

UMA ANÁLISE ESPACIAL SOBRE A SAÚDE NOS MUNICÍPIOS BRASILEIROS EM 2010

Marcio Marconato¹
Odirlei Fernando Dal Moro²
José Luiz Parré³

RESUMO

O objetivo do presente estudo é analisar as condições de saúde nos municípios brasileiros no ano de 2010 e verificar sua relação com as variáveis renda *per capita*, gasto *per capita* com saúde, educação e infraestrutura domiciliar. A metodologia utilizada foi a Análise Exploratória de Dados Espaciais (AEDE) e os modelos econométricos espaciais. Para testar a presença de autocorrelação espacial global foi utilizado o I de Moran Global; e através do I de Moran Local, foi possível verificar os *clusters* espaciais. Os modelos econométricos espaciais permitiram verificar o impacto das variáveis renda *per capita*, educação, gasto com saúde e infraestrutura sobre o índice de saúde FIRJAN. Os resultados apontaram autocorrelação espacial positiva do indicador de saúde nos municípios brasileiros, a análise local revelou que os *clusters* com elevado indicador estão situados nas regiões Sul, Sudeste e Centro-Oeste, as aglomerações com baixo índice estão no Norte e Nordeste. O modelo econométrico com defasagem espacial se mostrou mais adequado para explicar a relação entre o índice de saúde FIRJAN e as variáveis explicativas.

Palavras-chave: AEDE, I de Moran, FIRJAN, Saúde.

ABSTRACT

The aim of this study is to analyze the health conditions in Brazilian cities in 2010 and to verify its relationship among the variable per capita income, per capita spending on health, education and household infrastructure. The methodology used was the Exploratory Spatial Data Analysis (ESDA) and spatial econometric models. To test the presence of global spatial autocorrelation was used Moran's I Global; and the Moran's I Local, it was possible to verify the spatial clusters. The spatial econometric models allowed us to verify the impact of variables per capita income, education, health expenditure and infrastructure of the health index FIRJAN. The results showed positive spatial autocorrelation health indicator in Brazilian cities, local analysis showed that clusters with high indicator are located in the South, Southeast and Midwest; agglomerations with low rates are in the North and Northeast. The econometric model with spatial lag was more appropriate to explain the relationship between the health index FIRJAN and the explanatory variables.

Keywords: ESDA, Moran's I, FIRJAN, Health.

JEL: C01, C49, I32, I39, Z13.

ÁREA 2: DESENVOLVIMENTO ECONÔMICO

¹Doutorando em Teoria Econômica na Universidade Estadual de Maringá (UEM) – E-mail: marconatoce@bol.com.br.

²Doutorando em Teoria Econômica e professor do Departamento de Economia da Universidade Estadual de Maringá (UEM) – E-mail: odirleifernando@yahoo.com.br.

³Doutor em economia pela Escola Superior de Agricultura Luiz Queiroz (ESALQ) e professor da Universidade Estadual de Maringá (UEM) – E-mail: jlparre@uem.com.

1 INTRODUÇÃO

Nos últimos anos, diversas políticas públicas têm sido implementadas no Brasil para combater a pobreza e a desigualdade, sendo o Programa Bolsa Família um dos mais conhecidos do público em geral. Com a diminuição da pobreza e desconcentração de renda acredita-se que os indicadores de saúde também tenham melhorado. Contudo, ainda persiste no Brasil a extrema pobreza, a desigualdade social, o baixo desenvolvimento educacional e também as péssimas condições de infraestrutura domiciliar. Grande parte destas carências, tanto sociais quanto regionais, estão localizadas nas regiões Norte e Nordeste.

O conhecimento das condições de saúde da população é uma das atividades centrais do poder público, iniciada com o registro sistemático de dados de mortalidade e de sobrevivência. Com os avanços no controle das doenças infecciosas e a melhor compreensão do conceito de saúde e de seus determinantes sociais, passou-se a analisar outras dimensões do estado de saúde, medidas por dados de morbidade, incapacidade, acesso a serviços, qualidade da atenção, condições de vida e fatores ambientais, entre outros. Os indicadores de saúde foram desenvolvidos para facilitar a quantificação e a avaliação das informações produzidas com tal finalidade (RIPSA, 2008). Sendo o índice FIRJAN-Saúde um dos indicadores que busca retratar as condições de saúde em todos os municípios brasileiros (FIRJAN, 2016).

O Brasil apresenta grande extensão territorial e diversas diferenças sociais, culturais e econômicas entre suas regiões que podem levar a desigualdades nas condições de saúde. Nesse sentido, os estudos focados nos municípios são de grande relevância, pois permitem conhecer de forma mais detalhada a condição socioeconômica da população, já a análise exploratória de dados espaciais auxilia a visualização geográfica dos dados possibilitando uma informação mais pontual das unidades com melhores e piores índices de saúde no Brasil. Segundo o estudo do IPEA (2012), na área da saúde, a distribuição dos serviços reflete as desigualdades regionais, sendo as regiões Sul e Sudeste as que apresentaram a maior concentração de profissionais de saúde com nível superior (3,7 profissionais por mil habitantes), ao passo que a média nacional foi de 3,1. Nas regiões Norte e Nordeste esses números foram de 1,9 e 2,4, respectivamente.

O rápido desenvolvimento de tecnologias para análise de dados no espaço geográfico tem oferecido possibilidades inovadoras ao estudo das condições de saúde e de suas tendências, propiciando melhor compreensão dos fatores socioeconômicos e ambientais, entre outros, que determinam as condições de vida e o estado de saúde da população. A apropriação desse instrumental pelo setor saúde é sumamente importante no Brasil, onde acentuadas desigualdades se evidenciam não apenas entre as grandes regiões, os estados e os municípios, mas também no interior destas áreas, sobretudo nos espaços urbanos. Sobrepondo-se a concentração de situações diferenciadas que caracteriza o território brasileiro, as transformações demográficas observadas nas últimas décadas potencializam a dinâmica de distribuição de doenças e agravos, bem como de demanda e acesso aos serviços (MS, 2007).

Nesse contexto, o objetivo do presente estudo é analisar as condições de saúde nos municípios brasileiros no ano de 2010 e verificar sua relação com as variáveis renda *per capita*, gasto *per capita* com saúde, educação e infraestrutura domiciliar. A justificativa para a elaboração desse trabalho se dá pelo fato das condições de saúde da população nos municípios serem de interesse da sociedade como um todo e dos agentes públicos. Além do mais, a análise exploratória de dados espaciais permite identificar as regiões com baixos indicadores de saúde, o que exige medidas e ações por parte dos governos das três esferas (federal, estadual e municipal) a fim de melhorar as condições de vida da população nos municípios brasileiros. Visto que a análise mais detalhada por municípios depende da disponibilidade dos dados, será utilizado as informações do Censo demográfico do IBGE do ano de 2010.

A hipótese a ser investigada é a de que municípios com altos indicadores de saúde estão, geralmente, localizados em regiões onde os municípios vizinhos apresentam condições semelhantes, ocorrendo dependência de vizinhança, pois, os indivíduos residentes em unidades com serviço de saúde público precário tendem a recorrer a municípios mais próximos com melhores condições. Por conta de outros estudos que investigaram variáveis socioeconômicas relacionadas a pobreza, a concentração de renda e o índice de desenvolvimento humano e indicarem as regiões Norte e Nordeste como as mais carentes do Brasil, acredita-se que tais indicadores mostrarão essa mesma percepção, haja vista que

normalmente regiões mais pobres, com desigualdade de renda e baixos indicadores educacionais apresentam péssimas condições de saúde.

O artigo está dividido em cinco seções, além desta introdução, que apresenta o objetivo, a justificativa e a hipótese. A segunda seção apresenta a revisão de literatura, onde é apresentada resumidamente uma discussão sobre o tema desenvolvimento, a utilização dos indicadores e alguns trabalhos empíricos. Na terceira seção é apresentado o procedimento metodológico, em seguida os resultados encontrados e por último as considerações finais.

2 REVISÃO DE LITERATURA

Desde o final da Segunda Guerra Mundial até o início dos anos 1970, o termo desenvolvimento era entendido como sinônimo de crescimento econômico, tendo na industrialização seu principal alavanque, os projetos de industrialização haviam sido insuficientes para garantir processos socialmente incluídos, capazes de eliminar a pobreza e combater as desigualdades (DIAS, 2011).

O conceito de desenvolvimento vem mudando e deixando de abranger somente aspectos econômicos, além da renda *per capita*, fatores relacionados à educação, saúde e infraestrutura urbana têm, cada vez mais, pautado as discussões em busca de resultados que coloquem as regiões em patamares mais elevados de bem-estar social. As discussões em torno do desenvolvimento regional abordam fatores e as consequências da grande heterogeneidade dos estágios de desenvolvimento entre municípios e regiões. Com isso, o tema das desigualdades regionais se constitui em um dos aspectos mais relevantes do processo de desenvolvimento (XERXENEVSKY e FOCHEZATTO, 2011).

O desenvolvimento econômico é visto não apenas como um processo de enriquecimento do país, mas como uma melhoria da vida das pessoas, incluso neste contexto o acesso à educação e a saúde. Está melhora, embora necessária, não é unicamente ancorada pelo crescimento econômico, ou seja, para uma melhor análise sobre indicadores sociais é necessário a utilização de outros dados além do Produto Interno Bruto e/ou PIB *per capita* (SANDRONI, 1999).

Uma importante contribuição sobre a temática do desenvolvimento no Brasil foi dada por Celso Furtado. O estudo de Mendes e Teixeira (2004), discute as principais ideias de Furtado, no que se refere ao processo de desenvolvimento econômico brasileiro. Os autores destacam os aspectos regionais e o papel do mercado interno como o fator dinâmico no processo de crescimento e do desenvolvimento econômico do país, e destacam que segundo a ótica de Furtado o crescimento econômico não é condição suficiente para superar o subdesenvolvimento, sendo necessário a aplicação de reformas estruturais importantes, entre as quais, a superação das desigualdades socioeconômicas, que se refletem em disparidades regionais de renda, produto, educação, salário, saúde, etc.

