

INTERNAÇÕES HOSPITALARES DO SISTEMA ÚNICO DE SAÚDE POR DOENÇA PULMONAR OBSTRUTIVA CRÔNICA E SEUS DETERMINANTES: ANÁLISE ESPACIAL PARA AS MICRORREGIÕES DO BRASIL

Juliane Borchers¹
José Rodrigo Gobi²
José Luiz Parré³

RESUMO

O objetivo da presente pesquisa foi analisar a distribuição espacial da morbidade hospitalar do SUS pela doença obstrutiva crônica (DPOC) entre as microrregiões do Brasil e seus determinantes socioeconômicos, demográfico, ambiental e de gestão de saúde, em 2016. Para tanto, a Análise Exploratória de Dados espaciais (AEDE), especificação dos modelos econométricos espaciais e o modelo GWR (*Geographically Weighted Regression*) foram utilizados. Verificou-se a existência de dependência espacial da morbidade hospitalar por DPOC entre as microrregiões do Brasil, sendo observados aglomerações do tipo AA no Centro-Oeste, Sudeste e Sul e do tipo BB no Norte e Nordeste do país. Constatou-se que as variáveis PIB per capita, ações de promoção e prevenção em saúde, índice Firjan de educação e leitos de internação impactam positivamente nas internações. Já a densidade demográfica e número de médicos afetam negativamente. Destaca-se também a influência das regiões vizinhas na determinação dos condicionantes das internações. Pelo modelo GWR, percebe-se que as internações hospitalares defasada, índice Firjan de educação, número de médicos e leitos de internação exercem impacto local sobre o número de internações por esse agravado. Portanto, a detecção das microrregiões com maior número de internações hospitalares por DPOC e seus determinantes espaciais permitem o direcionamento de políticas públicas que minimizem esse problema nas regiões estudadas.

PALAVRAS-CHAVE: Doença obstrutiva crônica. Econometria espacial. Economia da Saúde.

ABSTRACT

The objective of the present research was to analyze the spatial distribution of SUS hospital morbidity due to chronic obstructive disease (COPD) among Brazilian micro-regions and their socioeconomic, demographic, environmental and health management determinants, in 2016. Therefore, the Exploratory Analysis Spatial data (AEDE), specification of spatial econometric models and the GWR (*Geographically Weighted Regression*) model were used. There was a spatial dependence on hospital morbidity due to COPD among the micro-regions of Brazil, with agglomerations of type AA in the Midwest, Southeast and South and type BB in the North and Northeast of the country. It was found that the GDP per capita variables, health promotion and prevention actions, the Firjan education index and hospitalization beds have a positive impact on hospitalizations. The demographic density and number of doctors affect it negatively. The influence of neighboring regions in determining the conditions of hospitalizations is also highlighted. The GWR model shows that lagged hospital admissions, the Firjan education index, the number of doctors and hospital beds have a local impact on the number of hospitalizations for this condition. Therefore, the detection of the microregions with the highest

¹ Mestranda do Programa de Pós-Graduação em Ciências Econômicas (PCE) da Universidade Estadual de Maringá (UEM). E-mail: juli_borchers@hotmail.com.

² Doutorando do Programa de Pós-Graduação em Ciências Econômicas (PCE) da Universidade Estadual de Maringá (UEM). E-mail: joserodrigogobi@gmail.com.

³ Professor Titular do Departamento de Economia da Universidade Estadual de Maringá (UEM).

number of hospital admissions for COPD and their spatial determinants allows the direction of public policies that minimize this problem in the studied regions.

KEYWORDS: Chronic obstructive disease. Spatial econometrics. Health Economics.

ÁREA 8: Econometria

CLASSIFICAÇÃO JEL: I12. C31. R00

1 INTRODUÇÃO

A doença pulmonar obstrutiva crônica (DPOC) é uma doença respiratória prevenível e tratável caracterizada por limitação do fluxo aéreo que não é totalmente reversível. Essa enfermidade está relacionada à obstrução crônica das vias aéreas inferiores, normalmente em decorrência da inalação de partículas nocivas (CARNEIRO et al., 2018; TORRES; CUNHA; VALENTE, 2018).

Os principais sintomas da DPOC são tosse, falta de ar excessiva e produção de catarro com ou sem chiado no peito. Além disso, em fases mais avançadas, essa doença produz consequências sistêmicas significativas, com manifestações de perda de peso e diminuição da massa muscular. A DPOC compreende a bronquite crônica e o enfisema. A primeira está associada a presença de tosse e produção de expectoração por pelo menos três meses em dois anos consecutivos. Já o enfisema, refere-se à destruição dos alvéolos (BRASIL, 2013; TORRES; CUNHA; VALENTE, 2018).

A DPOC é uma das principais causas de morbidade e mortalidade no mundo, afetando mais de 200 milhões de pessoas e a estimativa é de que essa doença se torne a terceira principal causa de óbitos em 2020 (FORO DE LAS SOCIEDADES RESPIRATORIAS INTERNACIONALES, 2017). Em termos epidemiológicos, as mortes devido a DPOC têm apresentado tendência de crescimento no Brasil. O número de óbitos aumentou de 25,0 mil em 2000 para 40,9 mil em 2017, sendo que a maior concentração de mortes em 2017 ocorreu na região Sudeste (17,9 mil), seguido do Sul (9,0 mil), Nordeste (7,8 mil), Centro-Oeste (3,9 mil) e Norte (2,3 mil). Com relação as internações hospitalares por esta enfermidade, houve decréscimo passando de 254,9 mil internações em 2000 para 118,7 mil em 2017. No contexto regional para o ano de 2017, a região Sudeste registrou o maior número de internações por esse agravo (40,3 mil). Na sequência, ficaram Sul (37,1 mil), Nordeste (24,2 mil), Centro-Oeste (9,8 mil) e Norte (7,3 mil) (BRASIL, 2019a).

A DPOC gera substancial custo financeiro sobre o indivíduo portador da doença e o sistema de saúde, promovendo gastos da ordem de US\$ 1.522, 00 por paciente ao ano. Segundo Fiedman e Hilleman (2001) e Silva et al. (2011), os custos financeiros relacionados com essa enfermidade podem ser divididos em diretos e indiretos. O primeiro, refere-se às despesas médicas (exames, consultas, serviços hospitalares e remédios) e não médicas (transporte, aluguel e/ou compra de equipamentos domiciliares). Já os custos indiretos correspondem as perdas por conta da redução ou interrupção da produtividade em decorrência do adoecimento ou morte precoce⁶. No ano de 2017, o valor total das internações hospitalares por DPOC no Brasil alcançaram os R\$ 107,3 milhões (BRASIL, 2019a).

Neste contexto, a prevenção da DPOC é tida como fundamental para reduzir o número de casos dessa doença, bem como os custos econômicos e sociais gerados por ela ao sistema de saúde. A DPOC ocorre mais frequentemente em pessoas acima dos 40 anos de idade, e o tabagismo é apontado como o principal fator para o desenvolvimento desse agravo^{1,2}. No entanto, nos últimos anos, cresceu o número de pesquisas que sugerem que existem outros fatores de risco além do tabagismo. Esses determinantes incluem a exposição aos poluentes

ambientais, ambientes de trabalho com poeira e fumaça, infecções respiratórias graves na infância, alimentação deficiente e baixa condição socioeconômica (CONSENSO BRASILEIRO SOBRE DOENÇA PULMONAR OBSTRUTIVA CRÔNICA II, 2004; SALVI; BARNES, 2009; SOUSA et al., 2011; ARBEX et al., 2012).

O comportamento da Doença Obstrutiva Crônica e os seus fatores associados tem sido objeto de estudo de diversos pesquisadores da área da saúde. As pesquisas (internacionais e nacionais), em geral, retratam o estado de saúde dos indivíduos pela incidência, prevalência, morbidade e mortalidade dessa enfermidade. Além disso, aplicam distintas metodologias empíricas (por exemplo, regressão logística, regressão de Poisson, mapeamento geográfico, etc.) para avaliar o impacto das condições socioeconômicas, demográficas, ambientais e de gestão sobre essas causas. Dentre esses estudos, destacam-se: Souza et al. (2011); Held e Riebler (2012); Antunes et al. (2013); Almeida (2013); Cao, Liang e Niu (2017); Yang et al. (2017); Torres, Cunha e Valente (2018) e Lee et al. (2019).

A partir da revisão dos estudos supracitados, constata-se que tanto a incidência da morbidade quanto mortalidade por DPOC estiveram associados com características socioeconômicas e demográfica (idade, renda familiar, educação, saneamento, sexo, raça, IMC), de comportamento (tabagismo, sedentarismo, alimentação), local de residência (poluição do ar, fatores meteorológicos) e de gestão em saúde (médicos, consultas, medicamentos). Fica claro, que a identificação de fatores de risco é um ponto chave das estratégias preventivas para reduzir a incidência dessa enfermidade.

