

DETERMINANTES SOCIOECONÔMICOS E ESPACIAIS DO CONSUMO PER CAPITA DE ENERGIA ELÉTRICA NO ESTADO DO PARANÁ EM 2018

Mauricio Cabral Penteado¹
Fernando Santos da Silva²
Flávia Regina Miecoanski³

Resumo

O artigo analisou a distribuição espacial do consumo de energia elétrica e seus determinantes socioeconômicos e espaciais nos municípios paranaenses em 2018. Foi utilizado o *I* de Moran, diagrama de dispersão e mapa de cluster LISA. Os resultados mostraram que o consumo de energia elétrica e o número de unidades consumidoras apresentaram *I* de Moran estatisticamente significativo e positivo, revelando que municípios com alto (baixo) consumo e número de unidades consumidoras eram rodeados por municípios com alto (baixo) valores dessa variável. E existiam *clusters* BAIXO-BAIXO e ALTO-ALTO para o consumo de energia em 2018. No centro do estado estavam os *clusters* BAIXO-BAIXO e nas bordas os *clusters* ALTO-ALTO. Na análise bivariada, as variáveis PIB *per capita*, densidade demográfica, IPDM- Educação e proporção de trabalhadores na indústria apresentaram correlação espacial positiva com o consumo de energia elétrica *per capita*, e a variável proporção de trabalhadores na agricultura apresentou correlação espacial negativa.

Palavras chave: Energia elétrica. Paraná. Consumo. Municípios.

SOCIOECONOMIC AND SPATIAL DETERMINANTS OF PER CAPITA CONSUMPTION OF ELECTRICITY IN THE STATE OF PARANÁ IN 2018

Abstract

The article analyzed the spatial distribution of electricity consumption and its socioeconomic and spatial determinants in the municipalities of Paraná in 2018. Moran's *I*, scatter diagram and LISA cluster map were used. The results showed that electricity consumption and the number of consumer units had a statistically significant and positive Moran's *I*, revealing that municipalities with high (low) consumption and number of consumer units were surrounded by municipalities with high (low) values of this variable. And there were LOW-LOW and HIGH-HIGH clusters for energy consumption in 2018. In the center of the state were the LOW-LOW clusters and on the edges the HIGH-HIGH clusters. In the bivariate analysis, the variables GDP per capita, demographic density, IPDM-Education and proportion of workers in industry showed a positive spatial correlation with the consumption of electricity per capita, and the variable proportion of workers in agriculture showed a negative spatial correlation.

Keywords: Electric energy. Paraná. Consumption. Counties.

¹ Mestrando no Programa de Pós-Graduação em Energia e Sustentabilidade da Universidade Federal da Integração Latino Americana (UNILA). Email: mauriciocabralpenteado@gmail.com ORCID: 0000-0002-9283-8358

² Doutorando em Desenvolvimento Rural Sustentável. Unioeste. Marechal Cândido Rondon. Paraná. Brasil. E-mail: silva92.fernando@gmail.com. ORCID: <https://orcid.org/0000-0002-4894-1323>

³ Doutoranda em Administração na Universidade Estadual de Maringá- UEM. Paraná. Email: flaviamiecoanski@gmail.com ORCID: 0000-0002-2947-6593

1. Introdução

A energia elétrica é necessária para a existência e manutenção da vida humana. Ela possibilita acesso a bens e serviços e torna viável a maioria das atividades econômicas. O bem-estar das pessoas está relacionado com a capacidade de adquirir bens e serviços e utilizá-los consumindo energia. As atividades econômicas e produtivas são muito dependentes da geração e consumo de energia.

Segundo Hao *et al.* (2016), se uma região apresenta elevada taxa de crescimento econômico, os seus vizinhos podem ser influenciados e se beneficiarem desse desenvolvimento. Assim, o consumo de energia das áreas vizinhas poderá ser afetado pelas políticas de desenvolvimento dessa região. O consumo de energia elétrica pode ter correlação espacial e sofrer influência do espaço geográfico devido à mobilidade dos agentes e transbordamentos dos efeitos econômicos.

