação espacial baseadas na distância, distância inversa, distância inversa ao quadrado, matrizes de contigüidade (torre e rainha), além das matrizes de k -vizinhos.

Os modelos de dados em painel com dependência espacial serão testados nas seguintes especificações:

a) Modelo (1) de defasagem espacial (SAR), na forma reduzida:

$$\ln DOENCA_t = \rho W_1 DOENCA_t + \alpha_1 + \alpha_2 z DE SM_t + z_t \beta_k + \tau D_t + \mu + u_t \quad (2),$$

em que: $W_1 DOENCA_t$ é variável dependente defasada espacialmente pela matriz de pesos espaciais W_1 , z_t corresponde ao vetor com k variáveis regressoras adicionais a variável desmatamento, e ρ é chamado parâmetro de defasagem autorregressiva ($-1 < \rho < 1$).

Haja vista a endogeneidade da variável defasada espacialmente, $W_1 DOENCA_t$, esta especificação de modelo será estimada pelo estimador *within*, utilizando como variáveis instrumentais as variáveis explicativas defasadas espacialmente pela matriz W_1 .

b) Modelo (2) de erro espacial (SEM):

$$\ln DOENÇA_t = \rho W_1 DOENÇA_t + \alpha_1 + \alpha_2 z DESM_t + z_{i\beta_k} + \tau D_t + \mu + u_t \quad (3),$$

$$u_t = \lambda W_2 u_t + \varepsilon_t,$$

em que λ é chamado parâmetro autorregressivo espacial ($-1 < \lambda < 1$) e $W_2 u_t$ é o termo de erro defasado espacialmente.

c) Modelo (3) de Durbin espacial (SDM):

$$\ln DOENÇA_t = \rho W_1 DOENÇA_t + \alpha_1 + \alpha_2 z DESM_t + z_{i\beta_k} + W_1 z_i \gamma_k + \tau D_t + \mu + u_t \quad (4),$$

d) Modelo (4) com defasagem espacial do erro e transbordamentos espaciais (SAC):

$$\ln DOENÇA_t = \rho W_1 DOENÇA_t + \alpha_1 + \alpha_2 z DESM_t + z_{i\beta_k} + W_1 z_i \gamma_k + \tau D_t + \mu + u_t \quad (5),$$

$$u_t = \lambda W_2 u_t + \varepsilon_t$$

A técnica de estimação adotada foi o método de ML, pois esta é uma metodologia bastante recorrida com a utilização de uma função de verossimilhança bem comportada para a relação entre variáveis dependentes e explicativas. Além disso, o método ML aplicado quando os números de ambos os períodos e unidades espaciais são grandes, fornece estimativas consistentes para os coeficientes, o que é válido neste experimento (Yu et al., 2008).

Por fim, a escolha do modelo foi obtida com a aplicação de uma série de testes Wald, seguindo a estratégia de LeSage e Pace (2009) e Elhorst (2010) para examinar se o modelo SDM foi a especificação preferida entre o conjunto de modelos de painéis já mencionados.

4 RESULTADOS E DISCUSSÃO

Partiu-se pelas estatísticas descritivas das variáveis de estudo, posteriormente, realizaram-se as regressões dos modelos econométricos que consideram a heterogeneidade espacial dos parâmetros, por meio de regimes espaciais distintos. Como remate, são verificados os testes de robustez.

A Tabela 1 sintetiza as estatísticas de média, desvio-padrão, valores mínimos e máximos de cada variável da pesquisa. Assim, destaca-se DOENÇA, que compreende a variável de resultado a ser avaliada. Em seguida, estende-se a análise para as variáveis explicativas utilizadas. Desse modo, essas últimas representam uma ampla gama de variáveis econômicas, sociais e ambientais que suprem adequadamente às necessidades de variáveis independentes para o modelo testado.

Quanto à DOENÇA, o valor médio registrado foi de 258 internações com valores mínimos e máximos iguais a 0 e 14.420, respectivamente. No que tange aos dados referentes ao desmatamento, tem-se que o valor médio registrado foi de 17,8 km² no incremento anual de áreas desmatadas, com valores mínimos e máximos iguais a -442,9 km² (isto é, reflorestamento) e 1.561 km², respectivamente. Em relação à área de florestas, o valor médio observado foi de 4.979 km², com valores mínimos e máximos iguais a 6,98 km² e 154.382 km², respectivamente.

Para densidade populacional, o valor médio foi de 26,76, isto é, quanto maior essa taxa, maior o número de habitantes por km², com valores mínimos e máximos iguais a 0,01 e 2.933, respectivamente. Em relação ao percentual da população urbana, o valor médio observado foi de 56,6% do total de residentes, com valores mínimos e máximos iguais a, aproximadamente, 2% e 99,76%, respectivamente.

Para o valor bruto adicionado industrial do PIB, o valor médio foi de R\$ 140.499,00 com valores mínimos e máximos iguais a R\$ 148,75 e R\$ 3,5 milhões, respectivamente. No que

tange o PIB *per capita*, tem-se que o valor médio registrado foi de R\$ 16.555,08, com valores mínimos e máximos iguais a R\$ 1.594,6 e R\$ 312.968,4, respectivamente.

Tabela 1 – Estatísticas das variáveis dependente e explicativas investigadas-Amazônia Legal- 2000-2019

Variáveis	Média	Desvio-Padrão	Mínimo	Máximo
DOENCA	258	667,4	0	14.420
DESM	17,80	57,12	-442,9	1.561
FLO	4.979	12.705	6,98	154.382
DPOP	26,76	140,7	0,01	2.933
IND	140.499,3	1.180.810	148,75	3,51e+07
PIB <i>per capita</i>	16.555	19.224	1.595	312.968
URBAN	56,60	19,90	1,56	99,76
K/L	9.815	60.067	0,007	1,894e+06
TEMP	26,52	1,07	22,01	29,88
PRECIP	1.701	531,6	433,6	6.098
EMISSÃO	26.481	187.566	0,14	6,796e+06
CR	2,14e+07	5,21e+07	1.447,28	8,69e+08
GASTOTRAN	2.136.435	8.002.591	83,65	3,66e+08
N	15440			
I	772			
T	20			

Fonte: Elaborada pelos autores, com base nos dados citados na seção 3.2 (2022).

Para a relação K/L, o valor médio registrado foi de R\$ 9.814,78, com valores mínimos e máximos iguais a R\$ 0,00 e R\$ 1.893.794,00, respectivamente. Já o crédito rural apresentou média de R\$ 2,14 milhões, com valores mínimos e máximos iguais a R\$ 1.447,28 mil e R\$ 86,9 milhões, respectivamente. Os gastos com transporte denotaram média de R\$ 2,14 milhões, com valores mínimos e máximos iguais a R\$ 83,00 e R\$ 36,6 milhões, respectivamente.

Em relação à emissão GEE, a média foi de 26.481,3 mil toneladas, com valores mínimos e máximos iguais a 0,14 e 6.795.914,00 toneladas, respectivamente. No que tange à temperatura, o valor médio observado foi de 26,52 ° C, com valores mínimos e máximos iguais a 22, 01°C e 29,88 ° C, respectivamente. Já a precipitação registrou o valor médio de 1.701,27 mm, com valores mínimos e máximos iguais a 433,63 e 6.098,46 mm, respectivamente.