A utilização dos indicadores sociais para mostrar a condição de vida da população ganhou força nos anos 1990 com a apresentação do Índice de Desenvolvimento Humano (IDH) criado pelos economistas Mahbub ul Haq e Amartya Sen. Posteriormente, no Brasil foram sendo desenvolvidos índices que refletissem a condição de vida da população em diferentes regiões, no Paraná é calculado o Índice IPARDES de desenvolvimento municipal (IPDM) pelo Instituto Paranaense de Desenvolvimento Econômico e Social (IPARDES), no Rio Grande do Sul o índice IDESE busca refletir a condição de vida da população gaúcha. No entanto, a partir dos anos 2000 a Federação das Indústrias do Rio de Janeiro (FIRJAN) passou a calcular o IFDM que mostra a condição de vida da população em todos os municípios brasileiros, uma de suas dimensões busca uma reflexão sobre a condição de saúde da população.

Em termos de aplicação empírica, alguns trabalhos interessantes sobre o desenvolvimento humano foram sendo realizados no Brasil, entres estes pode ser destacado o estudo de Melo (2007), no qual a autora analisou as condições socioeconômicas nos municípios localizados no Sudoeste paranaense. Os resultados mostraram que o índice médio de desenvolvimento se situou em aproximadamente 34 (considerando uma escala entre 0 e 100), e que para 16 municípios o indicador se situou acima deste valor e para 21 municípios abaixo da média. A ordenação das unidades de acordo com o grau de desenvolvimento revelou que mais da metade dos municípios apresentou baixo nível de desenvolvimento.

Já o estudo realizado por Melo e Parré (2007), procurou mensurar o índice de desenvolvimento rural dos municípios paranaenses, identificando os fatores determinantes do desenvolvimento desses

municípios. Os autores identificaram um grande número de municípios paranaenses em situação de baixo nível de desenvolvimento rural, o que mostra que, mesmo estando o processo de modernização da agricultura do Paraná bastante difundido, esse processo não foi expandido de forma homogênea em todo o espaço rural do estado.

O trabalho realizado por Macedo et al. (2011) buscou desenvolver um índice de desenvolvimento sustentável para os municípios do estado do Rio de Janeiro. A metodologia aplicada teve como base o método de apoio multicritério à decisão (AMD): a análise envoltória de dados (DEA), levando em conta vetores de desempenho de naturezas distintas, relacionados a questões econômicas (capacidade de investimento e PIB), sociais (educação, saúde, segurança e transporte) e ambientais (saneamento básico). Os resultados mostram o nível de desenvolvimento sustentável de cada município do estado do Rio de Janeiro e destacou as unidades com melhores e piores indicadores, o que contribuiu para o estabelecimento de políticas públicas que visem à melhoria do nível de sustentabilidade dos municípios do estado do Rio de Janeiro.

Cavalcante et al. (2010) buscaram averiguar se houve diminuição das desigualdades no IDH dos municípios do Acre, entre 1991 e 2000. Mais especificamente, os autores procuraram verificar se houve diminuição das disparidades socioeconômicas, de tal modo que isso levasse a um processo de convergência do referido índice, bem como determinar a magnitude desse processo e o tempo necessário para os municípios alcançarem o estado estacionário. Tal estudo fez-se necessário em virtude das diferenças observadas nos indicadores econômicos, sociais e geográficos, entre os municípios do estado.

Já o estudo realizado por Shikida (2009), buscou relacionar crimes violentos e o índice de desenvolvimento econômico. Utilizando o método dos componentes principais, ferramenta da estatística multivariada semelhante à análise fatorial, para calcular o Índice de Desenvolvimento Socioeconômico (IDS) para os 399 municípios do estado do Paraná e 10 variáveis que buscam refletir o nível de desenvolvimento humano, educação, saúde, renda, cultura e finanças públicas municipais. O trabalho concluiu que houve uma correlação negativa entre os crimes violentos e o IDS (os primeiros tendem a cair quando aumenta o IDS), embora a correlação encontrada tenha sido muito fraca (-0,06).

Embora muitos artigos sobre desenvolvimento econômico tenham sido escritos nas últimas décadas, percebe-se que os estudos que utilizam a econometria espacial ganharam força no Brasil, principalmente nos últimos anos. Segundo Golgher (2015), isso ocorreu em decorrência da disponibilidade de dados georreferenciados e do surgimento de softwares específicos para esse fim. Para Almeida (2012), essas condições permitiram que a econometria espacial começasse a ser aplicada em diversas áreas, como criminalidade, pobreza, economia, entre outras.

Dentre os trabalhos que discutem os aspectos de desenvolvimento no Brasil em termos geográficos, podem ser destacados alguns estudos. Lima, Caldarelli e Camara (2014) analisaram diversos indicadores de desenvolvimento da saúde para o estado do Paraná utilizando a análise exploratória de dados espaciais e concluíram que existe autocorrelação espacial no território paranaense, ou seja, os municípios com bons indicadores de saúde tendem a estar cercados por vizinhos na mesma situação.

A análise da dependência espacial do desenvolvimento humano no Rio Grande do Norte foi estudada por Costa et al. (2007), os autores buscaram verificar o comportamento do IDHM nas seguintes dimensões: educação, longevidade e renda *per capita*. A metodologia empregada para detecção da dependência espacial do IDHM foi a estatística do Índice de Moran Global e Local, que calcula a autocorrelação espacial. Os resultados indicaram haver uma dependência espacial nos municípios potiguar para os indicadores do IDHM, confirmando que a localização geográfica tem importante papel no desenvolvimento do estado.

A fim de compreender melhor o comportamento espacial do IDHM nos municípios do Espírito Santo, Lorena, Bergamaschi e Leite (2011), analisaram a dependência espacial entre os municípios desse estado. Para verificar a presença de autocorrelação espacial entre as variáveis, foi utilizado o Índice de Moran global e local. Os resultados revelaram haver dependência espacial para as dimensões longevidade, renda e PIB no Espírito Santo. A região metropolitana e a região Noroeste do estado foram às regiões que, para as três variáveis em análise, apresentaram os maiores índices de autocorrelação entre os municípios, caracterizando a existência de agrupamentos regionais bem distintos.

O estudo de Lins et al. (2015), buscou verificar a dependência espacial do Índice de Desenvolvimento Humano Municipal (IDHM), no Nordeste brasileiro, entre 2000 e 2010, buscando identificar padrões de clusters de alto e baixo crescimento e, assim, verificar se a evolução desse indicador está sujeita à interação espacial. Além disso, procurou-se analisar se os municípios com valores menores do IDHM em 2000 tiveram um crescimento mais elevado desse índice do que municípios com valores maiores para o mesmo ano. A metodologia empregada foi à análise exploratória de dados espaciais (AEDE) para verificar a hipótese de aleatoriedade espacial global da evolução do IDHM, cujo instrumental empregado foi à estatística I de Moran, que detectou a presença de autocorrelação espacial positiva. Os resultados indicaram o modelo de Defasagem com Erro Espacial (SAC) como o mais apropriado para avaliar a taxa de crescimento do IDHM na região Nordeste.

3 METODOLOGIA

Nessa secção é apresentado o procedimento metodológico. Primeiramente é discutida a análise exploratória de dados espaciais, em seguida os modelos econométricos e por último a descrição das variáveis e os respectivos bancos de dados.

3.1 Análise Exploratória dos Dados Espaciais

A análise exploratória dos dados espaciais (AEDE) trata diretamente dos efeitos decorrentes da dependência espacial e da heterogeneidade espacial (ALMEIDA, 2012). A dependência espacial ou autocorrelação espacial ocorre quando o valor de uma variável numa região i , por exemplo, está relacionada com o valor da mesma variável da região j . Já a heterogeneidade espacial surge ao se utilizar dados de unidades espaciais muito distintas para explicar um mesmo fenômeno (ANSELIN, 1988). Utiliza-se a AEDE para descrever e visualizar distribuições espaciais, identificar localidades atípicas, descobrir padrões de associação espacial (clusters espaciais) e sugerir diferentes regimes espaciais e outras formas de instabilidade (ALMEIDA; PEROBELLI; FERREIRA, 2008).

O primeiro passo no estudo da AEDE é testar a hipótese de que os dados espaciais sejam distribuídos aleatoriamente. Intuitivamente, aleatoriedade espacial significa que os valores de um atributo numa região não dependem dos valores deste atributo nas regiões vizinhas (ALMEIDA, 2012). Os dados espaciais podem ser definidos como sendo a observação de uma variável que se encontra associada a uma localização no espaço geográfico (SABATER; TUR; AZORÍN, 2011). É importante ressaltar que, segundo Almeida (2012), essa análise é mais apropriada na investigação de variáveis espacialmente densas ou intensivas, ou seja, que são divididas por algum indicador de intensidade (*percapita*, etc.).

A partir do uso da AEDE é possível extrair medidas de autocorrelação espacial global e local, investigando a influência dos efeitos espaciais por intermédio de métodos quantitativos (ANSELIN, 1988). Contudo, para desenvolver a AEDE deve-se, previamente, impor um arranjo que permita estimar coeficientes que deem a ideia do grau de interação entre as unidades espaciais (MEDEIROS e NETO, 2011).

- **Matrizes de Pesos Espaciais**

A dependência espacial é uma das características dos dados espaciais, pode se manifestar em diversos campos de estudo. Entretanto, um aspecto fundamental na determinação da autocorrelação espacial é a consideração do grau de vizinhança o qual se deseja realizar a análise de dependência espacial. Uma vez adotado o critério de vizinhança, pode ser construída a matriz de pesos espaciais (SABATER; TUR; AZORÍN, 2011). As matrizes de pesos espaciais são baseadas na contiguidade e podem ser definidas de acordo com a vizinhança, a distância tanto geográfica quanto socioeconômica, bem como uma combinação de ambas (ALMEIDA, 2012). Com base nesse conceito de contiguidade, é atribuído um valor unitário na matriz quando duas regiões são vizinhas; caso contrário, atribui-se um valor nulo. Nesse caso, temos que:

$$W_{ij} = \{1 \text{ se } i \text{ e } j \text{ são contíguos}; 0 \text{ se } i \text{ e } j \text{ não são contíguos}\} \quad (1)$$

Teoricamente, é considerado que $W_{ii} = 0$, ou seja, nenhuma região é considerada vizinha de si mesma, implicando que a matriz de contiguidade possua a sua diagonal principal completada com valor zero. Das formas de matrizes de pesos espaciais utilizadas, as mais comuns são a convenção rainha e torre. A convenção de contigüidade rainha considera além das fronteiras com extensão diferente de zero, também os vértices (nós), na visualização de um mapa, como contíguos. Caso apenas as fronteiras físicas com extensão diferente de zero entre as regiões sejam levadas em conta, a convenção de contigüidade é considerada como torre (ALMEIDA, 2012).