Além disso, observa-se que esses determinantes da DPOC possuem tendências de aglomerações espaciais. Dessa forma, a econometria espacial apresenta-se como uma metodologia apropriada para estudar esse agravo, mediante a introdução de variáveis que reflitam os condicionantes ambientais, de gestão, socioeconômicas e demográficas de uma determinada região.

A identificação da DPOC em seu estágio inicial, de seus fatores de risco, o encaminhamento rápido e adequado para o atendimento especializado e a atenção domiciliar atribuem a Atenção Básica caráter fundamental para melhorar os resultados curativos e prognóstico dos casos dessa enfermidade (BRASIL, 2013). No entanto, no Brasil, ao se considerar a oferta e a demanda por serviços de saúde, pode-se verificar disparidades na distribuição de profissionais e no acesso a ações de promoção e prevenção de saúde (SILVEIRA; PINHEIRO, 2014; DOMINGOS et al., 2017). Para estudar essas desigualdades, destaca-se o método de análise espacial. Essa metodologia permite melhor visualização da dinâmica de distribuição de doenças e agravos, bem como da demanda e acesso aos serviços de saúde (PERINETTI, 2015; ZHOU et al., 2015; MADHU et al., 2016).

Diante do exposto, o objetivo da presente pesquisa é analisar a distribuição espacial da morbidade hospitalar do SUS pela DPOC da população com 40 anos ou mais entre as microrregiões do Brasil e seus determinantes: socioeconômicos (PIB per capita), demográfico (educação), ambiental (densidade veicular) e de gestão de saúde (leitos de internação, número de médicos e ações de promoção e prevenção de saúde), em 2016. Para isso, utilizou-se a Análise Exploratória de Dados espaciais (AEDE) e a especificação dos modelos econométricos espaciais.

A hipótese a ser investigada neste estudo é a de que existe dependência espacial da morbidade hospitalar do SUS por DPOC entre as microrregiões do Brasil. Além disso, pressupõe-se que os fatores: socioeconômico (PIB per capita), demográfico (educação), ambiental (densidade veicular) e de gestão de saúde (leitos de internação, número de médicos e ações de promoção e prevenção de saúde) exercem impacto sobre o comportamento dessa variável.

Esta pesquisa procura contribuir para que ao serem identificados os fatores socioeconômicos, demográficos, ambientais e de gestão de saúde que determinam o estado de

saúde da população com 40 anos ou mais, políticas públicas sejam melhor direcionadas. Essas políticas podem incluir a redução das iniquidades no acesso aos serviços de saúde ofertados, a promoção da saúde e a melhoria da qualidade de vida dessas pessoas. Além disso, essas ações podem abranger a conscientização sobre os sintomas da DPOC e a importância dos exames preventivos.

2 METODOLOGIA

2.1 FONTE E DESCRIÇÃO DOS DADOS

Este estudo utilizou dados da morbidade hospitalar por DPOC, disponíveis no Departamento de Informática do SUS (DATASUS) do Ministério da Saúde (BRASIL, 2019a). A área de abrangência corresponde às 558 microrregiões do Brasil e o período de análise é o ano de 2016, dada a indisponibilidade de dados do PIB per capita municipal (variável explicativa) para os anos de 2017 e 2018, quando a coleta de dados foi realizada (entre setembro e outubro de 2019).

Ressalta-se que a morbidade hospitalar do SUS corresponde ao número de internações hospitalares aprovadas (AIHs) por DPOC em pessoas com 40 anos ou mais (a cada 100 mil indivíduos), sendo a variável de interesse do estudo. A coleta foi realizada abrangendo: a) as categorias J40 (bronquite não especificada como aguda ou crônica), J41 (bronquite crônica simples e a mucopurulenta), J42 (bronquite crônica não especificada), J43 (enfisema), J44 (outras doenças pulmonares obstrutivas crônicas) do Código Internacional das Doenças – CID 10; b) a faixa etária (com idade maior ou igual a 40 anos); c) por ano (2016) e d) por local de residência nas microrregiões brasileiras. A escolha dos diversos códigos atendeu à variabilidade da apresentação clínica da doença, além de serem as categorias mais utilizadas em estudos epidemiológicos (TORRES; CUNHA; VALENTE, 2018).

Como possíveis determinantes espaciais, o PIB per capita (R\$ mil) foi a variável usada para representar o aspecto socioeconômico, a educação (Índice Firjan de Desenvolvimento Municipal) representa o fator demográfico, a densidade veicular (número de veículos por quilômetros quadrado) como proxy do ambiente, leitos de internação (a cada 100 mil indivíduos), número de médicos (a cada mil pessoas) e ações preventivas na atenção básica (a cada 100 mil habitantes) representam os fatores de gestão de saúde. Cabe destacar que todas as variáveis, com exceção da educação e densidade veicular, foram definidas em termos per capita, ou seja, foram divididas pela população da microrregião correspondente.

Na Tabela 1 estão apresentadas a descrição das variáveis explicativas, a fonte dos dados e o sinal esperado das relações analisadas. Espera-se que as variáveis PIB per capita, densidade veicular e leitos de internação tenham associação positiva com as internações hospitalares. O sinal esperado para as variáveis médico, índice Firjan de educação e ações preventivas pode ser tanto positivo quanto negativo.

Tabela 1 – Variáveis explicativas da pesquisa, 2016

Variáveis	Descrição	Fonte	Sinal Esperado
Determinantes socioeconômicos e demográficos			
PIB per capita	Valor médio do PIB per capita (R\$ mil) para cada microrregião do Brasil.	Disponível em IBGE	+
Índice Firjan de Educação	Valor médio do Índice Firjan de Desenvolvimento Municipal de educação para cada microrregião do Brasil.	Disponível em FIRJAN	+/-
Determinante ambiental			
Densidade veicular	Valor calculado pela relação entre o total de veículos e a área da microrregião correspondente.	Disponível em DENATRAN e IBGE	+
Determinantes de gestão de saúde			
Médicos	Quantidade de médicos contidos no cadastro Nacional de Saúde (CNES).	Disponível em DATASUS	+/-
Leitos de internação	Apresenta o quantitativo de leitos hospitalares de internação disponibilizados para atendimento pelo SUS contidos no Cadastro Nacional de Estabelecimentos de Saúde - CNES.	Disponível em DATASUS	+
Ações preventivas	Quantidade de ações de promoção e prevenção em saúde aprovados para pagamento pelas Secretarias de Saúde. As ações de promoção e prevenção considerados foram em Atenção Básica.	Disponível em DATASUS	+/-

Fonte: Elaboração própria com base nos dados da pesquisa (2019).

É importante destacar que para realizar as estimativas econométricas da presente pesquisa, aplicou-se logaritmo natural (ln) em todas as variáveis (dependente e explicativas) (PENNA, 2009).

2.2 MÉTODO EMPÍRICO

2.2.1 Análise Exploratória de Dados Espaciais (AEDE)

A aplicação da análise exploratória de dados espaciais (AEDE) se explica por ser um método que objetiva retratar a distribuição espacial, os padrões de associação espacial (*clusters* espaciais), analisar a existência de diferentes regimes espaciais ou outras formas de instabilidade espacial e identificar observações atípicas (*outliers* espaciais) (ANSELIN; BERA, 1998).

A AEDE é benéfica no estudo do processo de difusão espacial porque focaliza principalmente em encontrar padrões de autocorrelação espacial. A abordagem predominante, neste tipo de análise, é baseada nas estatísticas globais como I de Moran (ANSELIN; BERA, 1998; ALMEIDA, 2012).

A autocorrelação espacial global pode ser calculada por meio da estatística *I* de Moran (ALMEIDA, 2012):

$$I_t = \left(\frac{n}{S_0}\right) \left(\frac{z'_t W z_t}{z'_t z_t}\right) \quad (1)$$

em que z_t é o vetor de n observações para o ano t na forma de desvio em relação à média, W é a matriz de pesos espaciais e o termo S_0 é um escalar igual à soma de todos os elementos de W .

O *I* de Moran propicia três tipos de informação: a) a significância provê a informação se os dados estão distribuídos aleatoriamente ou não; b) o sinal positivo da estatística, desde

que significativo, mostra que os dados estão concentrados através das microrregiões; e c) o sinal negativo indica a dispersão dos dados (ANSELIN; BERA, 1998; ALMEIDA, 2012).

Contudo, as estatísticas globais desconsideram uma possível existência de instabilidade espacial, no sentido que se em algumas áreas específicas a autocorrelação espacial for positiva e em outras, negativa, o efeito, no geral, pode se anular e a autocorrelação não ser detectada (SILVA, BORGES, PARRÉ, 2013). Para que a instabilidade espacial seja considerada pode-se utilizar a estatística I de Moran Local ou $LISA$, definido como (FISCHER; GETIS, 2010):

$$I_i = z_i \sum_{j=1}^i W_{ij} z_j \quad (2)$$

Na equação (3) é utilizado um coeficiente de autocorrelação espacial que seja capaz de detectar regimes de associação espacial que produzam um valor específico para cada área.