Com base na seção 3.3, a escolha da matriz de pesos espaciais seguiu o procedimento de Almeida (2012), adaptado para comparar o *I* de Moran, obtido com o uso das matrizes de ponderação espacial baseadas na distância, distância inversa, distância inversa ao quadrado, matrizes de contigüidade (torre e rainha), além das matrizes de *k*-vizinhos. A matriz de pesos espaciais do tipo rainha, contudo, foi a que apontou resultados mais significativos com a regressão, sendo a matriz utilizada nas estimações desta pesquisa.

Para verificar se existem padrões de associação espacial localizados (*clusters*) para as internações de doenças respiratórias anualmente dos municípios da Amazônia Legal, foi calculado o *I* de Moran local (LISA), apresentado nos mapas de significância e mapas de *clusters* na Figura 2.

Na Figura 2, observou-se uma grande semelhança entre os mapas de *clusters* ao longo dos períodos. Dois padrões de associação local para as internações de doenças respiratórias foram mais evidentes, para todos os períodos analisados, encontram-se principalmente na região denominada “Arco do Povoamento Adensado” (faixa que se estende de sudoeste ao nordeste, abrangendo parte dos Estados de Rondônia, Mato Grosso, Maranhão e parte do Pará) e Amazônia Central. O primeiro padrão de associação local é do tipo Alto-Alto (indicado pela cor

vermelha), ou seja, municípios com elevados valores nas internações de doenças respiratórias estão circundados por municípios que também apresentam alto número de internações.

O outro padrão de associação local do tipo Baixo-Baixo (indicado pela cor azul escuro), ou seja, são municípios com baixos valores no número de internações de doenças respiratórias rodeados por municípios com poucas internações. Alguns desses municípios estão localizados relativamente próximos ao *cluster* Alto-Alto, na porção sudoeste da Amazônia Legal.

Após a identificação de autocorrelação espacial, por intermédio dos resultados obtidos pelo Índice de Moran local, é preciso agora selecionar o modelo econométrico mais adequado. A estratégia sugerida por Anselin (2005) depende dos indicadores que resultam da aplicação do MQO. Dessa maneira, a matriz de ponderação espacial utilizada para confecção do modelo econométrico espacial selecionada, dentre várias testadas, é a do tipo Rainha ou *Queen*.

Os modelos estimados são os relacionados na seção 3.3, a saber: (0) modelo sem correção para dependência espacial, (1) modelo de defasagem espacial (SAR), (2) modelo de erro espacial (SEM), (3) modelo de Durbin espacial (SDM), e (4) modelo de erro espacial e transbordamentos espaciais (SAC).

O modelo (0) sem correção para dependência espacial, considerado o modelo-base, foi estimado por: 1) MQO com os dados combinados (*pooled OLS*); 2) considerando efeitos aleatórios em dados em painel por meio do Mínimos Quadrados Generalizados (MQG); e 3) considerando efeitos fixos por meio do estimador *within*. A Tabela 2 apresenta os resultados obtidos para estas estimações, bem como os resultados para os testes *F* e Hausman.

De acordo com a Tabela 2, o modelo que considera efeitos não observados mostrou-se mais adequado do que o estimado por MQO, isto é, ao não considerar os efeitos não observados, as estimativas por MQO são inconsistentes e enviesadas. Ademais, o modelo de efeitos aleatórios foi comparado ao modelo estimado por efeitos fixos por meio do teste de Hausman. A hipótese nula do teste de que não há diferença sistemática nos coeficientes estimados pelos dois métodos (e, portanto, as estimativas por efeitos aleatórios seriam consistentes), é rejeitada com 1% de significância. Assim, o modelo estimado por efeitos fixos mostrou-se mais adequado do que o modelo de efeitos aleatórios. Além disso, quando comparado com o modelo estimado por MQO, o modelo estimado por efeitos fixos exprime um menor valor para o critério de informação de Akaike (43.393,74 contra 31.704,12, respectivamente), indicando um melhor ajuste deste último modelo.

Em relação aos testes de Breusch-Pagan e Jarque-Bera, importantes para a escolha do modelo, diagnosticou-se que não se aceita a hipótese nula de homocedasticidade e a de que os resíduos não seguem uma distribuição normal, respectivamente. Além disso, para detecção da autocorrelação espacial na regressão, testaram-se os resíduos para autocorreção espacial por meio do I Moran Global da Regressão. Observou-se que ele é significativo a 1%, indicando que há efeitos espaciais nas variáveis de interesse. Desse modo, o uso de modelos espaciais para estudo do fenômeno foi mais adequado.

Portanto, mostrou-se relevante a estimação de modelos com correção para a dependência espacial. Esses modelos serão estimados por ML, considerando os efeitos fixos e espaciais. Além disso, todos os modelos são estimados com a matriz de variância e covariância robustas de White consistentes com heterocedasticidade e autocorrelação.

Mesmo, porém, os modelos MQO e de efeitos apresentando na grande maioria dos coeficientes das variáveis explicativas significantes, a escolha ideal parte para a estimação dos parâmetros do modelo econométrico espacial pelo método de defasagem espacial ou erro espacial.

A Tabela 3 contém os resultados das estimações de (1) modelo de defasagem espacial (SAR), (2) modelo de erro espacial (SEM), (3) modelo de Durbin espacial (SDM) e (4) modelo de erro espacial e transbordamentos espaciais (SAC).