Outro critério de proximidade na definição de pesos espaciais é a distância geográfica, na qual a ideia central subentende que duas regiões próximas geograficamente têm uma maior interação espacial. A matriz de k vizinhos é mais próximo, $w_{ij}(k)$ é um tipo de convenção que utiliza como critério medidas em quilômetros ou milhas. Formalmente:

$$w_{ij}(k) = \{1 \text{ se } d_{ij} \leq d_i(k); 0 \text{ se } d_{ij} > d_i(k)\} \quad (2)$$

Em que $d_i(k)$ é distância de corte para a região i especificamente, a fim de que esta região i tenha k vizinhos. Assim $d_i(k)$ é a menor distância para a região i a fim de que ela possua exatamente k vizinhos. A matriz de pesos é usada na econometria espacial para descrever a estrutura de dependência entre as unidades de análise, assim, deve-se identificar a matriz mais apropriada possível (PIRAS e LOZANO-GRACIA, 2012). A tarefa é descobrir a matriz de pesos espaciais que melhor representa a interação entre as regiões, um critério que pode ser adotado é utilizar um teste de autocorrelação espacial (I de Moran, por exemplo) e escolher a matriz que apresentar o maior valor do teste.

- **Autocorrelação Espacial Global Univariada**

Segundo Almeida (2012), a estatística I de Moran é um coeficiente de autocorrelação espacial, usando a medida de autocovariância na forma de produto cruzado. Foi proposto por Moran no ano de 1948, sendo considerado o primeiro coeficiente de autocorrelação espacial. A apresentação matricial da equação I de Moran é dada por:

$$I = \frac{Z'WZ}{Z'Z} \quad (3)$$


Onde Z denota os valores da variável de interesse padronizada, Wz representa os valores médios da variável de interesse padronizada nos vizinhos, definidos segundo uma matriz de ponderação espacial W . A média teórica do I de Moran é o quociente dado pela equação da esperança do I de Moran, $E(I) = [-1 / (n - 1)]$, onde n é o número de regiões. O valor da estatística I de Moran superior ao da esperança indica que há autocorrelação positiva, esse resultado revela a existência de similaridade entre os valores do atributo estudado e da localização espacial do atributo. A autocorrelação espacial negativa revela, por sua vez, que existe uma dissimilaridade entre os valores do atributo considerado e a localização espacial (SABATER; TUR; AZORÍN, 2011).

O I de Moran fornece três informações: a significância estatística informa sobre os dados estarem distribuídos aleatoriamente ou não; o sinal positivo da estatística I de Moran, desde que significativos, indica que os dados estão concentrados nas regiões, ou seja, valores similares. O sinal negativo, por sua vez, indica a concentração nas regiões, mas com valores dissimilares. A magnitude da estatística mostra a força da autocorrelação espacial, quanto mais próximo de um ou -1 mais forte é autocorrelação e quanto mais próximo de zero mais disperso estão os dados (ALMEIDA, 2012).

- **Diagrama de Dispersão de Moran Univariado**

Outra forma de visualizar a autocorrelação espacial é utilizando o diagrama de dispersão de Moran, o valor da variável de interesse (x) está colocada no eixo horizontal e a defasagem espacial da variável de interesse (w_x) no eixo vertical (ALMEIDA, 2012). Para conseguir a declividade da reta, estima-se uma regressão linear simples por mínimos quadrados ordinários (MQO), um exemplo do diagrama é apresentado na Figura 1:

FIGURA 1 - Diagrama de dispersão de Moran univariado



Fonte: Elaboração própria com base em Almeida (2012)

Um agrupamento Alto-Alto (AA) significa que as unidades espaciais que ali se encontram exibem valores altos da variável de interesse rodeados por unidades espaciais que apresentam valores também altos, representado pelo primeiro quadrante do diagrama. Um agrupamento Baixo-Baixo (BB) refere-se às unidades espaciais que mostram valores baixos circundados por unidades espaciais que ostentam valores também baixos, representado pelo terceiro quadrante. Um agrupamento Alto-Baixo (AB) diz respeito a um cluster no qual uma unidade espacial qualquer com um alto valor da variável de interesse é circunvizinhada por unidades espaciais com um baixo valor. Isso é representado pelo quarto quadrante. Um agrupamento Baixo-Alto (BA) é concernente a um cluster no qual uma unidade espacial qualquer com um baixo valor da variável de interesse é circundada por unidades espaciais com alto valor. Isso é representado no segundo quadrante (Figura 1).

- **Autocorrelação Espacial Local Univariada**

Do ponto de vista estatístico, a análise global da dependência espacial pode distorcer os resultados a nível local, embora o comportamento geral da variável analisada possa ser relevante sob uma perspectiva estatística, esta esconde algumas particularidades presentes em determinadas localizações do conjunto geográfico considerado. Assim, as análises relacionadas com o território normalmente estão mais direcionadas para identificar o comportamento local, juntamente com identificação das características próprias de cada espaço analisado. Deste modo, o método estatístico Indicador Local de Associação Espacial (LISA) é mais apropriado para verificar a autocorrelação espacial local (SABATER; TUR; AZORÍN, 2011).

Um Indicador Local de Associação Espacial (LISA) necessita satisfazer a dois critérios: para cada observação, indicar clusters espaciais significantes de valores similares em torno da observação e a soma dos indicadores locais, para todas as regiões, deve ser proporcional ao indicador de autocorrelação espacial global correspondente (ANSELIN, 1995).

Segundo Almeida (2012), o coeficiente I_i de Moran Local faz uma decomposição do indicador global de autocorrelação na contribuição local de cada observação em quatro categorias: alto-alto (AA), baixo-baixo (BB), alto-baixo (AB) e baixo-alto (BA), cada uma individualmente correspondendo a um quadrante no diagrama de dispersão de Moran. O coeficiente I_i de Moran local observada para a região i , pode ser expresso pela equação 4:

$$I_i = Z_i \sum_{j=1}^i W_{ij} Z_j \quad (4)$$

O cômputo de I_i só abrange os vizinhos da observação i , definidos conforme uma matriz de pesos espaciais, assim, para que I_i seja um indicador LISA é necessário que o somatório dos indicadores locais seja equivalente ao indicador global correspondente, de acordo com um fator de proporcionalidade (ANSELIN, 1995).

- **Autocorrelação Espacial Global Bivariada**

No estudo da Análise Exploratória dos Dados Espaciais (AEDE) é possível obter um coeficiente de autocorrelação espacial global bivariado. Segundo Almeida (2012), a ideia intuitiva é descobrir se o valor de um atributo observado numa dada região está relacionado espacialmente com os valores de outra variável observada em regiões vizinhas. A equação 5 mostra o I de Moran bivariado para duas variáveis, Z_1 e Z_2 .


$$I^{Z_1Z_2} = \frac{Z_1 W Z_2}{Z_1 Z_1} \quad (5)$$

Onde: Z_1 representa uma variável de interesse e Z_2 o valor de outra variável defasada na região vizinha e W é a matriz de pesos espaciais. De acordo com Anselin et al. (2003), essa estatística dá uma indicação do grau de associação linear (positiva ou negativa) entre o valor para uma variável em uma dada locação i e a média de uma outra variável nas locações vizinhas j .

- **Diagrama de Moran Bivariado**

O diagrama de dispersão de Moran bivariado (Figura 2) mostra no eixo das abscissas o valor de uma variável padronizada, observada numa determinada região, com o valor de outra variável padronizada, observado nas regiões vizinhas, no eixo das ordenadas. A autocorrelação positiva é reforçada com a inclinação crescente da reta de regressão e o agrupamento das unidades no primeiro e terceiro quadrante, por outro lado, quando existe autocorrelação espacial negativa a reta é decrescente e as unidades tendem a se agrupar em sua grande maioria no segundo e quarto quadrante (ALEMIDA, 2012).

FIGURA 2 - Diagrama de dispersão de Moran bivariado



Fonte: Elaboração própria com base em Almeida (2012).

No primeiro quadrante encontra-se o agrupamento alto-alto (AA), ou seja, as unidades espaciais pertencentes a essa aglomeração exibem regiões com valores altos da variável de interesse plotada no eixo das abscissas, rodeados regiões que apresentam valores também altos na outra variável de interesse, plotados no eixo das ordenadas. O agrupamento baixo-alto (BA) representa uma unidade espacial qualquer com um baixo valor da variável de interesse, mas é circundada por unidades espaciais com alto valor de outra variável, essa situação é demonstrada no segundo quadrante. O agrupamento baixo-baixo (BB) refere-se às unidades espaciais onde são observados valores baixos da variável de interesse circundados por unidades espaciais que ostentam valores também baixos na outra variável, representado pelo terceiro quadrante. Um agrupamento alto-baixo (AB) diz respeito a um cluster no qual uma unidade espacial qualquer com um alto valor da variável de interesse são vizinhos de unidades espaciais com um baixo valor, estando situado no quarto quadrante (Figura 2).

- **Autocorrelação Espacial Local Bivariada**

De acordo com Almeida (2012), é possível obter uma medida de autocorrelação espacial local multivariada. Supondo que haja duas variáveis de interesse, Z_1 e Z_2 respectivamente. A equação 6 representa o I de Moran local bivariado:

$$I_i^{Z_1 Z_2} = Z_{1i} W Z_{2i} \quad (6)$$

Em que: z_{1i} é uma variável de interesse e wz_{2i} é a defasagem espacial da outra variável de interesse z_{2i} na região vizinha. Assim somente os vizinhos da observação i , definidos conforme uma matriz de pesos espaciais, são incluídos no cálculo. O indicador local de associação espacial (LISA) fornece o grau de autocorrelação espacial estatisticamente significativo, em cada unidade regional (PIMENTEL e HADDAD, 2004). Da mesma forma como ocorre para a análise univariada, combinando as informações do diagrama de Moran bivariado com o mapa lisa de significância obtemos o mapa de cluster com os regimes bivariados, que permite uma visualização geográfica mais adequada do grau de concentração das variáveis estudadas.