2.2.2 Modelos econométricos espaciais

Na economia espacial três especificações de modelos se destacam: 1) Modelos de dependência espacial de alcance global (*Spatial Autoregressive Model* ou *Spatial Autoregressive Model*); 2) Modelos de dependência espacial de alcance global e local (*Spatial Durbin Model* ou *Spatial Durbin Error Model*); e 3) Modelos de dependência espacial de alcance local (*Spatial Lag of X*) (ANSELIN, 2013).

O alcance global se reflete na matriz de variância e covariância plena e ocorre por intermédio de um multiplicador espacial que transborda o efeito ocorrido em determinada região para as demais. Já no alcance local, a transferência de um efeito ocorre na vizinhança mais próximas, principalmente nos vizinhos de segunda ordem (diretos e indiretos) (ALMEIDA, 2012).

No entanto, para definir o modelo espacial mais adequado é necessário primeiramente utilizar a estimação do modelo clássico de regressão linear (MCRL) por Mínimos Quadrados Ordinários (MQO).

Para se considerar as interações entre as regiões, utiliza-se a matriz de peso espacial (W) apresentada anteriormente neste trabalho. Essa matriz pode se manifestar: a) na variável dependente do modelo *Spatial Autoregressive Model* (SAR), onde a variável dependente nas regiões vizinhas apresenta interação entre si e b) no erro do modelo *Spatial Error Model* (SEM), em que a dependência espacial nesse modelo se expressa no termo de erro (ALMEIDA, 2012; ANSELIN, 2013).

Os modelos SAR e SEM possuem as seguintes especificações:

$$y = \rho W y + X \beta + \varepsilon \quad (3)$$

$$y = X \beta + u. \quad (4)$$

Na Equação (3), tem-se que o termo $W y$ é um vetor $n \times 1$ de defasagens espaciais para a variável dependente, ρ é o coeficiente autorregressivo espacial, X é uma matriz de variáveis independentes exógenas, β são os coeficientes da regressão e ε é o termo de erro. Já para a Equação (4), tem-se que $u = \lambda W u + \varepsilon$, sendo λ o parâmetro do erro autorregressivo espacial que acompanha a defasagem $W \varepsilon$ somado ao erro (ALMEIDA, 2012).

Para definir o modelo mais adequado são utilizados teste de Multiplicadores de Lagrange da defasagem ($ML\rho$) e do erro ($ML\lambda$). Além disso, torna-se interessante estimar outros modelos espaciais como forma adicional de checar a robustez do modelo escolhido. Os modelos adicionais são o *Spatial Lag of X* (SLX), *Spatial Durbin Model* (SDM) e o *Spatial Durbin Error Model* (SDEM), na qual consideram que as defasagens espaciais das variáveis independentes podem afetar a variável explicativa (ALMEIDA, 2012).

O modelo SLX considera a ocorrência de externalidades nas variáveis explicativas, ou seja, as variáveis independentes de uma região influenciam a variável dependente da região vizinha. Dessa forma, esse modelo possui a seguinte especificação:

$$y = X\beta + WX_{\tau} + \varepsilon \quad (5)$$

em que τ denota um vetor ($k - 1$ por 1) que pode apresentar valor nulo caso alguma variável explicativa não apresentar interação espacial com as regiões vizinhas. Como esse modelo não apresenta um multiplicador espacial seu alcance acaba sendo estritamente local, pois seus impactos de transbordamentos são localizados (LESAGE; PACE, 2009; ALMEIDA, 2012).

Já os modelos SDM e SDEM podem ser representados, respectivamente, conforme segue (ALMEIDA, 2012):

$$y = \lambda Wy + X\beta + \lambda WX\beta + \varepsilon \quad (6)$$

$$y = X\beta + WX_{\tau} + u \quad (7)$$

onde, na Equação (6) o termo λW representam matrizes de pesos espaciais relacionadas a seus parâmetros (y e X). Na Equação (7), tem-se que WX_{τ} é um vetor ($k - 1$ por 1) de defasagens espaciais para as variáveis independentes exógenas e $u = \lambda Wu + \varepsilon$, sendo λ o parâmetro do erro autorregressivo espacial que acompanha a defasagem $W\varepsilon$ somado ao erro.

Conforme Equação (6), o modelo SDM tem tanto alcance global dado pelo multiplicador espacial que surge por conta da presença da variável dependente defasada espacialmente quanto um alcance local, devido as defasagens espaciais das variáveis independentes. Já o modelo SDEM (Equação 7), possui alcance global, com o transbordamento sobre o termo de erro e um alcance local, ao incorporar componentes de transferência sobre as variáveis independentes exógenas (ALMEIDA, 2012; ANSELIN, 2013).

2.2.3 Modelo de Regressão Ponderada Geograficamente

Na análise econométrica espacial, os parâmetros estimados globalmente podem não ser adequados para representar as condições locais, em virtude de caracterizar apenas respostas médias e não captar todas as disparidades do fenômeno em estudo. Dessa forma, para estimar respostas localizadas para cada região é recomendado utilizar o modelo *Geographically Weighted Regression* (GWR), minimizando os erros estruturais (ALMEIDA, 2012).

O modelo GWR é um desenvolvimento do Modelo Clássico de Regressão Linear (MCRL), permitindo que a relação entre as variáveis explicativas e dependentes variem por localidade. Esse modelo é especificado da seguinte forma (ALMEIDA, 2012):

$$y_i = \beta_0(u_i, v_i) + \sum_k \beta_k(u_i, v_i) x_{ik} + \varepsilon_i. \quad (8)$$

Verifica-se que (u_i, v_i) representam as coordenadas geográficas latitude e longitude da observação (região) i no espaço e $\beta_k(u_i, v_i)$ o coeficiente local no ponto i . Os pressupostos do MCRL permanecem para o modelo GWR. A partir das coordenadas é possível determinar a distância entre as observações. A ponderação geográfica da estimação dos parâmetros do modelo é feita por meio da função Kernel espacial, que utiliza a distância entre duas regiões e um parâmetro da largura da banda, determinando um peso entre essas duas regiões. Quanto mais próximas forem as observações, mais intenso será o processo de transbordamento e quanto mais distante menor será essa intensidade (ALMEIDA, 2012).

3 RESULTADOS

3.1 ANÁLISE DESCRITIVA E ESPACIAL DOS DADOS

Na Tabela 2 apresenta-se a estatística descritiva dos dados utilizados no presente estudo, correspondente às 558 microrregiões do Brasil em 2016. A média de internações hospitalares

foi de 70,59 a cada 100 mil, com coeficiente de variação de aproximadamente 115,60%, indicando alta disparidade entre as áreas pesquisadas. Destaque para a microrregião de Ivaiporã (PR), em que o número de internações hospitalares foi o mais alto (561,71/100 mil indivíduos).

Tabela 2 – Análise descritiva dos dados utilizados na pesquisa, Microrregiões do Brasil, 2016

Variáveis	Média	Desvio padrão	Coeficiente de Variação (%)	Máximo	Mínimo
Internações hospitalares (a cada 100 mil indivíduos)	70,59	80,89	115,60	561,71	0
PIB per capita (R\$ mil)	21,46	14,65	68,28	107,00	5,59
Educação	0,76	0,10	13,69	0,97	0,42
Densidade veicular	50,99	211,32	414,42	4049,984	0,014
Médicos (a cada 100 mil indivíduos)	11,31	3,13	27,65	41,13	4,75
Leitos de internação (a cada 100 mil indivíduos)	159,04	67,68	42,56	588,73	1,82
Ações preventivas (a cada 100 mil indivíduos)	250,95	565,32	225,27	11136,34	7,61

Fonte: Elaboração própria com base nos dados da pesquisa (2019).

O valor médio do PIB per capita nas 558 microrregiões, em 2016, foi de R\$ 21,46 mil, sendo que o coeficiente de variação correspondeu a 68,28%, o que demonstrou uma dispersão alta dessa variável entre áreas. As microrregiões de Parecis (MT) e Meruoca (CE) apresentaram o maior e o menor valor dessa variável, correspondendo a R\$ 107,00 mil e R\$ 5,59 mil, respectivamente (Tabela 2).

A média do índice Firjan de educação foi de 0,76 no ano de 2016, com coeficiente de variação de 13,69%. Destaque para as microrregiões de Fernandópolis (SP) que apresentou o maior índice (0,97) e a Almerim (PA) com um dos valores mais baixos (0,42).

A densidade veicular apresentou valor médio de 50,99 veículos por quilometro quadrado, com o coeficiente de variação correspondendo a 414,42%, o que também demonstra alta dispersão dessa variável entre as microrregiões brasileiras. As microrregiões de São Paulo (SP) e Purus (AM) exibiram maior e menor valor para essa variável, com 4.049,98 e 0,014, respectivamente (Tabela).

A média do número de médicos foi de 11,31 a cada 100 mil indivíduos, com coeficiente de variação de 27,65%. A microrregião de Barretos (SP) apresentou o maior número de profissionais (41,13/100 mil), já a microrregião de Portel (PA) teve a menor quantidade, 4,75 a cada 100 mil.