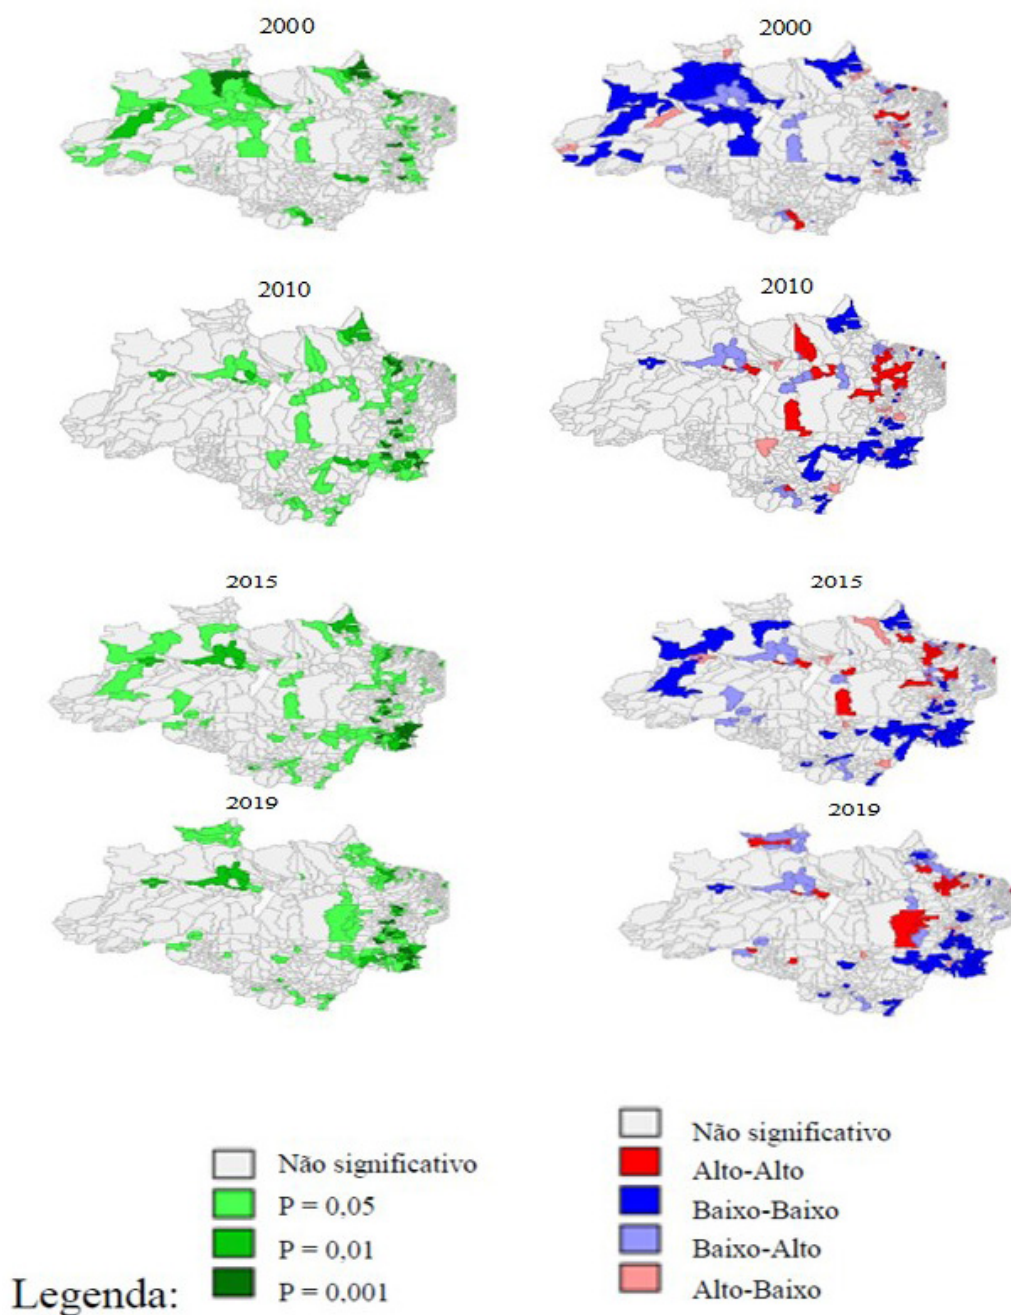


Figura 2 – Mapas de significância LISA e mapas de *clusters* para as internações de doenças respiratórias anuais dos municípios da Amazônia Legal, 2000-2019*.

Fonte: Elaborada pelos autores, com base nos dados citados na seção 3.2 (2022).

Nota: *A seleção de 5 anos foi adotada para resumir o período de tempo analisado de 2000 a 2019.

Primeiramente, pelos testes de Hausman na Tabela 3, sobrou rejeitada a hipótese nula, ou seja, sendo modelos de efeitos fixos mais adequados do que os modelos de efeitos aleatórios. Desse modo, não são mostrados esses últimos.

Tabela 2 – Resultados dos modelos estimados para a Amazônia Legal (sem correção para dependência espacial), 2000-2019

Variável dependente: LnDOENÇA	Modelo MQO	Modelo de efeitos aleatórios	Modelo de efeitos fixos
zDESM	0,0652***	0,0527***	0,0254***
lnFLO	0,145***	0,203***	0,423***
DPOP	0,276***	0,254***	0,0963***
IND	0,443***	0,181***	0,0478***
lnPIB <i>per capita</i>	-0,753***	-0,271***	-0,148***
URBAN	-0,0007	0,0042***	0,0026**
lnK/L	-0,0995***	-0,0560***	-0,0461***
TEMP	-0,0512***	-0,0881***	-0,116***
lnPRECIP	0,0415	-0,0668	-0,182***
lnEMISSAO	0,0798***	0,0170***	0,0035
lnCR	0,141***	0,0380***	0,0166***
lnGASTOTRAN	0,0364***	0,0113***	-0,0005
Const	4,441***	5,584***	6,598***
Prob>F	0,0000	0,0000	0,0000
I Moran Global da regressão	5,1842***	3,2179***	3,0309***
Breusch-Pagan	9.216,1***	5.982,2***	5.704,4***
Jarque-Bera	518,42***	4.951,8***	6.885,3***
R ²	0,5813		
R ² ajustado	0,581		
AIC	43.393,74	31.984,81	31.704,12
Teste de Hausman			1.589,2***

Fonte: Elaborada pelos autores, com base nos dados citados na seção 3.2 (2022).

Nota: * p -valor <0,10; ** p -valor <0,05; *** p -valor <0,01.

O modelo (1) de defasagem espacial exprime como significativos os coeficientes das variáveis densidade populacional, relação K/L, precipitação e crédito rural. O ajuste do modelo denota melhora em relação ao modelo-base, pois mostra um menor valor para o critério de informação de Akaike (28.662,17 < 31.704,12). Ademais, o coeficiente de defasagem espacial ρ se exprimiu como significativo. Assim, indicou a ausência de autocorrelação espacial, mostrando que a inclusão da variável defasada espacialmente foi suficiente para a correção da dependência espacial.

O modelo (2), de erro espacial, traz coeficientes das variáveis significativas: densidade populacional, IND, relação K/L, e crédito rural. Além disso, o parâmetro (λ) relativo ao erro espacial tem sinal positivo e significante. O valor do AIC para este modelo é inferior ao encontrado para o modelo-base (28.692,98 e 31.704,12, respectivamente), indicando um melhor ajustamento dos dados proporcionado pelo modelo de erro espacial.

O modelo (3), modelo de Durbin espacial, apresenta coeficientes significativos: área de floresta, densidade populacional, relação K/L, e crédito rural. Além disso, são significativos os coeficientes das variáveis defasadas espacialmente: desmatamento, área de floresta, emissão e crédito rural, indicando transbordamentos espaciais. O coeficiente de defasagem espacial, ρ , é significativo. O valor de AIC encontrado (28.532,07) foi mais baixo do que o modelo-base de efeitos fixos.

Por fim, o modelo (4), de erro espacial e transbordamentos espaciais, expressa coeficientes significativos: desmatamento, densidade populacional, relação K/L, precipitação, emissão e crédito rural. Além disso, o parâmetro λ do termo de erro espacial e o coeficiente de defasagem

espacial, ρ , são significativos, sendo negativo e positivo, respectivamente. O valor do AIC é o menor entre todos os modelos para os quais este critério de informação foi calculado (28.470,53).

Tabela 3 – Resultados dos modelos estimados para a Amazônia Legal (com correção para dependência espacial), 2000-2019

Variável dependente: lnDOENÇA	Modelo (1)	Modelo (2)	Modelo (3)	Modelo (4)
	SAR	SEM	SDM	SAC
zDESM	0,0182	0,00846	-0,00612	0,0171*
lnFLO	0,148	0,0184	-0,426*	0,136
DPOP	0,107***	0,0993***	0,101***	0,0892***
IND	0,0338	0,0398*	0,0353	0,0248
lnPIB <i>per capita</i>	-0,0728	-0,0802	-0,0612	-0,0538
URBAN	0,0024	0,0020	0,0017	0,0022
lnK/L	-0,0384***	-0,0348***	-0,0337***	-0,0349***
TEMP	-0,0206	-0,0259	-0,0236	-0,0122
lnPRECIP	-0,101*	-0,119	-0,0599	-0,0705*
lnEMISSAO	0,0180	0,0123	0,0111	0,0177*
lnCR	0,0220**	0,0285***	0,0352***	0,0167*
lnGASTOTRAN	-0,0033	-0,0034	-0,0040	-0,0026
WzDESM			0,0536***	
WlnFLO			1,141***	
WDPOP			0,0453	
WIND			-0,0200	
WlnPIB <i>per capita</i>			-0,0206	
WURBAN			0,00548	
WlnK/L			-0,0230	
WTEMP			0,00500	
WlnPRECIP			-0,0797	
WlnEMISSAO			0,0580**	
WlnCR			-0,0474***	
WlnGASTOTRAN			0,000569	
P	0,394***		0,377***	0,694***
λ		0,397***		-0,502***
Observações	15.440	15.440	15.440	15.440
AIC	28.662,17	28.692,98	28.532,07	28.470,53
Teste de Hausman	458,67***	592,22***	261,17***	539,84***

Fonte: Elaborada pelos autores, com base nos dados citados na seção 3.2 (2022).