3.2 Métodos Econométricos Espaciais

Os modelos econométricos espaciais são uma extensão da econometria clássica que utiliza a localização no território como um dos fatores explicativos nos modelos. No presente estudo estimam-se os modelos de: Defasagem Espacial (SAR), Erro Espacial (SEM) e o modelo Regressivo Cruzado Espacial (SLX).

O modelo de Mínimos Quadrados Ordinários (MQO) é estimado e o I de Moran dos resíduos é utilizado para testar a existência de autocorrelação espacial. A equação 6 representa o modelo MQO:

$$\begin{aligned} y &= X\beta + \varepsilon \\ \varepsilon &\sim N(0, \sigma^2 I) \end{aligned} \quad (7)$$

Em que ε é o termo de erro que se supõem seguir uma distribuição normal com média zero e variância constante.

- **Modelo de Defasagem Espacial (*SpatialLagModel* - SAR)**

O Modelo de Defasagem Espacial (SAR) informa que a variável dependente y é influenciada pela variável dependente das regiões vizinhas (Wy). Devido à multidirecionalidade da dependência espacial, a variável Wy é endógena, implicando que os valores de y nas regiões vizinhas influenciam a variável dependente num processo de causalção circular (ALMEIDA, 2012). O modelo SAR é represento pela equação 8:

$$y = \rho W_1 y + \beta_1 + X\beta_2 + \varepsilon \quad (8)$$

Em que $W_1 y$ é a variável dependente defasada pela matriz de pesos espaciais, ρ é o coeficiente autorregressivo espacial que mede a influência média dos vizinhos sobre a observação no vetor y , indicando a proporção da variação total em y explicada pela dependência espacial. Esse modelo não pode ser estimado por MQO devido à endogeneidade do regressor Wy . Em relação ao MQO, esse modelo possui um termo a mais para capturar o efeito da vizinhança.

- **Modelo de Erro Espacial (*SpatialErrorModel* - SEM)**

Pace e Zhu (2012) afirmam que o modelo SEM tem como principal vantagem em relação a modelos de defasagem espacial, como o SAR, evitar a verificação de viés nas estimativas. Como os modelos de defasagem espacial possuem forte correlação entre as variáveis dependente e sua defasagem espacial, podem ocorrer problemas de consistência pela convergência, tanto do valor esperado da variável dependente, quanto da matriz de covariância das explicativas, para uma mesma estimativa. O modelo SEM, por especificar a dependência espacial apenas no termo de erro evita problemas de consistência, ocorrendo apenas o risco de problemas de eficiência, assumidos preferíveis aos primeiros pela literatura econométrica. Nesse modelo, segundo Almeida (2012), a dependência espacial é residual, caracterizada pela estrutura autorregressiva de primeira ordem no termo de erro. O modelo de erro espacial é dado pela equação 9:

$$\begin{aligned} y &= \beta_1 + \beta_2 X + u \\ u &= \lambda W\mu + \varepsilon \end{aligned} \quad (9)$$

Onde λ é o coeficiente do parâmetro do erro autorregressivo espacial que acompanha a defasagem $W\mu$.

- **Modelo Regressivo Cruzado Espacial (SLX)**

Esse modelo considera que todas as variáveis contidas na matriz X possam transbordar espacialmente. Nesse sentido, todas as variáveis explicativas especificadas, podem apresentar um efeito transbordamento localizadas para as regiões vizinhas. A equação 9 representa o modelo regressivo cruzado:

$$y = \beta_1 + \beta_2 X + \beta_3 WX\tau + \varepsilon \quad (10)$$

Na equação 10, o termo (WX) representa a defasagem das variáveis explicativas e τ representa o efeito transbordamento. Esse modelo pode ser estimado por Mínimos Quadrados Ordinários sem incorrer em problemas.

- **Critério de escolha para o modelo econométrico mais adequado**

Para a escolha e análise do modelo econométrico espacial mais adequado será utilizado o procedimento sugerido por Florax, Folmer e Rey (2003). Os quais destacam as seguintes etapas:

1. Estimar o modelo clássico linear de Mínimos Quadrados Ordinários (MQO);
2. Testar a hipótese de ausência de autocorrelação espacial devido a uma defasagem ou a um erro por intermédio das estatísticas Multiplicador de Lagrange de defasagem espacial (ML_ρ) e Multiplicador de Lagrange de erro espacial (ML_λ);
3. Caso ambos os testes não sejam significativos, a utilização do MQO é a mais apropriada. Caso contrário, é necessário seguir para o próximo passo;
4. Caso ambos sejam significativos, estima-se o modelo apontado como o mais significativo de acordo com as versões robustas desses testes, ou seja, Multiplicador de Lagrange de defasagem espacial robusto (ML^*_ρ) e Multiplicador de Lagrange de erro espacial robusto (ML^*_λ). Dessa forma, se $ML^*_\rho > ML^*_\lambda$, utiliza-se o modelo com defasagem espacial como o mais apropriado. Caso $ML^*_\rho < ML^*_\lambda$, usa-se o modelo de erro autorregressivo como o mais apropriado. Se este passo não for satisfeito, é preciso seguir para o próximo;
5. Se o teste ML^*_ρ é significativo e o ML^*_λ não, adote o modelo de defasagem espacial, caso contrário, vá para o próximo;
6. Se o teste ML^*_λ é significativo e o ML^*_ρ não, adote o modelo de erro espacial.

3.3 Descrição das variáveis

As variáveis IFDM-Saúde e IFDM-Educação foram extraídas do banco de dados da Federação das Indústrias do Rio de Janeiro (FIRJAN), as variáveis renda *per capita* e infraestrutura domiciliar (percentual de domicílios com água e banheiro, coleta de lixo e energia elétrica) estão disponíveis no Atlas Brasil 2013 do Programa das Nações Unidas para o Desenvolvimento (PNUD), o valor referente ao gasto com saúde foi extraído no site do Ministério da Saúde – (SIOPS).

- Índice IFDM-Saúde (SAÚDE): o indicador é composto por quatro variáveis, número de consultas pré-natal, óbitos por causa mal definida, óbitos infantis por causas evitáveis e internação sensível a atenção básica. Os valores de referência do índice são divididos em quatro categorias: alto desenvolvimento quando os municípios possuem o IFDM-Saúde acima de 0,8, para valores entre 0,6 e 0,8 considera-se desenvolvimento moderado, quando o índice se situa no intervalo entre 0,4 e 0,6 o desenvolvimento é considerado regular e no caso do índice menor que 0,4 considera-se baixo desenvolvimento. Quanto mais próximo de um melhor as condições de saúde da população do município, por outro lado, o indicador próximo de zero demonstra que as condições de saúde da população do município são precárias.
- Renda *per capita* (RPC): refere-se a toda renda auferida pelos integrantes do domicílio dividido pelo número de moradores.
- Infraestrutura domiciliar (INF): representa o percentual de domicílios no município que possuem água e banheiro, coleta de lixo e energia elétrica.
- Gastos *per capita* com saúde (GPCS): refere-se ao gasto total do município com saúde dividido pelo número de habitantes do município.
- Índice IFDM-Educação (EDUC): o indicador engloba as variáveis taxa de matrícula na educação infantil, taxa de abandono escolar, taxa de distorção idade-série, percentual de docentes com ensino superior e resultado do IDEB. O indicador varia entre 0 e 1, e quanto mais próximo de 1 melhor o índice de educação do município.

3.4 Modelo Proposto

O modelo a ser estimado pode ser representado pela equação 11:

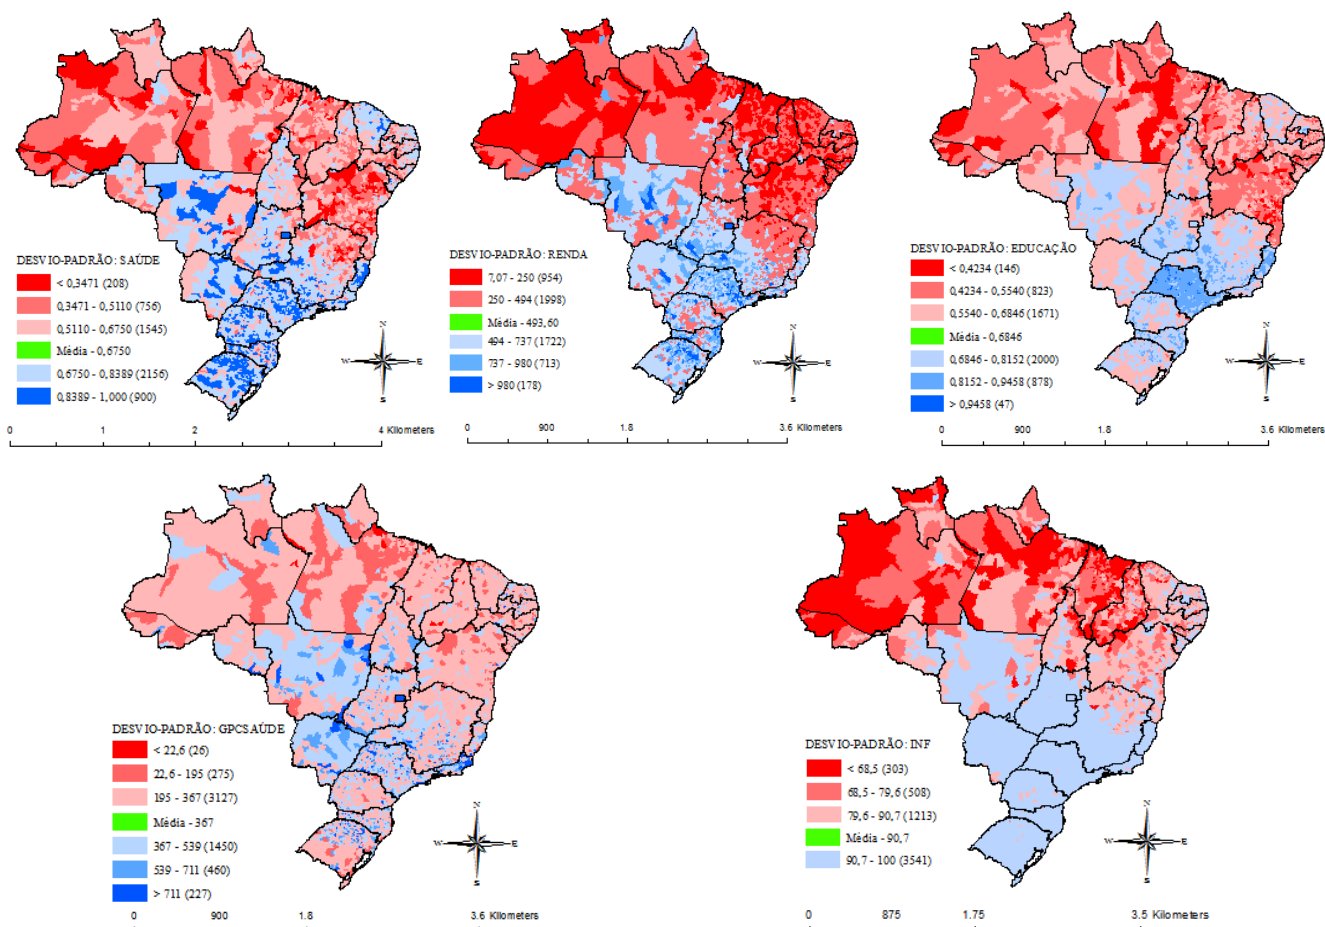
$$\text{SAÚDE} = \beta_1 + \beta_2\text{RPC} + \beta_3\text{EDUC} + \beta_4\text{GPCS} + \beta_5\text{INF} + \varepsilon \quad (11)$$