O valor médio de leitos em 2016 nas 558 microrregiões, foi de 159,04 a cada 100 mil, sendo que o coeficiente de variação correspondeu a 42,56%. As microrregiões de Tupã (SP) e Boquim (SE) apresentaram o maior e o menor valor para essa variável, correspondendo a 588,73/100 mil e 1,82/100 mil, respectivamente.

Por fim, a média de ações preventivas foi de 250,95 a cada 100 mil, sendo que o coeficiente de variação foi de 225,27% (Tabela 2), o que demonstra dispersão alta dessa variável entre as microrregiões brasileiras. O valor máximo dessas ações foi de 11.136,34 para cada 100 mil (microrregião de Tesouro – MT) e o mínimo correspondeu a 7,61 a cada 100 mil (microrregião de Santa Quitéria – SE).

Em termos regionais, observa-se na Figura 1 a distribuição do número de internações hospitalares por DPOC nas microrregiões do Brasil, em 2016. As microrregiões situadas nas regiões Norte, Nordeste e parte do Centro-Oeste do Brasil apresentaram baixo número de internações hospitalares, representados pelos tons mais claros. Por outro lado, as microrregiões do Sul e Sudeste do país tem elevado número de internações hospitalares por DPOC (tons mais escuros).

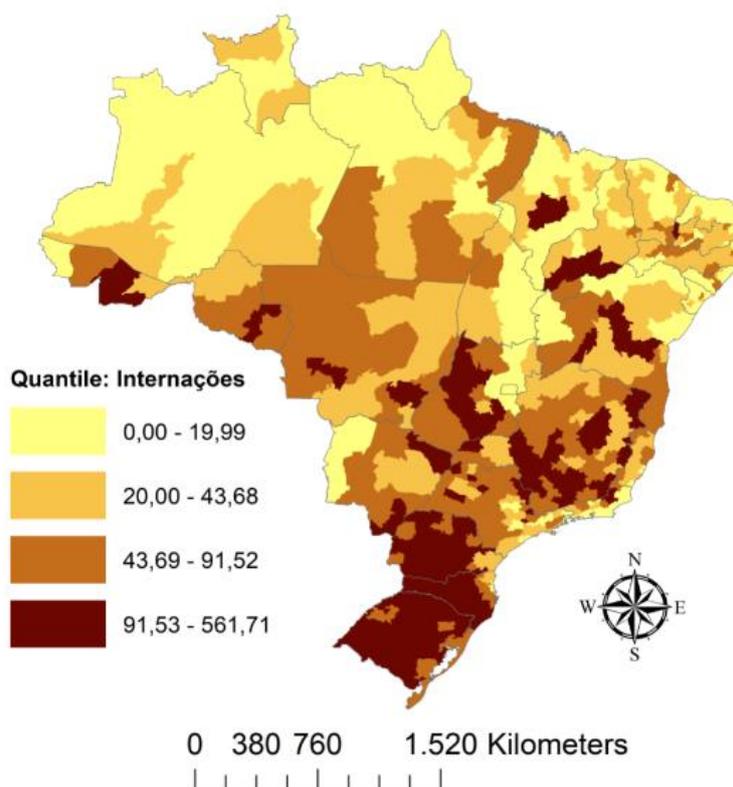


Figura 1 – Distribuição do número de internações hospitalares por DPOC em indivíduos com 40 anos ou mais, Microrregiões do Brasil, 2016.

Fonte: Elaboração própria com base nos dados da pesquisa (2019).

Dessa forma, pode-se notar certo padrão de distribuição espacial, o que indica que microrregiões com número de internações por DPOC similares estão agrupados em *clusters* espaciais. Essa associação necessita de confirmação por meio de testes específicos, que serão apresentados nas seções seguintes.

3.2 ANÁLISE DA AUTOCORRELAÇÃO ESPACIAL GLOBAL E LOCAL

A matriz que exibiu a melhor conexão entre as microrregiões foi a de 5 vizinhos, em virtude de apresentar o maior valor do coeficiente I de Moran (0,6256). Dessa forma, para estimar a análise exploratória de dados espaciais (AEDE) das internações por DPOC no Brasil em 2016 foi utilizada essa conexão espacial.

Na Figura (2a) está demonstrada o diagrama de dispersão de Moran para a variável internações hospitalares por DPOC em indivíduos com 40 anos ou mais. Verifica-se que, de fato, há presença de autocorrelação espacial positiva, pois a maior parte dos *cluster* representados foram AA e BB. Assim, em 2016, as microrregiões que apresentaram alto (baixo) número de internações por DPOC estão cercados por áreas que também demonstraram elevada (baixa) morbidade por esse tipo de doença.

Na Figura 2(b) estão apresentadas as aglomerações da estatística LISA para a variável de interesse no ano de 2016. Percebe-se em vermelho as microrregiões AA (formação de *cluster* com elevado número de internações por DPOC rodeados por áreas com altas internações) no Centro-Oeste, Sudeste e Sul do Brasil, predominantemente nos estados de Goiás, Minas Gerais, Paraná, Santa Catarina e Rio Grande do Sul. Nos estados de São Paulo, Mato Grosso e Mato Grosso do Sul é possível observar aglomerações AA, mas em menores quantidades.

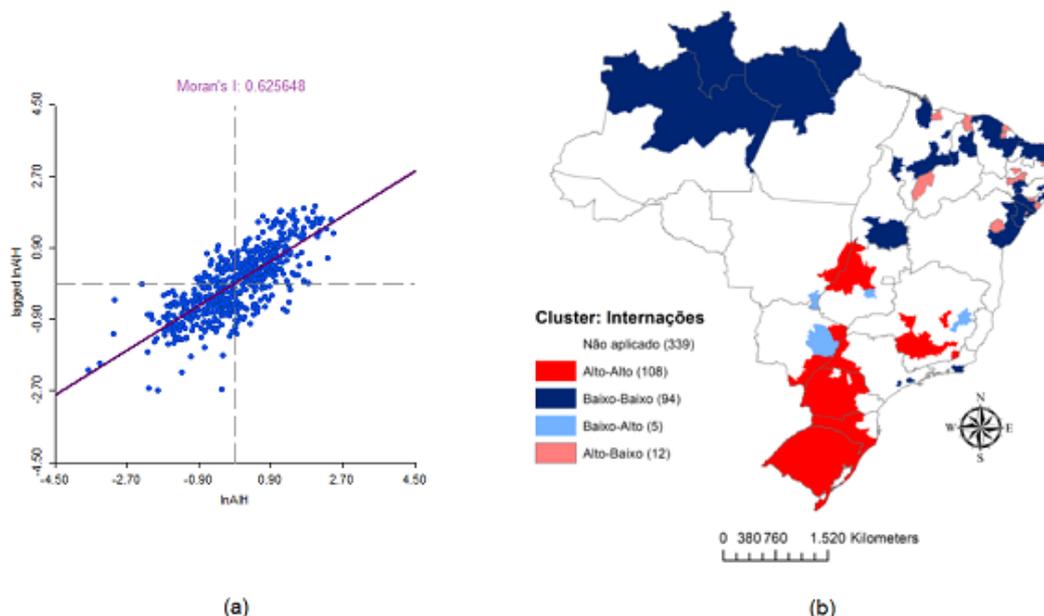


Figura 2 – Diagrama de dispersão de Moran (a) e Mapa de *Cluster* LISA (b) das internações hospitalares por DPOC em indivíduos com 40 anos ou mais, Microrregiões do Brasil, 2016
Fonte: Elaboração própria com base nos dados da pesquisa (2020).

Por outro lado, com relação às aglomerações BB (formação de *cluster* com baixo número de internações por DPOC cercados por regiões com baixa quantidade dessa variável), representadas pelas áreas em azul escuro, observa-se que em 2016 se concentraram em grande parte no Norte e Nordeste do Brasil. Os estados do Amazonas, Roraima, Pará, Amapá, Maranhão, Piauí, Ceará, Rio Grande do Norte, Pernambuco, Alagoas, Sergipe e Bahia concentraram esses *clusters*. Além disso, percebe-se pequena aglomeração no estado do Rio de Janeiro e São Paulo.

É possível verificar ainda a formação de regimes espaciais atípicos, *clusters* BA (regiões com menor número de internações por DPOC cercadas por vizinhos com internações superior à média brasileira) realçados em azul claro e as aglomerações AB (regiões com maior número de internações por essas doenças cercadas por microrregiões com internações inferior à média brasileira) denotados em rosa, aparecendo dispersos pelo mapa (Figura 2b).

3.3 RESULTADOS DOS MODELOS ECONOMETRICOS ESPACIAIS

O primeiro passo para definir o modelo econométrico espacial mais adequado é dado pela estimativa do teste *I* de Moran para encontrar a matriz de contiguidade que retrata a melhor conexão espacial. Novamente, a matriz 5 vizinhos exibiu a melhor conexão entre as microrregiões, pois apresenta o maior coeficiente para o teste. Logo, as estimativas dos modelos foram realizadas usando essa matriz de contiguidade.