Nota: * p -valor <0,10; ** p -valor <0,05; *** p -valor <0,01.

O desafio agora é a seleção do modelo mais adequado. Para isso, seguiu-se a estratégia descrita em LeSage & Pace (2009) e Elhorst (2010). A investigação deve-se iniciar como o modelo SDM e testá-lo com modelos alternativos. Ou seja, estima-se o modelo SDM, e testa-o para saber se ele é ou não o melhor modelo para ser utilizado.

De início, testaram-se as especificações entre os modelos SDM com os modelos SAR e SEM. Isto porque o modelo SDM é facilmente derivado a partir de um SEM, isto é, se $\lambda = 0$ e $\rho \neq 0$, o modelo é um SAR, enquanto, se $\lambda = -\beta\rho$, o modelo é um SEM. Após a estimativa do SDM, são realizados testes Wald explorando o vetor de coeficientes estimados. Os resultados desses testes estão na Tabela 4.

Tabela 4 – Testes Wald para seleção do modelo espacial, Amazônia Legal, 2000-2019

Comparações	χ^2	P-valor	AIC
SDM x SAR	30,78	0,0021	-
SDM x SEM	34,97	0,0005	-
SDM x SAC	-	-	(28.532,07 > 28.470,53)

Fonte: Elaborada pelos autores, com base nos dados citados na seção 3.2 (2022).

Na comparação entre os modelos SDM x SAR, com p-valor ($\text{Prob} > \chi^2 = 0,0021$), rejeitou-se a hipótese nula, isto é, o modelo SDM é mais adequado. Do mesmo modo, ao se comparar os modelos SDM X SEM, o p-valor ($\text{Prob} > \chi^2 = 0,0005$), rejeitou-se a hipótese nula, isto é, o modelo SDM, também foi o mais adequado.

Por fim, ainda na Tabela 4, ao se comparar com o modelo SAC, deve-se observar os resultados dos testes de Critério de Informação de Akaike (AIC). Como resultado, o modelo SAC apresentou AIC igual a 28.470,53, sendo inferior ao AIC do modelo SDM (28.532,07). Portanto, o modelo mais adequado identificado foi o SAC.

Com a seleção do modelo 4 (SAC) mais adequado, na Tabela 3, foi identificada a existência de fortes interações espaciais nas interações por doenças respiratórias. Ou seja, o fenômeno modelado neste estudo requer que a dependência espacial seja manifestada tanto na forma de defasagem da variável dependente, quanto no formato de erros autocorrelacionados espacialmente. O parâmetro de defasagem espacial (ρ) é significativo e positivo, indicando que as interações por doenças respiratórias, em determinado município, são influenciadas diretamente pelas interações nos municípios vizinhos. Por outro lado, o termo do erro auto-regressivo espacial (λ), negativo e significativo, indica que efeitos não modelados denotam uma autocorrelação espacial negativa, isto é, efeitos desconhecidos reduzem as interações por doenças respiratórias em determinado município, influenciadas pelos municípios vizinhos.

Em relação à DESM, como indicador que influencia as interações por doenças respiratórias, observou-se que seu efeito foi positivo. Isto é, seu incremento aumenta o número de interações (DOENÇA). Desse modo, o desmatamento torna-se muito útil para a avaliação do avanço das atividades agrossilvipastoris, da ocupação do homem e seu poder de artificialização do meio ambiente em geral. Somam-se, ainda, os significativos focos de incêndios na região. Assim, além dos efeitos para o bioma amazônico, o desmatamento e as queimadas têm impactos diretos e indiretos sobre a saúde humana, afetando de forma especialmente severa a saúde das populações da Amazônia (Hacon et al., 2021).

Em relação às variáveis demográficas que influenciam as interações por doenças respiratórias, a densidade populacional, DPOP, apontou efeito positivo. Nesse sentido, supondo aumento na densidade populacional, haverá incremento nas interações de doenças respiratórias. Ao contrário de Rupasingha et al. (2004), o incremento da densidade demográfica estaria relacionado a menores níveis de degradação ambiental. Isto talvez se deva ao nível de densidade demográfica, pois a Amazônia expressa valores populacionais menores ao se comparar com área de estudo dele nos Estados Unidos. Nesse caso, o incremento populacional exigiria mais recursos florestais. Assim, esse efeito também foi observado em Perz & Skole (2003) e Rudel et al. (2005).

Em relação às variáveis econômicas que influenciam as interações por doenças respiratórias, a razão capital por trabalho, K/L, exprimiu efeito negativo. Isto é, aumentando-se a razão capital-trabalho, serão reduzidas as interações. Nessa perspectiva, o incremento do capital conduz à criação de empregos com melhor remuneração em setores não agrícolas, o que contribui para menos desmatamento com trabalhadores e agricultores abandonando a agricultura em favor

de salários mais estáveis em outros setores, como serviço ou indústria. O efeito do capital e da produção é consistente com a literatura econômica (Klooster, 2003; Mather, 2004).

As emissões de GEE residenciais, industriais e de transportes apresentaram efeitos positivos, isto é, supondo um aumento na emissão de gases, eleva as internações por doenças respiratórias. Nesse sentido, a poluição ambiental é causada pelo consumo de combustíveis fósseis, como carvão, petróleo, gás natural etc. Assim, observou-se a existência de uma relação positiva e significativa entre o consumo de energia e os níveis de poluição, e, conseqüentemente, no número de internações. Essa relação na literatura registrou resultados positivos ou negativos (Qin & Yu, 2016; Instituto Ambiental do Paraná, 2020).

Já a variável precipitação relatou efeitos negativos, isto é, supondo um aumento no volume de chuvas reduz as internações por doenças respiratórias. Esse fato é coerente com o ciclo das queimadas na Amazônia, que é observado no período de seca (de julho a outubro, com pico em setembro), com graves impactos sociais, ambientais, e, principalmente, na saúde humana (Hacon et al., 2021).

Em relação ao crédito rural, observou-se efeito positivo, isto é, supondo um aumento na concessão de crédito rural, elevam-se as internações por doenças respiratórias. De acordo com Assunção et al. (2020), há evidências dos efeitos do crédito rural sobre o desmatamento da Amazônia brasileira. Os autores identificaram que a mudança na política (retrição ao crédito rural) promoveu uma redução substancial do desmatamento, principalmente em municípios que têm a pecuária como principal atividade.

Os modelos de regressão espacial exploram a complicada estrutura de dependência entre unidades. O efeito da mudança de uma variável explicativa para uma unidade específica afetará a unidade em si e, potencialmente, em todas as outras unidades, indiretamente. Isso revela a existência de efeitos marginais diretos, indiretos e totais.