As variáveis já foram apresentadas na subseção 3.3. Espera-se que as variáveis utilizadas causem um impacto positivo no indicador de Saúde. O modelo apresentado na equação 11 será estimado tanto por MQO como para os procedimentos de econometria espacial de modo a verificar se os efeitos espaciais são significativos para estudos envolvendo o indicador de saúde.

4 ANÁLISE DOS RESULTADOS

O mapa de desvio-padrão apresentado na Figura 3 permite visualizar a distribuição geográfica das variáveis IFDM-Saúde, renda *per capita*, IFDM-Educação, Gasto *per capita* com saúde e infraestrutura nos municípios brasileiros no ano de 2010. As regiões denotadas em azul representam as unidades onde o indicador está acima da média e os pontos realçados em vermelho mostram os valores acima da média. O valor médio do indicador considerando todos os municípios brasileiros é igual a 0,6750. Em torno de 55% dos municípios apresentou índice acima da média, situados em municípios da região Sul, Sudeste e Centro-Oeste em sua grande maioria. No que tange as unidades espaciais com índice abaixo da média foi observado que 45% estão nessa situação, localizadas principalmente em estados da região Norte e Nordeste.

Figura 3 – Mapa de Desvio-Padrão do IFDM-Saúde, Renda *Per Capita*, IFDM-Educação, Gasto *Per Capita* com Saúde e Infraestrutura dos Municípios do Brasil no ano de 2010



Fonte: Elaboração própria.

No mapa referente à renda *per capita* é possível observar que o valor médio foi de R\$ 493,00 no conjunto dos municípios. As unidades com renda acima da média estão localizadas principalmente nos estados da região Sul, Sudeste e Centro-Oeste, quase 47% dos municípios estão nessa situação. Diferentemente, para 53% a renda *per capita* se situa abaixo da média, os municípios com essa característica estão principalmente nos estados da região Norte e Nordeste, entretanto, está em destaque uma grande parte do estado de Minas Gerais que engloba municípios com baixa renda *per capita*.

A análise sobre o índice de educação da FIRJAN revelou que no ano de 2010 o indicador médio foi de 0,6846. Em torno de 53% das unidades apresentou indicador acima da média e estão principalmente localizados na região Sul e Sudeste, com destaque para o estado de São Paulo, onde 47 municípios apresentaram indicador acima de 0,9458. Nos estados do Mato Grosso do Sul, Mato Grosso, Goiás, Tocantins e Ceará também estão em evidência alguns municípios com índice acima da média. No que tange as unidades abaixo da média, estão em destaque 43% dos municípios. Os estados da região Norte e Nordeste apresentaram os piores indicadores, porém em unidades situadas nas regiões Centro-Oeste e Sul aparece diversas pontos que mostram municípios com índice abaixo da média.

O gasto médio com saúde *per capita* de todos os municípios foi de R\$ 367,00 no ano de 2010. Em torno de 38% dos municípios apresentou gasto com saúde por habitante acima da média, no mapa é possível observar a predominância no número de unidades onde o gasto *per capita* se situa a um desvio-padrão acima da média, essas unidades estão localizadas principalmente no estado de São Paulo, Rio de Janeiro, Mato Grosso do Sul e Mato Grosso. Nota-se, que 62% das unidades apresentaram gastos com saúde por habitante abaixo da média, em termos de localização geográfica é possível observar no mapa que a maior parte dos municípios nessa situação está localizada nas regiões Norte e Nordeste, porém, em muitas unidades situadas na região Sul seja observado à mesma situação, refletindo os baixos investimentos realizados pelo setor público municipal na área de saúde. Para 26 municípios o gasto ficou

muito abaixo da média, o valor foi inferior a R\$ 22,60 ao ano, essas unidades denotadas em vermelho escuro estão principalmente no Norte e Nordeste.

A variável infraestrutura domiciliar busca refletir as condições de moradia da população nos municípios brasileiros em termos de acesso a serviços básicos como coleta de lixo, água encanada e saneamento. No conjunto dos municípios o percentual médio foi de 90,7%. Em pouco mais de 63% dos municípios o percentual de pessoas atendidas está acima da média, no mapa a grande extensão realçada em azul revela que essas unidades estão localizadas nas regiões Sul, Sudeste e Centro-Oeste. Na outra ponta, 37% das unidades apresentaram percentual de atendimento abaixo da média, o mapa revela que nos estados da região Norte e Nordeste a carência desse tipo de serviço básico atinge grande parte da população.

• Autocorrelação Espacial Global

O resultado da autocorrelação espacial utilizando a estatística I de Moran do indicador IFDM-Saúde dos municípios brasileiros no ano de 2010 é apresentado na Tabela 1. Foram testadas as matrizes de contiguidades Rainha, Torre e k-vizinhos mais próximos, k5, k7 e k10. Independente da matriz utilizada foi observada autocorrelação espacial positiva, pois o valor da estatística I de Moran ficou acima da esperança do I de Moran de -0,0002 e significativas a 1%.

Nesse sentido, é possível inferir que municípios que apresentam elevado índice IFDM-Saúde estão cercados por unidades com indicador acima da média e as unidades municipais onde o indicador é baixo estão cercadas por vizinhos com situação semelhante. O maior valor do I de Moran foi da matriz Torre, sendo assim todas as análises e resultados apresentados posteriormente utilizaram essa configuração espacial, pois representa melhor a conexão entre os municípios.

Tabela 1 – Autocorrelação Espacial Global

Matrizes de contiguidade	I de Moran	P-Valor
Rainha	0,6429	0,001
Torre	0,6439	0,001
K5	0,6396	0,001
K7	0,6315	0,001
K10	0,6259	0,001

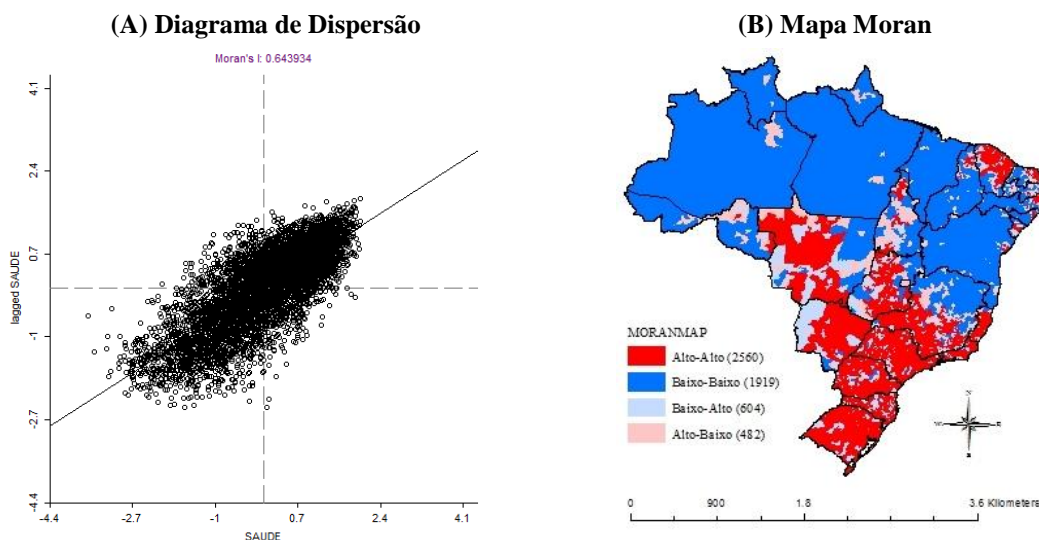
Fonte: Elaboração própria.