Na Tabela 3 apresentam-se os coeficientes da estimação por MQO, bem como os resultados dos testes de diagnóstico da regressão. Os testes que identificam a autocorrelação espacial inferiram um *I* de Moran Global significativo de 0,4822, bem como significância estatística nos testes focados do tipo Multiplicadores de Lagrange ($ML\rho$ e $ML\lambda$). Assim, o modelo MQO não é o mais adequado para esse estudo, pois não incluem os efeitos espaciais na regressão. É necessário, então, verificar as versões robustas dos testes $ML*\rho$ e $ML*\lambda$ para a escolha do modelo econométrico espacial mais adequado.

Os efeitos espaciais podem se manifestar no erro ou na variável dependente. Conforme demonstrado na Tabela, os valores referentes ao ML robusto da defasagem ($ML*\rho = 42,98$) e

ML robusto do erro ($ML*\lambda = 8,75$) foram significativos a 1%. Como o teste $ML*\rho$ foi maior que $ML*\lambda$, o modelo de defasagem espacial (SAR) pode ser o mais adequado para analisar a relação entre o número de internações hospitalares por DPOC e os determinantes socioeconômicos, demográficos, ambiental e de gestão nas microrregiões do Brasil em 2016.

Tabela 3 – Diagnóstico da regressão estimada por MQO – Variável dependente: Internações hospitalares por DPOC, Microrregiões do Brasil, 2016

Variáveis	Coefficientes
Constante	3,8193*
PIB per capita	0,4846*
Índice Firjan de Educação	2,6647*
Densidade Veicular	-0,1009*
Médicos	-1,0446*
Leitos de internação	0,7343*
Ações preventivas	0,0826
Diagnóstico da regressão	
R-Quadrado	0,3573
Jarque-Bera	12,92*
Breusch-Pagan	10,96***
Koenker-Bassett	8,85
Diagnóstico para autocorrelação espacial	
I de Moran (erro)	0,4822*
$ML\rho$ (defasagem)	326,22*
$ML*\rho$ (defasagem)	42,98*
$ML\lambda$ (erro)	291,99*
$ML*\lambda$ (erro)	8,75*

Fonte: Elaboração própria com base nos dados da pesquisa (2019).

Nota¹: Variáveis em LN. Nota²: *Significativo a 1%. **Significativo a 5%. ***Significativo a 10%.

Na Tabela 4 estão apresentados os resultados dos modelos econométricos espaciais SAR, SDM e SLX. Como foram identificados não normalidade dos erros (teste Jarque-Bera) e presença de heterocedasticidade (teste Breusch-Pagan) o método de Mínimos Quadrados em 2 Estágios (MQ2E) foi usado no modelo SAR e SDM. Já o modelo SLX foi estimado por Mínimos Quadrados Ordinários (MQO).

Tabela 4 – Resultados dos modelos econométricos espaciais SAR, SDM e SLX, Microrregiões do Brasil, 2013

Variáveis	Coefficientes modelo		
	SAR	SDM	SLX
Constante	3,10*	1,47	0,95
PIB per capita	0,15**	0,04	0,03
Índice Firjan de Educação	1,35*	1,06**	0,83
Densidade Veicular	-0,05*	-0,11*	-0,12*
Médicos	-0,74*	-0,61*	-0,74*
Leitos de internação	0,49*	0,50*	0,61*
Ações preventivas	0,09***	0,09***	0,06
W_PIB per capita	–	0,12	0,64*
W_Índice Firjan de Educação	–	-0,52	1,91***
W_Densidade veicular	–	0,11**	0,06
W_Médicos	–	0,16	-0,77**
W_Leitos de internação	–	-0,12	0,58*
W_Ações preventivas	–	-0,09	0,02
ρ (defasagem)	0,6443*	0,42*	–
Anselin-Kelejjan	0,105	1,184	–

Fonte: Elaboração própria com base nos dados da pesquisa (2019).

Nota¹: Variáveis em LN. Nota²: *Significativo a 1%. **Significativo a 5%. ***Significativo a 10%.

É importante destacar que a observância da defasagem espacial (ρ) confirma uma relação positiva entre a variável internações e sua defasagem espacial. Dessa forma, microrregiões com alto (baixo) nível de internações por DPOC tendem a ser circundadas por microrregiões com alta (baixa) quantidade desta variável. Além disso, a partir do teste Anselin-Kelejian evidencia-se que o modelo SAR incorpora corretamente a autocorrelação espacial dos erros, pois não foi possível rejeitar a hipótese nula a nível de 1% de significância.

De acordo com os resultados do modelo SAR (Tabela 4), existe relação espacial global positiva entre PIB per capita, índice Firjan de educação, leitos de internação e ações preventivas com as internações hospitalares por DPOC. Verifica-se que a expansão de 10% em cada uma destas variáveis provoca um aumento de 1,5%, 13,5%, 4,9% e 0,9%, respectivamente, nas internações de indivíduos com 40 anos ou mais.

Por sua vez, as variáveis densidade veicular e número de médico apresentaram sinal negativo (Tabela 4), indicando que o crescimento de 10% nessas variáveis, reduzem as internações hospitalares no SUS por DPOC em 0,5% e 7,4%.

Para uma checagem adicional da robustez do modelo espacial e considerando que as características das microrregiões vizinhas podem ser importantes na determinação dos condicionantes da morbidade por DPOC em determinada região, estimou-se o modelo *Spatial Durbin Model* (SDM) e *Spatial Lag of X* (SLX), incorporando as defasagens espaciais das variáveis explicativas.

Novamente, a partir do teste Anselin-Kelejian observa-se que o modelo SDM incorporou corretamente a autocorrelação espacial dos erros, dado a não rejeição da hipótese nula a nível de 1% de significância. Esse teste indicou que o modelo SDM é adequado para mensurar o efeito espacial local e global na regressão.

O modelo SDM (Tabela 4) apresentou autocorrelação global e local positiva e significativa da variável dependente defasada (ρ). Os coeficientes defasados no modelo indicaram que a densidade veicular na vizinhança afeta positivamente as internações hospitalares por DPOC na região de interesse. Ou seja, um crescimento em 10% na densidade veicular nas microrregiões vizinhas, aumentam as internações em 1,1% na microrregião em análise.

Quando observado o modelo SLX, evidencia-se relação global e local positiva entre PIB per capita, índice Firjan de educação e leitos de internação com as internações hospitalares, onde o aumento de 10% destas variáveis nas microrregiões vizinhas geram crescimento de 6,4%, 19,1% e 5,8%, nesta ordem, nas enfermidades na microrregião em análise. Por sua vez, a variável número de médicos apresentou relação espacial global e local negativa (Tabela 4), indicando que o crescimento de 10% nessa variável, reduz as internações hospitalares no SUS por DPOC em 7,7%.

Na próxima seção apresenta-se uma análise local mediante aplicação do modelo GWR, que fornece respostas localizadas para cada microrregião individualmente, minimizando os erros estruturais.

3.4 RESULTADOS DO MODELO GWR

Na Tabela 5 são apresentados os resultados do modelo GWR sem defasagem espacial, SAR, SDM e SLX. Em todos os modelos estimados, observa-se pelo menor critério AIC valor mais baixo para o modelo local, indicando que a estimação desse último é mais ajustada. É importante destacar que os modelos com aspecto local viabiliza uma resposta exclusiva para cada microrregião brasileira analisada. Além disso, o teste F infere que o modelo GWR apresentou melhora sobre o modelo global.

Para a escolha do modelo a ser desenvolvido para análise ponderada geograficamente, considera-se o menor critério AIC (Tabela 5). Dessa forma, o modelo escolhido foi o SAR (AIC = 1.043,49) que capta a defasagem na variável dependente.

Tabela 5 – Resultados do modelo GWR, Microrregiões do Brasil, 2013

Especificação do modelo	Regressão	AIC	Teste F	R ²
GWR sem componente espacial ¹	Global	1.380,92	–	0,36
	Local	1.117,70	5,74*	0,70
SAR ²	Global	1054,81	–	0,64
	Local	1,043,49	1,90*	0,68
SDM ³	Global	1.104,77	–	0,65
	Local	1.045,52	1,64**	0,67
SLX ⁴	Global	1.333,40	–	0,42
	Local	1.148,94	4,06*	0,71

Fonte: Elaboração própria com base nos dados da pesquisa (2019).

¹Tamanho da banda adaptativa = 114; ²Tamanho da banda adaptativa = 303; ³Tamanho da banda adaptativa = 558;

⁴Tamanho da banda adaptativa = 154.

Nota¹: Variáveis em LN. Nota²: Para o cálculo do *I* de Moran residual foi utilizada a matriz de pesos espaciais “5 vizinhos”. Nota³: *Significativo a 1%. **Significativo a 5%. ***Significativo a 10%.

A partir das estimações do modelo SAR, percebe-se que os efeitos locais das 558 microrregiões brasileiras para as variáveis explicativas que apresentam variação geográfica e significativas a 5% (considerando o teste $t_c = 1,96$) foram: internações hospitalares por DPOC defasada, índice Firjan de educação, número de médicos e leitos de internação, conforme demonstrado na Figura 3 – mapas (a) até (d).