O efeito marginal das internações por doenças respiratórias difere entre os municípios como resultado de interações espaciais. A principal diferença entre os impactos diretos e totais é que o primeiro mede o impacto da variação de uma unidade na variável X_k no município i . Em contraste, o impacto total mede o impacto da mesma mudança unitária na variável X_k em todos os municípios. A Tabela 5 indica os efeitos marginais de longo prazo direto, indiretos e totais. Desse modo, essas interações produzidas por *spillovers* globais levam a um cenário onde mudanças em uma região acionam uma sequência de ajustes em todas as demais regiões da amostra, em que um novo estado estacionário de longo prazo é definido.

Na Tabela 5, observou-se que a variável desmatamento mostrou um efeito positivo na variável internações por doenças respiratórias, com impacto maior nos efeitos indiretos (0,04), enquanto o efeito realimentador direto impacta nos seus municípios vizinhos (0,02). Os resultados apontados destacaram a relação positiva dos efeitos das variáveis densidade populacional, emissão e crédito rural. Isto é, essas variáveis geram efeitos no próprio município e nos vizinhos, ampliando o número de internações por doenças respiratórias, sendo, nesse caso, o efeito indireto maior do que o efeito direto. Em relação às variáveis relação capital-trabalho e precipitação, estas exibiram efeitos negativos, isto é, reduzem as internações tanto no mesmo município quanto em municípios vizinhos, e também foi verificado que os efeitos indiretos são maiores do que os diretos.

Esta é considerada a primeira análise que mostra a correlação das internações por doenças respiratórias com o maior número de variáveis possíveis, para todos os municípios na área da Amazônia Legal, no Brasil. Geralmente, a maioria das pesquisas concentra-se na análise de recortes espaciais 'isolados', por exemplo, estados, municípios, terras indígenas ou Unidades de Conservação (Spektor et al., 1991; Cançado et al., 2006; Braga et al., 2007; Ignotti et al., 2007; Rosa et al., 2008; Mascarenhas et al., 2008).

Tabela 5 – Resultados da mensuração dos impactos do modelo SAC estimado para a Amazônia Legal, 2000-2019

Variável dependente: LnDOENÇA	Coefficientes	Erros Padrões Robustos	Z	P > z
Efeitos diretos Longo Prazo				
zDESM	0,0200*	0,0106	1,890	0,0590
lnFLO	0,150	0,145	1,030	0,302
DPOP	0,104***	0,0349	2,990	0,0030
IND	0,0286	0,0194	1,470	0,140
lnPIB <i>per capita</i>	-0,0597	0,0398	-1,500	0,133
URBAN	0,0025	0,0024	1,040	0,300
lnK/L	-0,0402***	0,0088	-4,550	0,0000
TEMP	-0,0124	0,0178	-0,690	0,489
lnPRECIP	-0,0764*	0,0438	-1,740	0,0810
lnEMISSAO	0,0198*	0,0118	1,670	0,0950
lnCR	0,0197*	0,0105	1,870	0,0620
lnGASTOTRAN	-0,0033	0,0058	-0,570	0,568
Efeitos indiretos Longo Prazo				
zDESM	0,0377*	0,0208	1,810	0,0700
lnFLO	0,285	0,280	1,020	0,309
DPOP	0,194***	0,0664	2,930	0,0030
IND	0,0530	0,0361	1,470	0,142
lnPIB <i>per capita</i>	-0,111	0,0746	-1,480	0,138
URBAN	0,0048	0,0047	1,020	0,306
lnK/L	-0,0749***	0,0168	-4,450	0,0000
TEMP	-0,0229	0,0331	-0,690	0,490
lnPRECIP	-0,142*	0,0817	-1,730	0,0830
lnEMISSAO	0,0392*	0,0229	1,650	0,099
lnCR	0,0365*	0,0194	1,880	0,0600
lnGASTOTRAN	-0,0063	0,0110	-0,570	0,568
Efeitos totais Longo Prazo				
zDESM	0,0577*	0,0313	1,850	0,0650
lnFLO	0,435	0,424	1,020	0,306
DPOP	0,299***	0,100	2,980	0,0030
IND	0,0816	0,0553	1,480	0,140
lnPIB <i>per capita</i>	-0,171	0,114	-1,500	0,135
URBAN	0,0073	0,0071	1,030	0,303
lnK/L	-0,115***	0,0251	-4,590	0,0000
TEMP	-0,0352	0,0509	-0,690	0,489
lnPRECIP	-0,218*	0,125	-1,740	0,0810
lnEMISSAO	0,0569*	0,0346	1,650	0,0950
lnCR	0,0561*	0,0298	1,880	0,0600
lnGASTOTRAN	-0,0096	0,0168	-0,570	0,568

Fonte: Elaboração própria, com base nos dados citados na seção 3.3.2 (2022).

Nota: * *p*-valor <0,10; ** *p*-valor <0,05; *** *p*-valor <0,01.

Conforme descrito anteriormente, foram encontradas evidências robustas de que as internações por doenças respiratórias respondem às mudanças, principalmente negativas, relacionadas às variáveis razão capital-trabalho e precipitação, e positivas, com desmatamento, densidade populacional, emissão GEE e crédito rural.

Os resultados obtidos por meio do Mapa LISA indicaram o agrupamento de áreas desmatadas na região sul da Amazônia Legal. Esta área coincide com os estados que ocupam o topo da lista daqueles com as áreas mais desmatadas da Amazônia, Pará (34,46%), Mato Grosso (32,34%) e Rondônia (13,76%) (Instituto Nacional de Pesquisas Espaciais, 2021). Além disso, essa região está compreendida na área comumente chamada de “arco do desmatamento”. (Fearnside, 2017; Oliveira et al., 2019). Ademais, segundo Fearnside (2017), aproximadamente 80% da perda de floresta na Amazônia brasileira ocorreu no “arco do desmatamento”, que é uma faixa em forma de meia-lua ao longo das bordas sudoeste da floresta.

Na Amazônia, vários estudos analisaram os custos da poluição para o sistema de saúde e os impactos desta na saúde humana, principalmente em crianças e idosos (Rosa et al., 2008; Jacobson et al., 2014; Machin et al., 2019; Human Rights Watch, 2020). Em outras palavras, os resultados aqui encontrados reforçam que é necessária uma política voltada para a contenção do desmatamento, principalmente na área denominada **arco do desmatamento**, pois, com isso, melhorariam as condições ambientais e, conseqüentemente, a saúde humana.

Testaram-se os resultados para o modelo MQO; no entanto, a suposição de que os resíduos eram independentes não foi satisfeita. Além disso, foram identificados efeitos espaciais, e, para preencher esta lacuna, os modelos espaciais foram usados.

Desse modo, o modelo espacial utilizado (SAC) apontou que os efeitos de transbordamento espacial afetam as internações por doenças respiratórias em consequência das variações nas variáveis explicativas. A estimativa empírica fornece evidências significativas de interdependência espaço-temporal nas internações. As variáveis desmatamento, densidade populacional, razão capital-trabalho, precipitação, emissão e crédito rural determinam significativamente o número de internações; no entanto, o “espaço” desempenha um papel moderador para a promoção do real efeito dessas variáveis. Assim, um importante resultado encontrado reside no fato de que desconsiderar efeitos de transbordamento espacial leva a uma superestimação dos efeitos reais das variáveis explicativas. Como resultado, na ausência do componente ‘espaço’, conduz a uma estimativa inconsistente das internações por doenças respiratórias ao longo do tempo analisado. Além disso, as evidências dos efeitos espaciais significativos encontrados aqui, tanto diretos como indiretos e totais, estão a favor das descobertas atuais das internações por doenças respiratórias. E, por fim, identificaram-se fatores desconhecidos que contribuem para a redução das internações. Esta pesquisa é passível de ser vista como primeiro passo para a identificação de condicionantes do número de internações por doenças respiratórias.