O estado do Paraná possui municípios que consomem muita energia, e outros menores, com pouco consumo. Em 2017 era o quinto estado do Brasil em IDH e PIB e em 2020 quarto maior produtor de energia do Brasil e quarto maior consumidor (IBGE, 2020, ANEEL, 2020). Nessa condição, o Paraná precisa de estudos específicos que analisem o setor energético a fim de gerar informações úteis. Assim, o objetivo central desse estudo é investigar os determinantes espaciais do consumo de energia elétrica no estado do Paraná no ano de 2018 e, sendo assim, essa pesquisa buscará mapear o consumo de energia elétrica e também a formação ou não de *clusters*, demonstrando-se por meio de uma análise espacial desses dados, se há possíveis explicações para as diferenças de consumo de energia elétrica em determinadas regiões do Paraná.

No caso da energia elétrica, há pelo menos duas justificativas para considerar que exista a dependência espacial. Segundo Cabral, Legey e Cabral (2017), é provável que regiões vizinhas influenciem o consumo de energia de uma região, porque estas regiões são social e economicamente inter-relacionadas. Sendo assim, primeiro as regiões próximas tendem a ter maior integração, comunicação e cooperação, de tal maneira que regiões vizinhas procurem manter um padrão de desenvolvimento que implica em influências regionais no consumo de energia. Segundo, a mobilidade dos agentes no espaço contribui para uma regionalização do consumo de energia, à medida que as pessoas trabalham e visitam regiões vizinhas, contribuindo para disseminação do consumo de energia.

Variações na produção de uma região levam a variações na dependência e utilização de energia da própria região e das demais regiões do sistema. O crescimento de uma região sob o prisma do consumo de energia tem influência sobre o crescimento da própria região e das regiões com as quais tem relação geográfica ou comercial. Assim, o consumo de energia tem impacto local e regional, causando diversos efeitos em localidades próximas umas das outras (PEROBELI, *et al.*, 2010).

Segundo Huang *et al.* (2019), os efeitos de transbordamento espacial aparecem quando determinadas regiões demonstram desenvolvimento na infraestrutura, sendo de transportes, indústrias, etc. As regiões que estão situadas próximas geograficamente são mais propensas e estimuladas a desenvolver cooperação econômica, regional e social, desta maneira, é provável que as regiões vizinhas estejam relacionadas pelas suas atividades econômicas e ocorra um transbordamento espacial dos efeitos iniciados em uma

determinada região. Assim, negligenciar a correlação espacial pode levar a estimativas enviesadas.

Existem poucos trabalhos na literatura nacional e regional sobre energia elétrica, especificamente com abordagem espacial. Há uma certa escassez de estudos mais regionalizados, uma vez que a maioria busca analisar o setor para o Brasil em sua totalidade. A maior parte das pesquisas na literatura brasileira procura estimar funções de demanda microeconômicas do consumo de energia elétrica. Demais estudos fazem apenas análises históricas sobre o setor energético brasileiro. Nesse sentido, concentram-se as principais contribuições do trabalho, ao tentar identificar determinantes espaciais e socioeconômicos deste consumo.

O artigo está dividido em 4 seções além desta introdução. Na seção 2 é apresentado informações sobre o setor de energia elétrica no estado do Paraná. A seção 3 apresenta a metodologia utilizada na pesquisa e a seção 4 os resultados e discussões. Por fim, a seção 5 traz as considerações finais do trabalho.

2. Energia Elétrica e o Setor no Estado do Paraná

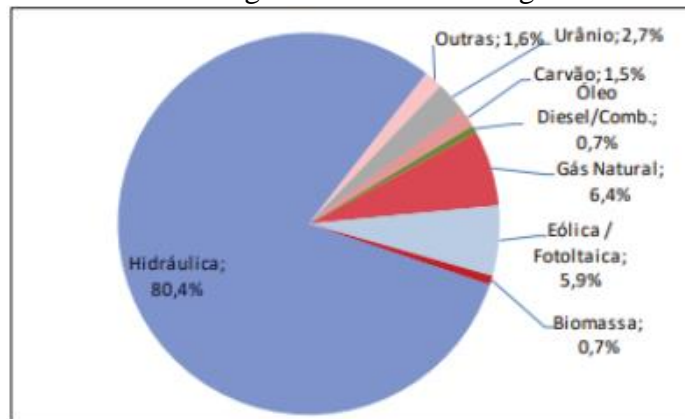
De acordo com a Agência Nacional de Energia Elétrica (ANEEL) (2008), a água é o recurso natural que se apresenta com maior abundância no planeta e é uma das poucas fontes para produção de energia que não contribui para o aquecimento global. Apesar de ser considerada renovável a participação da água na matriz energética mundial ainda é pouco expressiva. Segundo o relatório Key World Energy Statistics (IEA, 2020), entre 1973 e 2018, a participação da força das águas na produção total de energia aumentou de 1,8% para apenas 2,5%. No mesmo período, a energia à carvão saiu de 24,5% para 26,9%, aumento inferior ao do gás natural, que saiu de 16% para 22,8%. Vários elementos explicam esse aparente paradoxo. Um deles está relacionado às características de distribuição da água na superfície terrestre.