Na Figura 3(a), verifica-se que o efeito espacial local das internações hospitalares defasada é positivo, isto é, um crescimento das internações das microrregiões vizinhas pode influenciar o comportamento das internações da microrregião em questão. Os maiores impactos estão localizados no Sul – nos estados do Rio Grande do Sul, Santa Catarina e Paraná, no Sudeste – nos estados de São Paulo, Rio de Janeiro, Espírito Santo e Minas Gerais, no Centro-Oeste – nos estados do Mato Grosso do Sul e Goiás, e no Nordeste, principalmente na Bahia, Sergipe, Alagoas e Pernambuco. Por sua vez, as menores intensidades são observadas nos estados do Acre, Amazonas, Rondônia, Roraima, Amapá e em partes do Pará e Mato Grosso.

No referente ao índice Firjan de educação (Figura 3b), observou-se coeficientes locais significativos e positivos em diversas regiões do país. Dessa forma, elevações no índice de educação poderia exercer forte efeito local no número de internações hospitalares por DPOC. A maior intensidade desse condicionante pode ser evidenciada nas regiões Sudeste – Rio de Janeiro, Espírito Santo e São Paulo, e no Norte – Rondônia, Acre, Amazonas e Pará.

Com relação ao número de médicos (Figura 3c), observou-se que, com exceção de grande parte da região Nordeste e no estado do Amapá, esse determinante apresentou coeficientes locais significativos em quase todas as microrregiões do Brasil. Considerando seu efeito local negativo, tem-se que uma expansão na quantidade de médicos poderia gerar redução das internações hospitalares por DPOC. A maior intensidade desse condicionante pode ser evidenciada nos estados de Minas Gerais e Bahia, e embora em menor vivacidade, verifica-se tons médios de laranja nos estados de Rondônia, Acre, Amazonas, Roraima, Pará, Mato Grosso, Goiás, Mato Grosso do Sul, Maranhão, Rio Grande do Norte, Rio Grande do Sul, Santa Catarina, Paraná, São Paulo e no Distrito Federal.

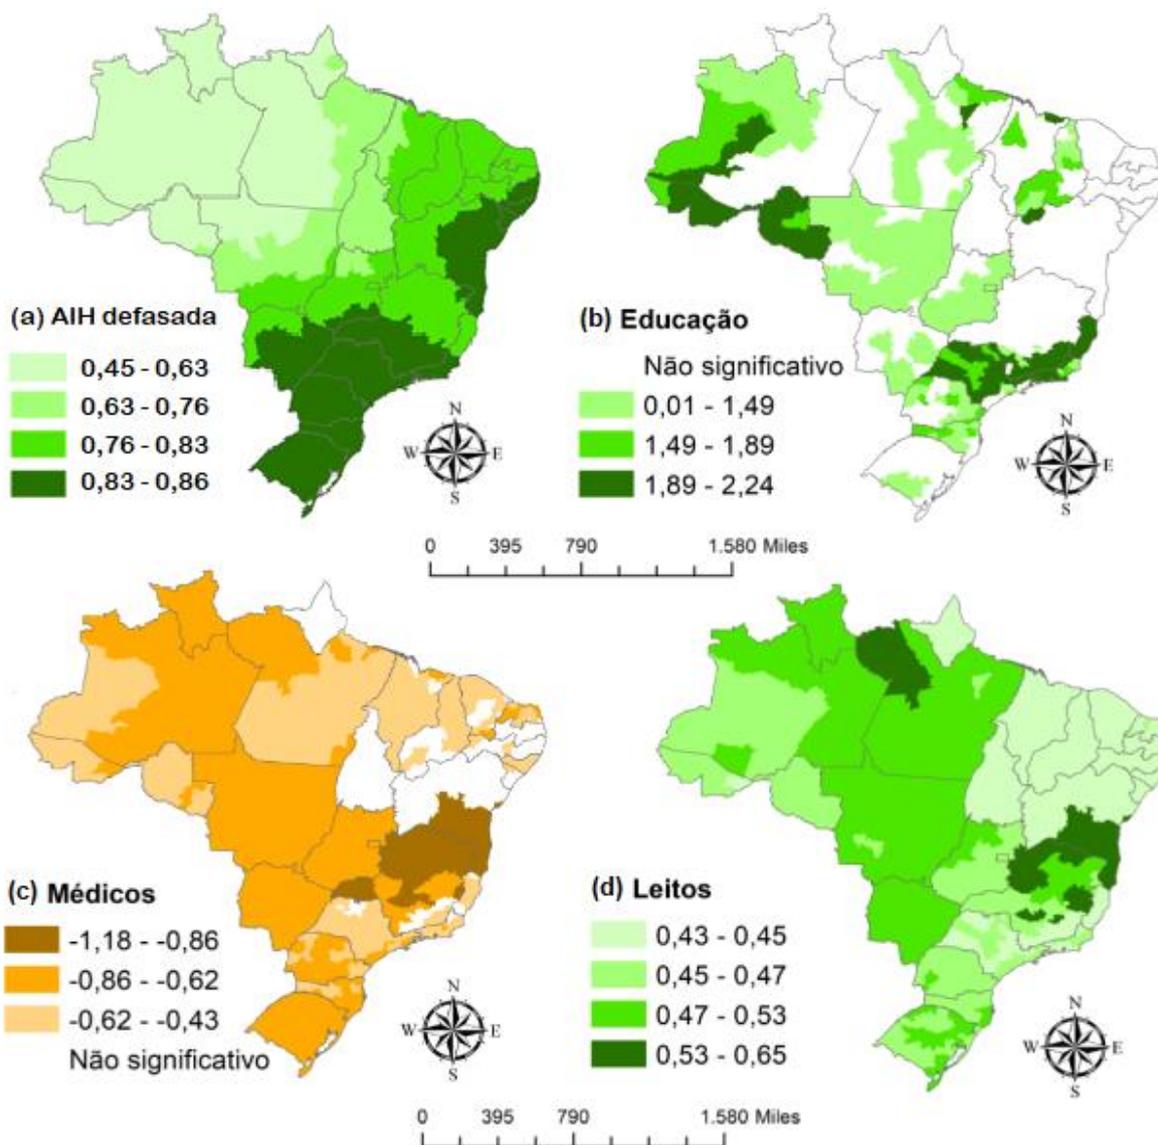


Figura 3 – Impacto dos coeficientes locais significativos, modelo SAR, Microrregiões do Brasil, 2016.

Fonte: Elaboração própria com base nos dados da pesquisa (2019). Nota: considerando teste $t_c = 1,96$, ao nível de significância de 5%.

Por fim, a variável leitos de internação (Figura 3d) apresenta sinal positivo em todas as microrregiões do país. Considerando seu efeito local positivo, tem-se que um aumento na quantidade de leitos de internação nas áreas destacadas (tons de verde) poderia gerar expansão das internações hospitalares por doenças pulmonares. A maior intensidade desse condicionante pode ser evidenciada nos estados do Pará, Minas Gerais e Bahia.

4 DISCUSSÃO

Os resultados da pesquisa permitiram observar que existem disparidades espaciais na morbidade hospitalar por DPOC entre as microrregiões do Brasil. Conforme verificado, em 2016, aglomerações do tipo AA foram encontradas no Centro-Oeste, Sudeste e Sul do Brasil, especialmente nos estados de Goiás, Minas Gerais, Paraná, Santa Catarina e Rio Grande do Sul. Nos estados de São Paulo, Mato Grosso e Mato Grosso do Sul é possível perceber esse tipo de

cluster, mas em menor quantidade. Assim, nessas localidades se concentravam microrregiões com alto número de internações hospitalares por DPOC, rodeados por microrregiões com também elevada morbidade pelo agravo.

Por outro lado, no mesmo período de análise, *clusters* do tipo BB foram observadas em grande parte do Norte e Nordeste (principalmente nos estados do Amazonas, Roraima, Pará, Amapá, Maranhão, Piauí, Ceará, Rio Grande do Norte, Pernambuco, Alagoas, Sergipe e Bahia) do país. Ou seja, nessas localidades se concentravam microrregiões com baixo número de internações por DPOC cercados por regiões com baixa quantidade dessa variável.

Em termos epidemiológicos, entre os anos 2008 e 2016, tanto o número de mortes quanto as internações devido a DPOC foram maiores nas regiões Sul e Sudeste do Brasil. Em 2016 a maior concentração de óbitos ocorreu no Sudeste (17,3 mil), seguido do Sul (9,1 mil), Nordeste (7,0 mil), Centro-Oeste (3,2 mil) e Norte (1,9 mil). Com relação as internações hospitalares por esse agravo, a região Sul apresentou maior número (35,2 mil). Na sequência, ficaram Sudeste (35,0 mil), Nordeste (16,0 mil), Centro-Oeste (7,4 mil) e Norte (4,6 mil) (BRASIL, 2019a).