O diagrama de dispersão de Moran do índice IFDM-Saúde dos municípios do Brasil no ano de 2010 permite verificar o padrão de concentração das unidades. No eixo das abscissas está colocada a variável IFDM-Saúde e no eixo das coordenadas é plotada a defasagem da variável de IFDM-Saúde. O diagrama apresenta quatro categorias: alto-alto, baixo-baixo, baixo-alto e alto-baixo. O agrupamento alto-alto (AA) mostra as unidades que ostentam elevado indicador de saúde e a média dos vizinhos também é alta, já as aglomerações baixo-baixo (BB) refere-se aos municípios com baixo índice de saúde e a média das unidades vizinhas está na mesma situação. Os clusters baixo-alto (BA) representam as unidades com baixo índice de saúde e o indicador médio dos municípios vizinhos é alto e as unidades caracterizadas como alto-baixo (AB) representa o grupo de municípios com elevado indicador de saúde, mas a média das unidades contíguas é baixa. O Moran Map facilita a visualização geográfica das informações apresentadas no diagrama de Moran, os municípios com elevado indicador de saúde, ou seja, alto-alto (AA) estão destacados em vermelho no mapa, já as unidades municipais que exibem baixo índice de saúde, sendo assim, baixo-baixo (BB) estão realçadas em azul mais escuro, as unidades baixo-alto (BA) estão denotadas em azul mais claro e o agrupamento alto-baixo (AB) são representadas pelas unidades denotadas em vermelho mais claro (Figura 4).

A disposição dos municípios no diagrama de Moran mostra que 46% das unidades estão agrupadas no primeiro quadrante, no mapa de Moran os pontos denotados em vermelho revelam a localização geográfica das unidades nessa situação, região Sul, Sudeste, Centro-Oeste e no Estado do Ceará. No segundo quadrante estão 11% dos municípios que aparecem realçadas em azul claro no mapa, principalmente nas regiões Sul, Sudeste e Centro-Oeste, outras 34% das unidades estão aglomeradas no

terceiro quadrante, no mapa de Moran as localidades destacadas em azul escuro apontam que os municípios com essa característica estão situados predominantemente nas regiões Norte e Nordeste. No quarto quadrante estão 9% dos municípios, os quais estão destacados em vermelho claro no mapa, situados em algumas regiões do Nordeste e do Centro-Oeste (Figura 4).

Figura 4 – Diagrama de dispersão e Mapa de Moran do índice IFDM-Saúde dos municípios do Brasil do ano de 2010

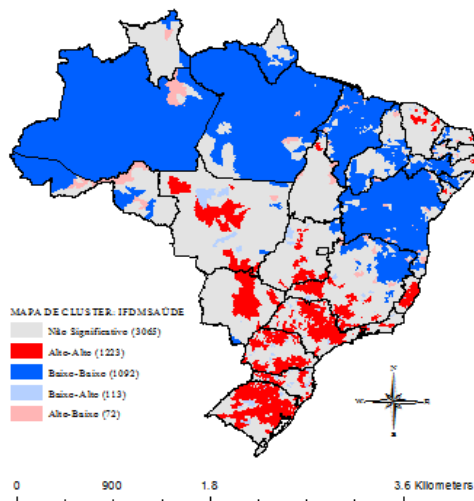


Fonte: Elaboração própria.

- **Autocorrelação Espacial Local**

No mapa de cluster apresentado na Figura 5 é possível visualizar onde estão formados os agrupamentos estatisticamente significativos a pelo menos 5%. Em vermelho escuro estão destacadas as unidades municipais alto-alto e em azul escuro os municípios baixo-baixo. O total de 1223 municípios compõem o agrupamento espacial com elevado indicador IFDM-Saúde e estão localizados em municípios dos estados do Rio Grande do Sul, Santa Catarina, Paraná, São Paulo, Espírito Santo, Minas Gerais, Mato Grosso do Sul, Mato Grosso e Goiás. Nota-se a formação de aglomerações com baixo indicador que envolve 1092 municípios situados em grande parte nos estados da região Norte e Nordeste, no qual se destacam Para, Amazonas, Acre, Bahia, Pernambuco, Paraíba e Piauí. É possível visualizar a formação de alguns agrupamentos baixo-alto, realçados em azul claro e alto-baixo, denotados em vermelho claro, estes aparecem dispersos pelo mapa.

Figura 5– Mapa de Cluster do IFDM-Saúde dos Municípios do Brasil no Ano de 2010



Fonte: Elaboração própria.

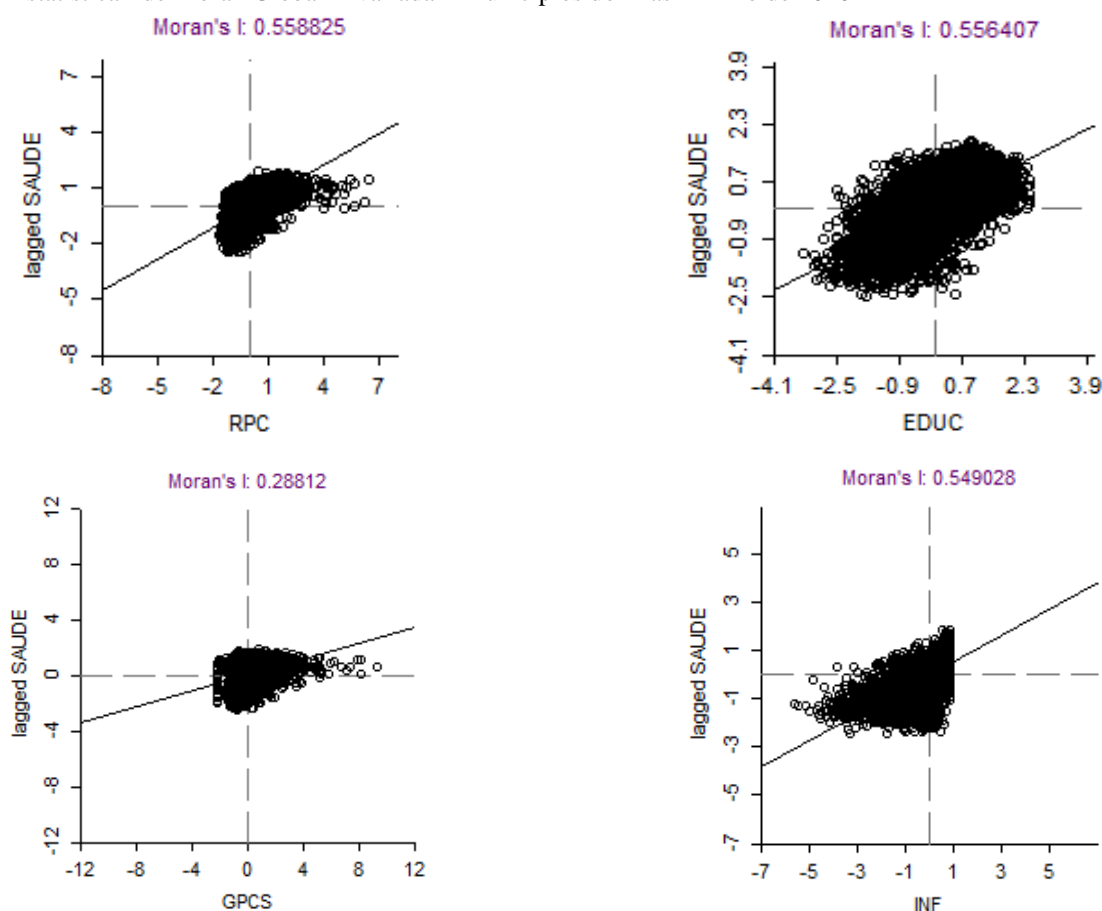
- **Autocorrelação Espacial Global Bivariada**

Na análise multivariada o indicador IFDM-Saúde é relacionado com diversas variáveis selecionadas que representam características socioeconômicas e de infraestrutura dos municípios brasileiros, entre estas estão: renda *per capita*, IFDM-Educação, Gastos *per capita* com saúde e infraestrutura domiciliar. No diagrama de Moran o indicador IFDM-Saúde está plotado no eixo vertical, já as outras variáveis são colocadas no eixo horizontal. O diagrama é dividido em quatro quadrantes representando as associações espaciais alto-alto no primeiro quadrante, baixo-alto no segundo quadrante, baixo-baixo no terceiro quadrante e alto-baixo no quarto quadrante (Figura 6).

No primeiro quadrante (AA) estão concentradas as unidades que ostentam valor elevado das variáveis selecionadas e o índice de saúde médio das unidades vizinhas também é alta. Já o segundo quadrante (BA) engloba as unidades com baixo valor das variáveis selecionadas e a IFDM-SAÚDE médio dos vizinhos é elevado. O terceiro quadrante (BB) é concernente com as unidades com baixo valor das variáveis selecionadas e o indicador de saúde médio das unidades contiguas é baixa. E no quarto quadrante (AB) estão agrupados os municípios onde as variáveis selecionadas são baixas e o índice de saúde médio é dos vizinhos é baixo.

Pelos diagramas apresentados na Figura 7 é possível visualizar que o IFDM-Saúde está relacionado positivamente com as variáveis selecionadas, os resultados são reforçados pela inclinação positiva da reta de regressão, nesse sentido, é possível afirmar que as unidades municipais com elevado indicador de saúde estão cercadas por municípios vizinhos com renda *per capita*, índice de educação, gasto *per capita* com saúde e infraestrutura domiciliar acima da média.

Figura 6 – Estatística I de Moran Global Bivariada – Municípios do Brasil – Ano de 2010



Fonte: Elaboração própria.