Os resultados deste estudo evidenciam o impacto à saúde e a perda da qualidade de vida e bem-estar das populações amazônicas, sem levar em consideração o elevado impacto econômico das doenças respiratórias para o SUS, que, de acordo com Hacon et al. (2021), é próximo de um bilhão de reais gastos na última década (2010-2020) nessa região.

Além disso, a exposição a partículas em suspensão no ar é um importante fator de risco para o adoecimento e morte por doenças respiratórias, com aumento da mortalidade geral de indivíduos com comorbidades, mortes prematuras e baixo peso ao nascer (Ortega-García et al., 2018), câncer de pulmão, doença cardíaca, infarto do miocárdio e acidente vascular cerebral (Uzoigwe et al., 2013; Dong et al., 2018), mais recentemente, Diabetes do tipo 2 (Anghorbani et al., 2014; Sun & Zhu, 2019), e perda da função cognitiva. Nenhum desses agravantes não respiratórios foi analisado neste estudo. Dessa maneira, o elevado custo financeiro do Estado com hospitalizações de baixa e alta complexidade por doenças do aparelho respiratório representa uma pequena parcela dos impactos à saúde, sociais e econômicos, decorrentes da poluição do ar na Amazônia brasileira.

5 CONCLUSÕES

Este artigo investigou os condicionantes das internações por doenças respiratórias para a região da Amazônia Legal, isto é, se o conjunto de variáveis explicativas selecionados tem algum tipo de relação com a variável dependente. O estudo abrange o período de 2000 a 2019.

A literatura apontou a importância das diferenças inter-regionais para a compreensão do processo de desenvolvimento da Região Amazônica, isto é, a importância de sua heterogeneidade, e reforça a ideia de que as internações por doenças respiratórias não se processam de maneira igual no espaço, além disso, impactam no complexo comportamento das variáveis socioeconômicas, ambientais etc. Este artigo contribuiu com uma análise econométrico-espacial, utilizando um painel de dados mais extenso do que os de estudos anteriores, além de tratar a heterogeneidade espacial dos parâmetros por meio de modelos espaciais.

A Análise Exploratória de Dados Espaciais (AEDE) mostrou autocorrelação espacial global para as internações por doenças respiratórias na região, em um padrão de concentração. A AEDE indicou a existência de *clusters* do tipo Alto-Alto em parte do Arco do Desmatamento e parte da Amazônia Central. Outros pequenos *clusters* com diferentes padrões de associação foram observados.

A análise econométrica parte de um modelo global para as internações por doenças respiratórias, tendo se iniciado ignorando os efeitos espaciais, de sorte que a estimação por efeitos fixos mostrou-se a mais apropriada. Posteriormente, considerando os efeitos espaciais, vários modelos espaciais foram estimados alternativamente, e o que melhor se ajustou aos dados (com base no menor valor de AIC) foi o modelo SAC, após seguir todos os procedimentos-padrão da literatura.

Neste último, verificou-se que as internações por doenças respiratórias foram explicadas pelas variáveis independentes desmatamento, densidade populacional, emissão de GEE e crédito rural, com coeficientes positivos, enquanto razão capital-trabalho e precipitação foram negativos. Além disso, observou-se que outros fatores desconhecidos impactam negativamente as internações. Por fim, foram exibidos esses efeitos de maneira direta e indireta, e constatou-se que a presença dos municípios vizinhos se mostrou significativa.

Por fim, a não estimação de diferentes métodos como o GMM system ou considerando variáveis instrumentais podem ser reveladas como a principal limitação desse estudo. A aplicação dessas técnicas permite um melhor controle de endogeneidade em função da defasagem espacial da variável dependente (modelos SAR e SDM). Portanto, sugere-se em pesquisas futuras a aplicação dos mesmos para apoiar os resultados aqui encontrados e torna-nos mais robustos.

Concluindo, este artigo contribui para a compreensão das internações por doenças respiratórias na Amazônia Legal como um processo heterogêneo no espaço. As relações encontradas são desigualmente distribuídas na Região. A metodologia adotada mostrou-se especialmente adequada para captar os aspectos espaciais envolvidos nessa relação. Por fim, acredita-se que os estudos e políticas para a Amazônia brasileira devam considerar, sobretudo, estas diferenças intra-regionais.

REFERÊNCIAS

- Almeida, E. (2012). *Econometria espacial aplicada*. Campinas: Alínea.
- Alves, L. (2020). Surge of respiratory illnesses in children due to fires in Brazil's Amazon region. *The Lancet. Respiratory Medicine*, 8(1), 21-22.
- Andrade, M. F., Kumar, P., Freitas, E. D., Ynoue, R. Y., Martins, J., Martins, L. D., Nogueira, T., Perez-Martinez, P., Miranda, R. M., Albuquerque, T., Gonçalves, F. L. T., Oyama, B., & Zhang, Y. (2017). Air quality in the megacity of São Paulo: evolution over the last 30 years and future perspectives. *Atmospheric Environment*, 159, 66-82.

- André, P. A., Veras, M. M., Miraglia, S. G. K., & Saldiva, E. P. H. N. (2012). Lean diesel technology and human health: a case study in six Brazilian metropolitan regions. *Clinics*, 67(6), 639-645.
- Anghorbani, M., Momeni, F., & Mansourian, M. (2014). Systematic review and metaanalysis of air pollution exposure and risk of diabetes. *European Journal of Epidemiology*, 29(4), 231-242.
- Anselin, L. (1988). *Spatial econometrics: methods and models*. Dordrecht: Kluwer Academic Publishers.
- Anselin, L. (2005). *Exploring spatial data with GeoDa: a workbook*. Centre for Spatially Integrated Social Science.
- Anselin, L. (2013). *Spatial econometrics: methods and models*. Dordrecht: Springer Science & Business Media.
- Arbex, M. A., Pereira, L. A., Carvalho-Oliveira, R., Saldiva, P. H., & Braga, A. L. (2014). The effect of air pollution on pneumonia-related emergency department visits in a region of extensive sugar cane plantations: a 30-month time-series study. *Journal of Epidemiology and Community Health*, 68(7), 669-674.
- Artaxo, P., Rizzo, L. V., Brito, J. F., Barbosa, H. M. J., Arana, A., Sena, E. T., Cirino, G. G., Bastos, W., Martin, S. T., & Andreae, M. O. (2013). Atmospheric aerosols in Amazonia and land use change: from natural biogenic to biomass burning conditions. *Faraday Discussions*, 165, 203-235.
- Assunção, J., Gandour, C., Rocha, R., & Rocha, R. (2020). The effect of rural credit on deforestation: evidence from the Brazilian Amazon. *Economic Journal*, 130(626), 290-330.
- Belotti, F., Hughes, G., & Mortari, A. P. (2017). Spatial panel data models using Stata. *The Stata Journal*, 17(1), 139-180.
- Böhm, G. M., Saldiva, P. H. N., Pasqualucci, C. A. G., Massad, E., Martins, M. A., Zin, W. A., Cardoso, W. V., Criado, P. M. P., Komatsuzaki, M., Sakae, R. S., Negri, E. M., Lemos, M., Capelozzi, V. M., Crestana, C., & Silva, R. (1989). Biological effects of air pollution in São Paulo and Cubatão. *Environmental Research*, 49(2), 208-216.
- Braga, A. L. F., Pereira, L. A. A., Procópio, M., André, P. A., & Saldiva, P. H. N. (2007). Associação entre poluição atmosférica e doenças respiratórias e cardiovasculares na cidade de Itabira, Minas Gerais, Brasil. *Cadernos de Saude Publica*, 23(4, Suppl. 4), S570-S578.
- Brasil. Ministério da Economia. Relação Anual de Informações Sociais – RAIS. (2020). *Cadastro geral de empregados e desempregados*. Brasília. Recuperado em 13 de outubro de 2020, de <http://www.rais.gov.br>
- Brasil. Ministério da Saúde. Departamento de Informação e Informática do Sistema Único de Saúde – DATASUS. (2022). *Sistema de Informações Hospitalares do SUS (SIH/SUS), CID-10*. Brasília. Recuperado em 20 de janeiro de 2022, de www.datasus.gov.br
- Cançado, J. E. D., Saldiva, P. H. N., Pereira, L. A. A., Lara, L. B. L. S., Artaxo, P., Martinelli, L. A., Arbex, M. A., Zanobetti, A., & Braga, A. L. F. (2006). The impact of sugar cane-burning emissions on the respiratory system of children and the elderly. *Environmental Health Perspectives*, 114(5), 725-729.
- Carmo, C. N., & Hacon, S. (2013). Estudos de séries temporais de poluição atmosférica por queimadas e saúde humana. *Ciência & Saúde Coletiva*, 18(11), 3245-3258.
- Carmo, C. N., Hacon, S., Freitas, K. M. L., & Freitas, S. R. (2010). Associação entre material particulado de queimadas e doenças respiratórias na região sul da Amazônia brasileira. *Revista Panamericana de Salud Pública*, 27(1), 10-16.