Alguns estudos apontam que essas diferenças verificadas no Sul e Sudeste do Brasil podem ser explicadas devido às temperaturas mais baixas (GODOY et al., 2001; BRASIL, 2010; HELD; RIEBLER, 2012) e ao fato das maiores prevalências de tabagismo no país se encontrarem nessas duas regiões (VALENTE; MALTA, 2011; LEVY; DE ALMEIDA; SZKLO, 2012; TORRES; CUNHA; VALENTE, 2018). No entanto, existem outros fatores de risco que podem ajudar a entender a distribuição espacial das internações por DPOC, como socioeconômicos e demográficos, ambientais e de gestão em saúde (SOUSA et al., 2011; ARBEX et al., 2012).

Os resultados dos modelos econométricos espaciais permitiram constatar que o fator econômico (PIB per capita) apresentou associação positiva com o número de internações hospitalares por DPOC, em 2016. Esse resultado está relacionado com o fato de que a população com melhores condições socioeconômicas tem maior acesso a serviços médicos e medicamentos, no qual permitem realizar exames preventivos com maior regularidade e ter acesso a tratamentos adequados quando doentes, o que pode levar a um aumento do número de diagnósticos de DPOC. Essa elevação do diagnóstico, por sua vez, pode incorrer em uma alta morbidade hospitalar pela enfermidade (SILVA et al., 2016; GÖPFFARTH; KOPETSCH; SCHMITZ, 2016).

A educação influencia de diversas formas a qualidade de vida da população. Na presente pesquisa, a relação entre o índice Firjan de desenvolvimento Municipal para a educação e internações por DPOC se mostrou positiva, apresentando dependência espacial tanto no modelo estimado globalmente, abordando características gerais, quanto localmente, ao serem consideradas as condições locais dessas regiões (modelo GWR). A educação permite melhor compreensão sobre saúde preventiva, fazendo com que os indivíduos procurem por mais informações sobre as doenças, realizem mais exames preventivos, busquem ter hábitos mais saudáveis e a utilizar de forma mais frequente e eficiente os serviços e insumos de saúde (GÖPFFARTH; KOPETSCH; SCHMITZ, 2016).

Por conta da grande área de contato entre a superfície do sistema respiratório e o meio ambiente, a qualidade do ar interfere fortemente na saúde respiratória. Os pacientes portadores de DPOC são vulneráveis ao estresse adicional em vias respiratórias causado por diferentes agentes agressores, como o tabagismo e aos poluentes do ar em ambientes internos e externos (SALVI; BARNES, 2009). Contudo, os resultados dessa pesquisa apontaram que o aumento de veículos nas microrregiões diminui as internações por esse agravo. Isso pode estar ocorrendo em virtude de a variável não estar captando a exposição ao ar poluído, como era esperado. Na verdade, o resultado encontrado pode estar relacionado com o fato de que microrregiões com

maior número de automóveis seriam regiões com melhores condições socioeconômicas, o que permitiria ter maior acesso a serviços de saúde para a população.

No que se refere aos condicionantes de gestão, a associação entre a variável dependente e a presença de leitos de internação é positiva, apresentando dependência espacial tanto no modelo estimado globalmente quanto localmente, pois o maior acesso a hospitais públicos com leitos tende a aumentar as internações pela agilidade de acesso aos recursos secundários e facilidade dos médicos em induzir o paciente a internação hospitalar (PAZÓ et al., 2017).

Para o fator número de médicos, observou-se efeito negativo, apresentando também dependência espacial global e local. Esse resultado está relacionado com o maior acesso aos atendimentos e orientações às famílias referentes aos métodos de prevenção da DPOC, o que pode auxiliar na diminuição das internações hospitalares por essa doença (FARIA; SANTANA, 2016; SANTOS; JACINTO, 2017).

E por fim, as ações de promoção e prevenção à saúde apresentou efeito positivo em relação às internações por DPOC, sendo que a dependência espacial pode ser observada tanto globalmente quanto localmente, para o ano de 2016. Ações de promoção e prevenção da saúde são ações voltadas para a melhoria na qualidade de vida e a redução dos riscos à saúde, por meio da construção de políticas públicas saudáveis, que proporcionem melhorias no modo de viver (BRASIL, 2009). Essas ações, principalmente quando associadas com a Atenção Básica permite auxiliar na detecção precoce e georeferenciamento dos casos dessa doença, podendo aumentar os registros de internações (RASELLA, 2013; REIS, 2014).

5 CONSIDERAÇÕES FINAIS

O objetivo da presente pesquisa foi analisar a distribuição espacial da morbidade hospitalar do SUS pela DPOC da população com 40 anos ou mais entre as microrregiões do Brasil e seus determinantes: socioeconômicos, demográfico, ambiental e de gestão de saúde, em 2016. Para isso, utilizou-se a Análise Exploratória de Dados espaciais (AEDE), a especificação dos modelos econométricos espaciais e o modelo GWR.

De acordo com os resultados foi possível verificar a existência de dependência espacial da morbidade hospitalar por DPOC entre as microrregiões do Brasil, sendo observados aglomerações do tipo AA no Centro-Oeste, Sudeste e Sul e do tipo BB no Norte e Nordeste do país. Constatou-se que o PIB per capita, índice Firjan de educação, leitos de internação e ações de promoção e prevenção em saúde apresentaram associação positiva com o número de internações hospitalares por esta enfermidade. Já as variáveis densidade demográfica e número de médicos exibiram efeito negativo. Ressalta-se ainda a influência das regiões vizinhas na determinação dos condicionantes das internações.

Pelo modelo GWR foi possível observar que as internações hospitalares defasada, o índice Firjan de educação, número de médicos e leitos de internação exercem impacto local sobre o número de internações por DPOC nas microrregiões brasileiras em 2016.

As desigualdades ao acesso de serviços de saúde observadas por todo o Brasil, como a distribuição irregular de profissionais de saúde, leitos de internação e dificuldade na realização de atendimentos preventivos na Atenção Básica, podem ajudar a refletir sobre as diferenças encontradas na morbidade hospitalar por DPOC. Por isso, ações que objetivem maior equidade no acesso aos serviços de saúde, qualificação profissional e equipes que atuem sobre a promoção de hábitos saudáveis, conscientização dos sintomas da enfermidade e da importância da prevenção são essenciais para a redução da ocorrência desta enfermidade.

O tabagismo é considerado como um dos principais fatores associados à DPOC. No entanto, cada vez mais surgem estudos que sugerem que existem outros fatores ambientais que podem colocar em risco a saúde dos indivíduos, como a exposição aos poluentes ambientais, ambientes de trabalho com poeira e fumaça, etc., contribuindo para o aumento da mortalidade

e morbidade, principalmente por doenças respiratórias. Os resultados obtidos nesta pesquisa encontraram associação negativa da densidade veicular, não sendo a melhor *proxy* para medir a poluição ambiental. De qualquer maneira é importante orientar as pessoas quanto à adoção de medidas preventivas que busquem reduzir os efeitos dos poluentes presentes nos ambientes externos e internos, reduzindo os efeitos adversos associados a essa exposição.

REFERÊNCIAS

ALMEIDA, E. **Econometria Espacial**. Campinas–SP. Alínea, 2012.

ALMEIDA, E. S.; PEROBELLI, F. S.; FERREIRA, P.G. Existe convergência da produtividade agrícola espacial no Brasil? **Revista de Economia e Sociologia Rural**, v. 46, p. 31-52, 2008.

ANSELIN, L.; BERA, A. K. **Spatial dependence in linear regression models with an introduction to spatial econometrics**. Statistics Textbooks and Monographs, v. 155, p. 237-290, 1998.

ANSELIN, L. **Spatial econometrics: methods and models**. Springer Science & Business Media, 2013.

ANTUNES, F. P.; COSTA, M. C. N.; PAIM, J. S.; VIEIRA-DA-SILVA, L. M.; CRUZ, A. A.; NATIVIDADE, M.; BARRETO, M. I. Desigualdades sociais na distribuição espacial das hospitalizações por doenças respiratórias. **Caderno de Saúde Pública**, v. 29, n. 07, p. 1346-1356, 2013.

ARBEX, M. A.; SANTOS, U. P.; MARTINS, L. C.; SALDIVA, P. H. N.; PEREIRA, L. A. A.; BRAGA, A. L. F. A poluição do ar e o sistema respiratório. **Jornal Brasileiro de Pneumologia**, v. 38, n. 5, p. 643-655, 2012.

BRASIL. Ministério da Infraestrutura. Estatísticas DENATRAN. Disponível em: <<https://infraestrutura.gov.br/relatorios-estatisticos.html>>. Acesso em 12 de out. 2019b.

BRASIL. Agência Nacional de Saúde Suplementar. Manual técnico de promoção da saúde e prevenção de riscos e doenças na saúde suplementar. 3. ed. rev. e atual. – Rio de Janeiro: ANS, 2009. Disponível em: <https://www.ans.gov.br/images/stories/Materiais_para_pesquisa/Materiais_por_assunto/ProdEditorialANS_Manual_Tecnico_de_Promocao_da_saude_no_setor_de_SS.pdf>. Acesso em: 20 de nov. 2019.

BRASIL. Ministério da Saúde. Departamento de Informática do SUS. Informações de Saúde, 2019. Disponível em: <<http://datasus.saude.gov.br>>. Acesso em: 20 de nov. 2019a.