No diagrama bivariado que relaciona o indicador de saúde e a renda *per capita* foi observado que 42% das unidades estavam concentradas no primeiro quadrante, 38% se encontravam no terceiro

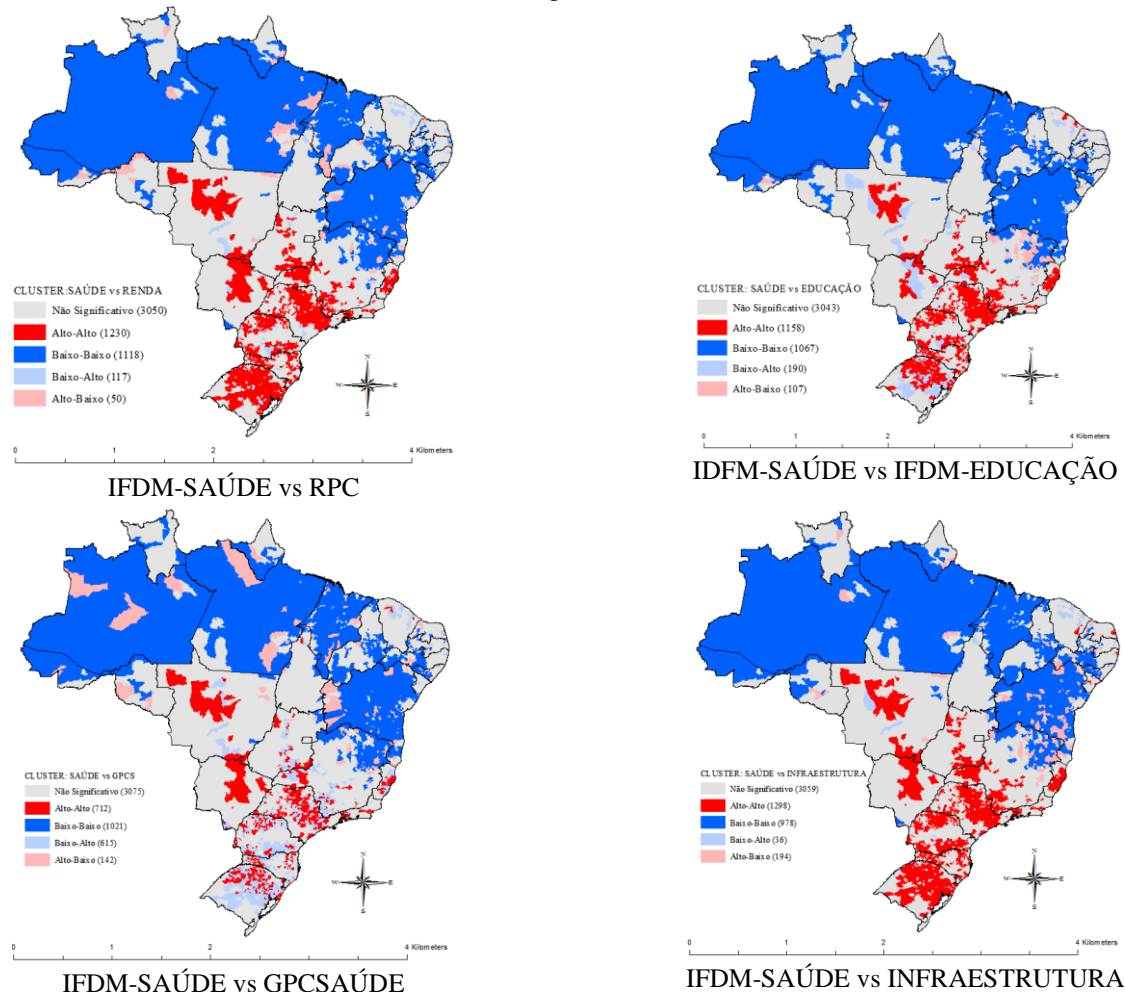
quadrante, 15% dos municípios localizavam-se no segundo quadrante e 5% situavam-se no quarto quadrante. No que tange ao diagrama que confronta o indicador saúde com a educação, verificou-se que 44% estavam agrupados no primeiro quadrante, já 34% aparecem situados no terceiro quadrante, no segundo estão 13% das unidades e 9% estão aglomerados no quarto quadrante.

O diagrama que mostra a relação entre indicador de saúde e os gastos *per capita* com saúde, revelou que 30% estão concentrados no primeiro quadrante, 34% no terceiro quadrante, outros 28% se concentram no segundo quadrante e 8% aparecem no quarto quadrante. O diagrama em que o índice de saúde é relacionado com a variável infraestrutura domiciliar, mostrou que 51% dos municípios estão concentrados no primeiro quadrante, no terceiro quadrante aparecem 30% das unidades, 7% estão situadas no segundo quadrante e no quarto quadrante estão 12% dos municípios.

- **Autocorrelação Espacial Local Bivariada**

Os mapas de clusters bivariados exibidos na Figura 7 mostram em quais regiões foram formados os agrupamentos espaciais estatisticamente significativos da relação entre o indicador de saúde e as variáveis renda *per capita*, indicador de educação, gasto *per capita* com saúde e infraestrutura domiciliar (água e banheiro, coleta de lixo e energia elétrica). As associações espaciais alto-alto (AA) aparecem destacadas em vermelho no mapa e os agrupamentos baixo-baixo (BB) em azul.

Figura 7 – Estatística I de Moran Bivariada Local – Municípios do Brasil – Ano de 2010



Fonte: Elaboração própria.

Os mapas de cluster apresentados na Figura 7 demonstram que dada a relação positiva entre o indicador saúde e as variáveis selecionadas a maioria dos agrupamentos formados são alto-alto (AA) e baixo-baixo (BB). As associações espaciais com elevado indicador de saúde e renda *per capita*, educação,

gastos *per capita* com saúde e infraestrutura domiciliar aparecem predominantemente localizados nas regiões Sul, Sudeste e Centro-Oeste. Por outro lado, os agrupamentos espaciais com baixo indicador da saúde e das variáveis selecionadas estão situados na região Norte e Nordeste.

• Resultados dos Modelos Econométricos

O resultado do modelo de Mínimos Quadrados Ordinários é apresentado na tabela 2, a variável dependente é o índice IFDM-Saúde e as variáveis explicativas representam características dos municípios que podem impactar o no indicador, são elas: renda *per capita*, o indicador IFDM da educação, os gastos *per capita* com saúde e infraestrutura domiciliar. Na parte superior da referida tabela estão os coeficientes estimados, os quais foram todos estatisticamente significativos e apresentaram o sinal esperado. Na segunda parte da tabela é possível verificar que o modelo apresenta multicolinearidade, já que o teste de condition number ficou acima de 30, o teste de Jarque-Bera mostra que os erros não se distribuem normalmente e há presença de heterocedasticidade.

O diagnóstico para autocorrelação espacial apresenta o I de Moran difuso igual a 0,33 e significativo, o que reforça a presença de autocorrelação espacial. Os testes de multiplicador de Lagrange apresentados na tabela 2 foram estatisticamente significativos a 1%, sendo assim, o modelo de MQO não é o mais apropriado, pois não incluem os efeitos espaciais, sendo necessário utilizar os modelos econométricos espaciais para representar a relação entre o indicador de saúde e as variáveis explicativas.

Tabela 2 – Resultado do Modelo EconométricoMQO - Variável dependente: saúde

VARIÁVEIS	COEFICIENTES
CONSTANTE	- 2,7161*
RPC	0,1487*
EDUC	0,4126*
GCSPC	0,0147*
INF	0,3249*
DIAGNÓSTICO DA REGRESSÃO	
R-Quadrado	0,43*
Condition number	137
Jarque-Bera	5020*
Koenker-Bassett	1008*
DIAGNÓSTICO PARA AUTOCORRELAÇÃO ESPACIAL	
I de Moran dos erros	0,33*
ML (Defasagem)	1744,58*
ML (Defasagem) robusto	148,67*
ML (Erro)	1676,28*
ML (Erro) robusto	80,37*

Fonte: Elaboração própria. Obs: *Significativo a 1%.

O valor referente ao multiplicador robusto da defasagem foi de 148,67 superior ao multiplicador robusto de erro de 80,37 indicado que o modelo econométrico espacial com defasagem (SAR) é o mais adequado para verificar a relação entre as variáveis explicativas selecionadas e o indicador de saúde da FIRJAN nos municípios do Brasil. A equação 12 apresenta formalmente o modelo SAR a ser estimado:

$$SAÚDE = \beta_1 + \beta_2 RPC + \beta_3 EDUC + \beta_4 GPCS + \beta_5 INF + \rho W_1 SAÚDE + \varepsilon \quad (12)$$

Na tabela 3 estão os resultados referentes aos modelos econométricos espaciais de defasagem espacial (SAR) e o modelo cruzado espacial (SLX). Como as hipóteses de normalidade e de homocedasticidade foram rejeitadas o modelo SAR foi estimado por mínimos quadrados em dois estágios (MQ2E) com erros padrão robustos.

Tabela 3 – Modelos Econométricos Espaciais – Variável dependente: IFDM-Saúde

VARIÁVEIS	COEFICIENTES MODELO SAR	EFEITOS MARGINAIS ⁴ NO MODELO SAR	COEFICIENTES MODELO SLX
Constante	- 1,4784 *	- 2,9022	- 2,0658*
RPC	0,0745*	0,1463	0,0709*
EDUC	0,2347*	0,4607	0,3607*
GCSPC	0,0086**	0,0169	- 0,0078***
INF	0,1888*	0,3706	- 0,2101*
WSAÚDE	0,4906*	0,4906	-
WRPC	-	-	0,0002*
WEDUC	-	-	0,0471***
WGPCS	-	-	0,0040***
WINF	-	-	0,0021*

Fonte: Elaboração própria. Obs.: *Significativo a 1%. **Significativo a 10%. ***Não Significativo.

Os efeitos marginais totais encontrados no Modelo de Defasagem Espacial (SAR) mostram que um aumento de 1% na renda eleva em 0,14% o indicador de saúde dos municípios. O índice da educação também apresentou sinal positivo, assim, um aumento de 1% no indicador IFDM-Educação eleva em 0,46% o índice de saúde. Um aumento 1% nos gastos em saúde *per capita* aumenta o índice em 0,016%. Um aumento de 1% no número de domicílios com acesso a infraestrutura adequada nos municípios faz aumentar em 0,37% o indicador de saúde. O coeficiente de defasagem apresentou sinal positivo e significativo a 1%, ou seja, um aumento de 1% no indicador de saúde do município vizinho leva a um aumento de 0,49% no indicador do município em análise. No modelo cruzado espacial (SLX) a defasagem das variáveis renda e infraestrutura municipal apresentou coeficiente positivo e estatisticamente significativo a 1%, porém a magnitude foi baixa, esse resultado mostra que um aumento na renda e nos investimentos em infraestrutura domiciliar nos municípios vizinhos ocasionam um aumento no indicador de saúde do município em análise.