Do volume total, a quase totalidade está nos oceanos e, embora pesquisas estejam sendo realizadas, a força das marés não é utilizada em escala comercial para a produção de energia elétrica. Da água doce restante, apenas aquela que flui por aproveitamentos com acentuados desníveis e/ou grande vazão pode ser utilizada nas usinas hidrelétricas, como consequência a utilização desse tipo de energia acontece apenas por um grupo de países com características geográficas propícias (IEA, 2020).

De acordo com (ANEEL) (2019), as fontes de energia renováveis são a principal composição da matriz de geração de energia elétrica no Brasil, onde, no primeiro trimestre de 2019 representaram 87% da produção total, enquanto os demais 13% foram gerados por combustíveis fósseis. Quando se compara com a média mundial, que no ano de 2016 apontava somente 24% da geração baseada em fontes renováveis e o restante de 86% em não renováveis, o Brasil demonstra ter uma produção eficiente de energia renovável (EPE, 2019).

Apesar do índice favorável de 87%, cerca de 80% está concentrada em fontes hidráulicas (Figura 1), sendo as demais, eólica, solar e biomassa, responsáveis por somente 7%, comprometendo a estabilidade da geração de energia por fontes renováveis pelo baixo percentual de diversificação.⁷

Figura 1. Oferta de Energia no Sistema Interligado Nacional (SIN)



Fonte: Boletim de informações gerenciais (ANEEL, 2019)

O estado do Paraná se destaca na geração e no consumo de energia elétrica no Brasil. Contava, em 2020, com 229 empreendimentos em operação gerando 19.300.654,12 kWh de energia, o que correspondia a 11,32% do total gerado no Brasil, ficando atrás apenas de São Paulo (15,78%), Pará (13,65%) e Minas Gerais (12,21%) (ANEEL, 2020). Em 2017 o Paraná foi responsável por consumir 6,58% do total de consumo de energia no Brasil, ficando atrás apenas de São Paulo, Minas Gerais e Rio de Janeiro.

Do total de energia elétrica consumida no estado do Paraná em 2017, 23,82% destinava-se ao setor residencial, 40,36% ao setor industrial, 19,16% ao comercial e 7,69% ao setor rural, além de outros setores. A maioria das unidades consumidoras de energia, em 2017, eram residências, 80%, seguido de comércio com 8,51%, estabelecimentos rurais com 7,70% e indústrias com 1.66% (EPE, 2018).

Apesar de já se destacar na geração de energia, o Paraná tem potencial para crescer e explorar várias fontes de energia, como eólica, solar e biomassa. O estado possui potencial em fontes renováveis. O Sudeste do Paraná possui características favoráveis para instalação de usinas eólicas. O estado também é favorecido em termos de radiação solar (CEPEL, 2002; ANEEL, 2008). No que diz respeito a energia gerada pela biomassa, principalmente pela cana-de-açúcar, já que o bagaço e a palha já são utilizados como fonte de energia. O volume já produzido de cana e o potencial de crescimento permitem demanda crescente para etanol e resíduos para produção de energia. (ANEEL, 2008).

O Paraná apresenta bons índices de irradiação solar, com destaque para a mesorregião Noroeste, que possui a maior média anual e menor variabilidade da irradiação global. Os altos índices de irradiação encontrados em toda a região Norte e em direção ao Oeste do estado fazem com que a média seja elevada, superior a grande parte dos países grandes europeus como Alemanha, Reino Unido e França (TIEPOLO, *et al.*, 2018).

3. Metodologia

No que diz respeito a natureza do estudo, classifica-se como pesquisa aplicada. O objetivo é gerar conhecimentos para aplicação prática dirigidos à solução de problemas

específicos (GIL, 2008). Quanto a natureza dos dados utilizados na pesquisa, são dados oriundos da Base de dados do estado do Paraná (IPARDES) e, para um melhor entendimento dos resultados, estão dispostas no Quadro 1. Ademais, serão utilizados esses dados para a realização da análise espacial.