- Dong, H., Yu, Y., Yao, S., Lu, Y., Chen, Z., Li, G., Yao, Y., Yao, X., Wang, S.-L., & Zhang, Z. (2018). Acute effects of air pollution on ischaemic stroke onset and deaths: a time-series study in Changzhou, China. *BMJ Open*, 8(7), e020425.
- Elhorst, J. P. (2010). Applied spatial econometrics: raising the bar. *Spatial Economic Analysis*, 5(1), 9-28.
- Fearnside, P. M. (2017). Deforestation of the Brazilian Amazon. In H. Shugart (Ed.), *Oxford Research Encyclopedia of Environmental Science*. New York: Oxford University Press.
- Field, R. D., & Shen, S. S. P. (2008). Predictability of carbon emissions from biomass burning in Indonesia from 1997 to 2006. *Journal of Geophysical Research*, 113(G4), 2008JG000694.
- Fried, J. S., Torn, M. S., & Mills, E. (2004). The impact of climate change on wild fire severity: a regional forecast for northern California. *Climatic Change*, 64(1-2), 169-191.
- Hacon, S. S., Gonçalves, K. S., Barcellos, C., & Oliveira-da-Costa, M. (2021). *Amazônia brasileira: potenciais impactos das queimadas sobre a saúde humana no contexto da expansão da Covid-19* (Nota Técnica). FIOCRUZ, WWF-Brasil.
- Human Rights Watch – HRW. Instituto de Estudos para Políticas de Saúde – IEPS. Instituto de Pesquisa Ambiental da Amazônia – IPAM. (2020). *O ar é insuportável: os impactos das queimadas associadas ao desmatamento da Amazônia brasileira na saúde*. Recuperado em 30 de dezembro de 2021, de https://ipam.org.br/wp-content/uploads/2020/08/brazil0820pt_web.pdf
- Ignotti, E., Hacon, S. S., Junger, W. L., Mourão, D., Longo, K., Freitas, S., Artaxo, P., & Leon, A. C. M. P. (2010). Air pollution and hospital admissions for respiratory diseases in the subequatorial Amazon: a time series approach. *Cadernos de Saúde Pública*, 26(4), 747-761.
- Ignotti, E., Hacon, S. S., Silva, A. M. C., Junger, W. L., & Castro, H. (2007). Efeitos das queimadas na Amazônia: método de seleção dos municípios segundo indicadores de saúde. *Revista Brasileira de Epidemiologia*, 10(4), 453-464.
- Instituto Nacional de Pesquisas Espaciais – INPE. TerraBrasilis. (2021). *Taxas de desmatamento Amazônia Legal: estados*. Recuperado em 20 de março de 2021, de http://terrabrasilis.dpi.inpe/app/dashboard/deforestation/biomes/legal_amazon/rates
- Instituto Nacional de Pesquisas Espaciais – INPE. (2022). *Projeto Prodes 2022: monitoramento da floresta amazônica brasileira por satélite*. Recuperado em 19 de março de 2022, de <http://www.obt.inpe.br/prodes/index.php>
- Instituto Ambiental do Paraná – IAP. (2020). *Projeto gestão de qualidade do ar*. Recuperado em 30 de dezembro de 2021, de <http://www.iap.pr.gov.br/modules/conteudo/conteudo.php?conteudo=92>
- Instituto Brasileiro de Geografia e Estatística – IBGE. (2012). *Indicadores de desenvolvimento sustentável* (Estudos e Pesquisas: Informação Geográfica, No. 9). Rio de Janeiro. Recuperado em 30 de setembro de 2021, de http://geoftp.ibge.gov.br/documentos/recursos_naturais/indicadores_desenvolvimento_sustentavel/2012/ids2012.pdf
- Instituto Brasileiro de Geografia e Estatística – IBGE. (2018). *Contas econômicas ambientais*. Rio de Janeiro: IBGE.
- Instituto Brasileiro de Geografia e Estatística – IBGE. (2022). *Censo 2010*. Rio de Janeiro: IBGE.
- IpeaData. (2022). *Base de dados macroeconômicos, financeiros e regionais do Brasil*. Recuperado em 17 de outubro de 2021, de <http://renastonline.ensp.fiocruz.br/recursos/ipeadata-base-dados-macroeconomicos-financeiros-regionais-brasil>