5 CONSIDERAÇÕES FINAIS

Este estudo objetivou analisar as condições de saúde nos municípios brasileiros no ano de 2010, utilizando o indicador IFDM-Saúde calculado pela Federação das Indústrias do Rio de Janeiro (FIRJAN). Foi verificada também a relação entre o IFDM-Saúde e as variáveis renda *per capita*, IFDM-Educação, gasto *per capita* com saúde e infraestrutura domiciliar. Os mapas de desvio-padrão permitiram visualizar a distribuição geográfica das variáveis estudadas e foi constatado que os municípios situados no Norte e Nordeste apresentaram os menores indicadores de saúde e educação. Além do mais são regiões que apresentaram renda *per capita* e gasto com saúde por habitante abaixo da média e o percentual de domicílios com infraestrutura adequada está abaixo do observado para o Brasil.

O resultado do teste para autocorrelação espacial do IFDM-Saúde através do I de Moran foi positivo, indicando que os municípios com elevado índice de saúde estão cercados por vizinhos na mesma situação, e unidades que ostentam baixo indicador são vizinhos de municípios com baixo índice. No diagrama de Moran os municípios concentraram-se no primeiro e no terceiro quadrante. Utilizando a estatística I de Moran local foi possível visualizar que os agrupamentos com elevado indicador de saúde estão situados nas regiões Sul, Sudeste e Centro-Oeste e as aglomerações com baixo índice estão situados no Norte e Nordeste.

A análise bivariada revelou que o índice de saúde está relacionado positivamente com todas as variáveis explicativas, reforçando assim que as unidades com elevada renda, educação, gasto per capita com saúde e infraestrutura domiciliar tendem a apresentar melhores indicadores de saúde. No mapa de cluster foi possível verificar que as aglomerações “alto-alto” estão situadas nas regiões Sul, Sudeste e

⁴No modelo SAR, para se ter o impacto total (efeitos diretos e indiretos) proporcionado pela realimentação da interação espacial entre as regiões é preciso fazer o seguinte cálculo: $(1 - \rho)^{-1}\beta_k$ (ALMEIDA, 2012, p. 253).

Centro-Oeste, por outro lado, nas regiões Norte e Nordeste estão grande parte das aglomerações “baixo-baixo”.

Os resultados dos modelos econométricos mostraram que o indicador de saúde aumenta quando ocorre um aumento na renda, na educação, no gasto com saúde ou no percentual de famílias residindo em domicílios com melhor infraestrutura. O modelo de defasagem espacial se mostrou mais adequado para explicar a relação entre o índice de saúde e as variáveis explicativas, pois o valor do multiplicador de Lagrange robusto da defasagem foi maior do que o do erro. Como sugestão para trabalhos futuros seria realização da mesma análise, entretanto, aplicada para a região Sul, onde haverá a possibilidade de analisar os pormenores de cada um dos estados, tal como presença de infraestrutura básica, acesso a rodovias asfaltadas, o que é de suma importância para os gestores públicos, uma vez que fornece informações mais detalhadas sobre as condições socioeconômicas dos municípios.

REFERÊNCIAS

ALMEIDA, E. **Econometria espacial aplicada**. Alínea: Campinas, 2012.

ALMEIDA, E. S.; PEROBELLI, F. S.; FERREIRA, P. G. C. Existe convergência espacial da produtividade agrícola no Brasil? **Revista de Economia e Sociedade Rural**, Rio de Janeiro, v. 46, n. 1, p. 31-52, jan./mar. 2008.

ANSELIN, L. **Spatial econometrics: methods and models**. London: Kluwer Academic, 1988.

ANSELIN, L. Local indicators of spatial association (LISA). **Geographical Analysis**, v. 27, n. 2, p. 93-115, 1995.

ANSELIN, L. SYABRI, I.; SMIRNOV, O. Visualizing multivariate spatial correlation with dynamically linked windows. University of Illinois, 2003, (mimeo).

CAVALCANTE, A. A.; SILVA, R. G.; ALMEIDA, E. S.; CAVALCANTI, F. C. S. Análise da convergência do Índice de Desenvolvimento Humano na Amazônia Sul-Ocidental no período de 1991 a 2000. **Revista Brasileira de Gestão e Desenvolvimento Regional**, Taubaté, v. 6, n.3, p. 214-238, 2010.

COSTA, A. M. B., SILVA, F. M., GOMES, C., CUELLAR, M. Z., ALMEIDA, S.A.S., AMORIN, R. F., CARVALHO, M.J.M. Comportamento espacial do índice de desenvolvimento humano no Rio Grande do Norte com o uso do programa TerraView (desenvolvido pelo INPE). In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., 2007, Florianópolis. **Anais...** Florianópolis: Centro de Convenções de Florianópolis, 2007, p. 5159-5166.

DIAS, C. A estratégia do planejamento nacional. **Desafios do desenvolvimento**, Brasília, ano 8, n. 69, p. 58-64, (Ed. esp.) 2011.

FLORAX, R. J. G. M., 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.

FEDERAÇÃO DAS INDÚSTRIAS DO RIO DE JANEIRO. Índice Firjan de Desenvolvimento Municipal – Saúde. Disponível em: <<http://www.firjan.com.br/ifdm/>>. Acesso em: 29 out. 2015.

GOLGHER, A. B. **Introdução à econometria espacial**. Paco Editorial: Jundiaí, 2015.

LEITE, P. S. **Novo enfoque do desenvolvimento econômico e as teorias convencionais**. Fortaleza: Imprensa Universitária, 1983.

LIMA, V. M. A.; CALDARELLI, C. E.; CAMARA, M. R. G. Análise do desenvolvimento municipal paranaense: uma abordagem espacial para a década de 2000. **Revista Economia e Desenvolvimento**, Santa Maria, vol. 26, n. 1, p. 1-19, 2014.

LINS, J. G. M. G.; LOURES, A. R.; LOMBARDI-FILHO, S. C.; SILVA, M. V. B. Análise espacial da evolução do índice de desenvolvimento humano nos municípios da região Nordeste. **Revista Economia e Desenvolvimento**, Recife, v. 14, p. 81-96, 2015.

- LORENA, R. B.; BERGAMASCHI, R. B.; LEITE, G. R. Análise exploratória espacial do Índice de Desenvolvimento Humano municipal do estado do Espírito Santo. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 15., 2011, Curitiba. **Anais...** São José dos campos: INPE, 2011. p. 4776-4782.
- MACEDO, M. A. S.; CRUZ, C. F. C.; FERREIRA, A. C. S. índice de desenvolvimento sustentável: uma análise apoiada em DEA para os municípios do estado do Rio de Janeiro. **Gestão & Regionalidade**, São Caetano do Sul. vol. 27, n. 81, p. 19-31, 2011.
- MEDEIROS, C. N.; NETO, V. R. P. **Análise espacial da extrema pobreza no estado do Ceará**. In: ENCONTRO DE ECONOMIA DO CEARÁ, 7., 2011, Fortaleza. **Anais...** Fortaleza: IPECE, 2011.
- MENDES, C. C.; TEIXEIRA, J. R. **Desenvolvimento econômico brasileiro: uma releitura das contribuições de Celso Furtado**. Brasília: UNB, 12 ago. 2004. 19 p. (Texto para discussão, n. 320).
- MELO, C. O. Índice relativo de desenvolvimento econômico e social dos municípios da região Sudoeste paranaense. **Revista Análise Econômica**, Porto Alegre, ano 25, n. 47, p. 149-164, 2007.
- MELO, C. O.; PARRÉ, J. L. Índice de desenvolvimento rural dos municípios paranaenses: determinantes e hierarquização. **Revista de Economia e Sociologia Rural**, Rio de Janeiro, v. 45, n. 02, p. 329-365, 2007.
- MINISTÉRIO DA SAÚDE. **Introdução à estatística espacial para a saúde pública**. Brasília, DF, 2007. 120 p.
- PACE, R. K.; ZHU, S. Separable spatial modeling of spillovers and disturbances. **Journal of Geographical Systems**, v. 14, n. 1, p. 75-90, 2012.
- PIMENTEL, E. A.; HADDAD, E. A. **Análise da distribuição espacial da renda no estado de Minas Gerais: uma abordagem setorial**. São Paulo: NEREUS, 2004. 26 p. (Texto para discussão n.2).
- PIRAS, G.; LOZANO-GRACIA, N. Spatial J-test: some Monte Carlo evidence. **Statistics and Computing** 22, p. 169–183, 2012.
- PROGRAMA DAS NAÇÕES UNIDAS PARA O DESENVOLVIMENTO. Atlas Brasil 2013. Disponível em: <<http://www.pnud.org.br/atlas>>. Acesso em: 29 out. 2015.
- REDE INTERAGENCIAL DE INFORMAÇÃO PARA A SAÚDE (RIPSA). **Indicadores básicos para a saúde no Brasil: conceitos e aplicações**. Rede Interagencial de Informação para a Saúde - RIPSA. 2. ed. Brasília: Organização Pan-Americana da Saúde, 2008. 349 p.
- SABATER, L. A.; TUR, A. A.; AZORÍN, J. M. N. Análise Exploratória dos Dados Espaciais (AEDE). In: COSTA, J. S.; DENTINHO, T. P.; NIJKAMP, P. **Compêndio de Economia Regional: métodos e técnicas de análise regional**. Vol. 2. Principia, p. 237-298, 2011.
- SANDRONI, P. H. **Novíssimo dicionário de economia**. São Paulo: Best Seller, 1999.
- SHIKIDA, P. F. A. Crimes violentos e desenvolvimento socioeconômico: um estudo para o Estado do Paraná. In: MEETING OF THE LATIN AMERICAN AND CARIBBEAN LAW AND ECONOMICS ASSOCIATION (ALACDE), 13., 2009. **Anais eletrônicos...** Barcelona, Espanha: Universitat Pompeu Fabra, 2009. Disponível em: <<http://repositories.cdlib.org/bple/alacde/052709-1>>. Acesso em: 13 set. 2015.
- XERXENEVSKY, L. L.; FOCHEZATTO, A. **Índice Relativo de Desenvolvimento Socioeconômico dos Municípios do Litoral do Rio Grande do Sul: uma Aplicação da Análise Fatorial**. In: ENCONTRO DE ECONOMIA DA REGIÃO SUL (ANPECSUL), 14., 2011. **Anais...** Florianópolis: UFSC, 2011.