BRASIL. Ministério da Saúde. Protocolo Clínico e Diretrizes Terapêuticas. Portaria SAS/MS nº 609. Doença Pulmonar Obstrutiva Crônica. 2013. Disponível em: <<https://portalquivos2.saude.gov.br/images/pdf/2014/abril/02/pcdt-doenca-pulmonar-obs-cronica-livro-2013.pdf>>. Acesso em 20 de nov. 2019.

Brasil. Ministério da Saúde. Secretaria de Atenção à Saúde. Departamento de Atenção Básica. Doenças respiratórias crônicas. Brasília: Ministério da Saúde, 2010.

CAO, Q.; LIANG, Y.; NIU, X. China's air quality and respiratory disease mortality based on the spatial panel model. **International journal of environmental research and public health**, v. 14, n. 9, p. 1081, 2017.

CARNEIRO, A. C. C. et al. Questionários de qualidade de vida relacionada à saúde na doença pulmonar obstrutiva crônica (DPOC): revisão de literatura. 2018.

CHASCO, C. Geodaspace: a resource for teaching spatial regression models. **Rect@**, n. 4, p. 119, 2013.

CONSENSO BRASILEIRO SOBRE DOENÇA PULMONAR OBSTRUTIVA CRÔNICA II - DPOC. **Jornal Brasileiro de Pneumologia**, v. 30, supl. 5, p. 1-42, 2004.

DA SILVA, L. N. S.; BORGES, M. J.; PARRÉ, J. L. Distribuição Espacial da Pobreza no Paraná. **Revista de Economia**, v. 39, n. 3, 2013.

DOMINGOS, C. M. et al. Distribuição do Profissional Médico na Macrorregião Norte do Paraná: Inequidade entre os Municípios de Diferentes Portes Populacionais. **Revista Brasileira de Educação Médica**, v. 41, n. 1, p. 117-125, 2017.

FARIA, R.; SANTANA, P. Variações espaciais e desigualdades regionais no indicador de mortalidade infantil do estado de Minas Gerais, Brasil. **Saúde e Sociedade**, v. 25, p. 736-749, 2016.

FIRJAN. Índice Firjan de Desenvolvimento Municipal. Disponível em: <<https://www.firjan.com.br/ifdm/>>. Acesso em 02 de out. 2019.

FISCHER, M. M.; GETIS, A. **Handbook of Applied Spatial Analysis**. Springer Berlin Heidelberg, 2010.

FLORAX, R. J.; FOLMER, H.; REY, S. J. Specification searches in spatial econometrics: the relevance of Hendry's methodology. **Regional Science and Urban Economics**, v. 33, n. 5, p. 557-579, 2003.

FORO DE LAS SOCIEDADES RESPIRATORIAS INTERNACIONALES. El impacto global de la Enfermedad Respiratoria – Segunda edición. México, Asociación Latinoamericana de Tórax, 2017.

FOTHERINGHAM, A. S.; BRUNSDON, C.; CHARLTON, M. **Geographically Weighted Regression: The Analysis of Spatially Varying Relationship**. Chichester: John Wiley, 2002.

GODOY, D. V.; ZOTTO, C. D.; BELLICANTA, J.; WESCHENFELDER, R. F.; NACIF, S. B. Doenças respiratórias como causa de internações hospitalares de pacientes do Sistema Único de Saúde num serviço terciário de clínica médica na região nordeste do Rio Grande do Sul. **J Pneumol**, v. 27, n. 4, p. 193-198, 2001.

GÖPFFARTH, D.; KOPETSCH, T.; SCHMITZ, H. Determinants of regional variation in health expenditures in Germany. **Health economics**, v. 25, n. 7, p. 801-815, 2016.

GREENE, W. H. **Econometric analysis**. Pearson Education Limited, 2012.

HELD, L.; RIEBLER, A. A conditional approach for inference in multivariate age-period-cohort models. **Statistical Methods in Medical Research**, v. 21, n. 4, p. 311–329, ago. 2012.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA – IBGE. Produto interno bruto dos municípios. Disponível em: <https://www.ibge.gov.br/estatisticas/economicas/contas-nacionais/9088-produto-interno-bruto-dos-municipios.html?=&t=o-que-e>. Acesso em 02 de out. 2019.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA – IBGE. Área dos municípios. Disponível em: <https://www.ibge.gov.br/geociencias/organizacao-do-territorio/estrutura-territorial/15761-areas-dos-municipios.html?=&t=downloads>. Acesso em 02 de out. 2019.

KO, F. W.; HUI, D. S. Air pollution and chronic obstructive pulmonary disease. **Respirology**, v. 17, n. 3, p. 395-401, 2012.

MADHU, B. et al. Spatio-Temporal Pattern of Breast Cancer-Case Study of Southern Karnataka, India. **Journal of clinical and diagnostic research: JCDR**, v. 10, n. 4, p. LC20, 2016.

LEE, Jongmin et al. Factors associated with chronic obstructive pulmonary disease exacerbation, based on big data analysis. **Scientific reports**, v. 9, n. 1, p. 6679, 2019.

LESAGE, J. P.; PACE, R. K. **Introduction to spatial econometrics**. CRC Press, Boca Raton, 2009.

LEVY, D.; DE ALMEIDA, L. M.; SZKLO, A. The Brazil SimSmoke policy simulation model: the effect of strong tobacco control policies on smoking prevalence and smoking-attributable deaths in a middle income nation. **PLoS Med.**, v. 9, n. 11, 2012.

LU, B. et al. Geographically weighted regression with a non-Euclidean distance metric: a case study using hedonic house price data. **International Journal of Geographical Information Science**, v. 28, n. 4, p. 660-681, 2014.

PAZÓ, R.G. et al. Panorama das internações por condições sensíveis à atenção primária no Espírito Santo, Brasil, 2000 a 2014. **Revista Brasileira de Medicina de Família e Comunidade**, v. 12, n. 39, p. 1-12, 2017.

PENNA, K. E. D. V. N. Testes HEGY de raízes unitárias sazonais: efeitos de observações atípicas, erros de medida e quebras estruturais. **Dissertação** (Mestrado em Estatística) – Instituto de Matemática e Estatística, Universidade de São Paulo, São Paulo, 2009.

PERINETTI, A. **Análisis espacial de factores socioeconómicos, de servicios de salud y de mortalidad por cáncer de mama, Argentina, 2009-2011**. 155 f. Dissertação (Mestrado) – Escola Nacional de Saúde Pública Sergio Arouca, Rio de Janeiro, 2015.

RASELLA, D. Impacto do Programa Água para Todos (PAT) sobre a morbi-mortalidade por diarreia em crianças do Estado da Bahia, Brasil. **Cadernos de Saúde Pública**, v. 29, p. 40-50, 2013.

REIS, M. Public primary health care and children's health in Brazil: evidence from siblings. **Journal of Population Economics**, v. 27, n. 2, p. 421-445, 18 ago. 2014.

SALVI, S. S.; BARNES, P. J. Chronic obstructive pulmonary disease in non-smokers. **Lancet**, v. 374, n. 9691, p. 733-43, 2009.

SANTOS, A. M. A.; JACINTO, P. A. O Impacto do Programa Saúde da Família Sobre a Saúde das Crianças da Área Rural do Brasil. **Revista de Economia e Sociologia Rural**, v. 55, n. 2, p. 227-246, 2017.

SILVEIRA, R. P.; PINHEIRO, R. Entendendo a necessidade de médicos no interior da Amazônia-Brasil. **Rev. bras. educ. méd**, p. 451-459, 2014.

SOUZA, C. A.; CÉSAR, C. L. G.; BARROS, M. B. A.; CARANDINA, L.; GOLDBAUM, M.; PEREIRA, J. C.R. Doença Pulmonar Obstrutiva Crônica e fatores associados em São Paulo, SP, 2008-2009. **Revista de Saúde Pública**, v. 45, p. 887-896, 2011.

TORRES, K. D. P.; CUNHA, G. M.; VALENTE, J. G. Tendências de mortalidade por doença pulmonar obstrutiva crônica no Rio de Janeiro e em Porto Alegre, 1980-2014. **Epidemiologia e Serviços de Saúde**, v. 27, p. e2017139, 2018.

TYSZLER, M. **Econometria espacial**: discutindo medidas para a matriz de ponderação espacial. 2006.

VALENTE, J. G.; MALTA, D. C. Tendências do tabagismo na população adulta das capitais brasileiras: uma análise dos dados de inquéritos telefônicos de 2006 a 2009. **Rev Bras Epidemiol**, v. 14, supl. 1, p. S103-14, 2011.

YANG, Y. et al. Risk factors of chronic obstructive pulmonary disease among adults in Chinese mainland: a systematic review and meta-analysis. **Respiratory medicine**, v. 131, p. 158-165, 2017.

ZHOU, H. B. et al. Spatio-temporal analysis of female breast cancer incidence in Shenzhen, 2007–2012. **Chinese journal of cancer**, v. 34, n. 3, p. 13, 2015.