- Jacobs, J., Kreutzer, R., & Smith, D. (1997). Rice burning and asthma hospitalizations, Butte County, California, 1983-1992. *Environmental Health Perspectives*, *105*(9), 980-985.
- Jacobson, L. S. V., Hacon, S. S., Castro, H. A., Ignotti, E., Artaxo, P., Saldiva, P. H. N., & Leon, A. C. M. P. (2014). Acute effects of particulate matter and black carbon from seasonal fires on peak expiratory flow of school children in the Brazilian Amazon. *PLoS One*, *9*(8), e104177.
- Klooster, D. (2003). Forest transitions in Mexico: institutions and forests in a globalized countryside. *The Professional Geographer*, *55*(2), 227-237. <http://doi.org/10.1111/0033-0124.5502010>.
- LeSage, J., & Pace, R. K. (2009). *Introduction to spatial econometrics*. New York: CRC Press.
- Machin, A. B., Nascimento, L. F., Mantovani, K., & Machin, E. B. (2019). Effects of exposure to fine particulate matter in elderly hospitalizations due to respiratory diseases in the South of the Brazilian Amazon. *Brazilian Journal of Medical and Biological Research*, *52*(2), e8130.
- Mascarenhas, M. D. M., Vieira, L. C., Lanzieri, T. M., Leal, A. P. P. R., Duarte, A. F., & Hatch, D. L. (2008). Poluição atmosférica devido à queima de biomassa florestal e atendimentos de emergência por doença respiratória em Rio Branco, Brasil – setembro, 2005. *Jornal Brasileiro de Pneumologia*, *34*(1), 42.
- Mather, A. S. (2004). Forest transition theory and the reforestation of Scotland. *Scottish Geographical Journal*, *120*(1-2), 83-98.
- Mott, J. A., Mannino, D. M., Alverson, C. J., Kiyu, A., Hashim, J., Lee, T., Falter, K., & Redd, S. C. (2005). Cardiorespiratory hospitalizations associated with smoke exposure during the 1997, Southeast Asian forest fires. *International Journal of Hygiene and Environmental Health*, *208*(1-2), 75-85.
- National Aeronautics and Space Administration – NASA. (2022). *POWER data access viewer: prediction of worldwide energy resources*. Recuperado em 13 de janeiro de 2022, de <https://power.larc.nasa.gov/data-access-viewer/>
- Observatório do Clima. Sistema de Estimativas de Emissões e Remoções de Gases de Efeito Estufa – SEEG. (2019). *Análise das emissões brasileiras de gases de efeito estufa e suas implicações para as metas do Brasil*. Observatório do Clima.
- Observatório do Clima. Sistema de Estimativas de Emissões e Remoções de Gases de Efeito Estufa – SEEG. (2022). *Plataforma SEEG*. Recuperado em 23 de janeiro de 2022, de <http://seeg.eco.br>
- Oliveira, P. C. S. S., Santos, A. M., & Ferreira, N. C. (2019). Modelagem dinâmica do desmatamento no sul da Amazônia Ocidental. *Boletín Geográfico*, *37*(3), 188-206.
- Oliveira, R. C., Almeida, E., Freguglia, R. S., & Barreto, R. C. S. (2011). Desmatamento e crescimento econômico no Brasil: uma análise da curva de Kuznets ambiental para a Amazônia Legal. *Revista de Economia e Sociologia Rural*, *49*(3), 709-739.
- Ortega-García, J. A., Sánchez-Solís, M., & Ferrís-Tortajada, J. (2018). Contaminación atmosférica y salud de los niños. *Anales de Pediatría*, *89*(2), 77-79.
- Perz, S., & Skole, D. (2003). Secondary forest expansion in the Brazilian Amazon and the refinement of forest transition theory. *Society & Natural Resources*, *16*(4), 277-294.
- Qin, X., & Yu, W. (2016). Foreign direct investment, economic growth and environmental pollution: an empirical study based on spatial panel data of 259 prefecture-level cities in China. *Macroeconomy Research*, *36*, 99-103.

- Reddington, C. L., Butt, E. W., Ridley, D. A., Artaxo, P., Morgan, W. T., Coe, H., & Spracklen, D. V. (2015). Air quality and human health improvements from reductions in deforestation-related fire in Brazil. *Nature Geoscience*, *8*(10), 768-771.
- Rosa, A. M., Ignotti, E., Hacon, S. S., & Castro, H. A. (2008). Analysis of hospitalizations for respiratory diseases in Tangará da Serra, Brazil. *Jornal Brasileiro de Pneumologia*, *34*, 575-582.
- Rudel, T. K., Coomes, O. T., Moran, E., Achard, F., Angelson, A., Xu, J., & Lambin, E. (2005). Forest transitions: towards a global understanding of land use change. *Global Environmental Change*, *15*(1), 23-31.
- Rupasingha, A., Goetz, S. J., Debertin, D. L., & Pagoulatos, A. (2004). The environmental Kuznets curve for US counties: a spatial econometric analysis with extensions. *Papers in Regional Science*, *83*(2), 407-424.
- Saldiva, P. H. N., Pope III, C. A., Schwartz, J., Dockery, D. W., Lichtenfels, A. J., Salge, J. M., Barone, I., & Bohm, G. M. (1995). Air pollution and mortality in elderly people: a time-series study in Sao Paulo, Brazil. *Archives of Environmental Health*, *50*(2), 159-163.
- Saldiva, P. H. N., Lichtenfels, A. J. F. C., Paiva, P. S. O., Barone, I. A., Martins, M. A., Massad, E., Pereira, J. C. R., Xavier, V. P., Singer, J. M., & Bohm, G. M. (1994). Association between air pollution and mortality due to respiratory diseases in children in São Paulo, Brazil: a preliminary report. *Environmental Research*, *65*(2), 218-225.
- Santos, A. M., Silva, C. F. A., Almeida Junior, P. M., Rudke, A. P., & Melo, S. N. (2021). Deforestation drivers in the Brazilian Amazon: assessing new spatial predictors. *Journal of Environmental Management*, *294*, 113020.
- Sastry, N. (2002). Forest fires, air pollution, and mortality, in Southeast Asia. *Demography*, *39*(1), 1-23.
- Silva, A. C. O., Fonseca, L. M. G., Körtling, T. S., & Escada, M. I. S. (2020). A spatio-temporal Bayesian network approach for deforestation prediction in an Amazon rainforest expansion frontier. *Spatial Statistics*, *35*, 100393.
- Silva, C. A., Santilli, G., Sano, E. E., & Laneve, G. (2021). Fire occurrences and greenhouse gas emissions from deforestation in the Brazilian amazon. *Remote Sensing*, *13*(3), 376.
- Silva, P. R. S., Ignotti, E., Oliveira, B. F. A., Junger, W. L., Morais, F., Artaxo, P., & Hacon, S. (2016). High risk of respiratory diseases in children in the fire period in Western Amazon. *Revista de Saude Publica*, *50*, 29.
- Spektor, D. M., Hofmeister, V. A., Artaxo, P., Brague, J. A. P., Echelar, F., Nogueira, D. P., Hayes, C., Thurston, G. D., & Lippmann, M. (1991). Effects of heavy industrial pollution on respiratory function in the children of Cubatão, Brazil: a preliminary report. *Environmental Health Perspectives*, *94*, 51-54.
- Sun, Z., & Zhu, D. (2019). Exposure to outdoor air pollution and its human health outcomes: a scoping review. *PLoS One*, *14*(5), e0216550.
- Tacconi, L., Moore, P. F. & Kaimowitz, D. (2007). Fires in tropical forests: what is really the problem? Lessons from Indonesia. *Mitigation and Adaptation Strategies for Global Change*, *12*(1), 55-66.
- Uzoigwe, J. C., Prum, T., Bresnahan, E., & Garelnabi, M. (2013). The emerging role of outdoor and indoor air pollution in cardiovascular disease. *North American Journal of Medical Sciences*, *5*(8), 445-453.

- Viswanathan, S., Eria, L., Diunugala, N., Johnson, J., & McClean, C. (2006). An analysis of effects of San Diego wildfire on ambiente air quality. *Journal of the Air & Waste Management Association*, 56(1), 56-67.
- Vormittag, E. M. P. A., Rodrigues, C. G., André, P. A., & Saldiva, P. H. N. (2018). Assessment and valuation of public health impacts from gradual biodiesel implementation in the transport energy matrix in Brazil. *Aerosol and Air Quality Research*, 18(9), 2375-2382.
- Yu, J., De Jong, R., & Lee, L. (2008). Quasi-maximum likelihood estimators for spatial dynamic panel data with fixed effects when both n and T are large. *Journal of Econometrics*, 146(1), 118-134.

Recebido: Maio 10, 2023;

Aceito: Março 19, 2024

JEL Classification: Q26; Q32; Q54