Quadro 1 - Descrição das variáveis

Variável	Descrição da Variável	Fonte	Sinal Esperado
Ln_Cons_Perc	Logaritmo Natural do Consumo de energia elétrica (kw/h)/População estimada pelo IBGE	IPARDES(2018); IBGE(2018)	Variável dependente
Ln_PIB_perc	Logaritmo Natural do PIB per capita	IPARDES(2018)	(+)
Ln_Dens_Dem	Logaritmo Natural da Densidade Demográfica (hab/km ²)	IPARDES(2018)	(+)
IPDM_Educ	Índice IPARDES de Desenvolvimento para a Educação	IPARDES(2018)	(+)
Prop_Ind	Proporção de trabalhadores na Indústria número de empregados na indústria/número total de empregados do município	IPARDES(2018); RAIS(2018)	(+)
Prop_Com	Proporção de trabalhadores no comércio (número de empregados no comércio/número total de empregados do município)	IPARDES(2018); RAIS (2018)	(+)(-)
Prop_Ser	Proporção de trabalhadores em serviços (número de empregados em serviços/número total de empregados do município)	IPARDES(2018); RAIS(2018)	(+)
Prop_Agr	Proporção de trabalhadores na agropecuária (número de empregados na agropecuária/número total de empregados do município)	IPARDES(2018); RAIS(2018)	(-)

Fonte: Dados retirados da Base de Dados do IPARDES (2018).

Para Tobler (1970), entre si, todas as coisas estão relacionadas, porém se há proximidade, essas coisas são mais relacionadas entre si do que coisas distantes. Anselin (1998) trouxe inovação ao apresentar a AEDE como um conjunto de técnicas, para estudar padrões espaciais (clusters), apresentar regimes espaciais diferentes e diversas formas de não estacionaridade espacial. Na AEDE a autocorrelação é, muitas vezes, a ferramenta mais importante, pois procura mostrar o fenômeno em que a proximidade espacial é acompanhada por valor de correlação.

3.1 Análise Exploratória de Dados Espaciais - AEDE

A Análise Exploratória de Dados Espaciais (AEDE) faz uso de dados georreferenciados e com frequência é utilizada para verificar a existência de padrões espaciais, como a dependência espacial e a heterogeneidade espacial, em que pode mostrar indícios de semelhanças entre regiões vizinhas. Este método leva em consideração o relacionamento e a distribuição que os dados possuem no espaço. A AEDE, possui grande importância nos estudos dos processos de difusão espacial, pois indica possíveis padrões

de autocorrelação espacial (ANSELIN, 1994; HAINING, 1997; GOODCHILD et al., 2000).

A criação de uma matriz de vizinhança é imprescindível para fazer uma análise espacial, que também pode ser denominada de matriz de distância, matriz de conectividade ou matriz de proximidade. Esta matriz de proximidade mostra a relação espacial de cada área a ser estudada, podendo ser unida pela lista de vizinhos de cada polígono, pela distância entre eles e pela conectividade ponderada pelo comprimento da fronteira comum (ARAÚJO et al., 2014).

Qualquer variável pode ser espacialmente defasada para qualquer unidade espacial. O mais comum para quantificar a estrutura de dependência espacial é criando e utilizando uma matriz de peso espacial (ANSELIN, 1992).

Segundo Anselin (1995), é possível construir uma matriz de pesos espaciais $W(n \times n)$, em que cada um dos elementos W_{ij} é uma medida de proximidade entre A_i e A_j . Sendo assim, esta medida é calculada seguindo os critérios:

$w_{ij} = 1$, quando o centro i de A_i está a uma certa distância de A_j ; senão $w_{ij} = 0$;

$w_{ij} = 1$, quando A_i compartilha um lado comum com A_j ; senão $w_{ij} = 0$;

$w_{ij} = l_{ij}/l_i$, onde l_{ij} é o comprimento da fronteira entre A_i e A_j e l_i é o perímetro de A_i ;

3.2 Associação Espacial Global Univariada

O primeiro passo quando se trata de um estudo AEDE é testar a hipótese de que os dados espaciais possuem distribuição aleatória. De maneira intuitiva, a existência de aleatoriedade espacial significa que os valores de um atributo observado em uma região não dependem dos valores desse mesmo atributo observado nas regiões vizinhas. Há na literatura um conjunto de estatísticas que fazem a averiguação por meio de testes formais sobre a presença de autocorrelação espacial, buscando a existência de coincidência de similaridade de valores de um atributo observado com a similaridade da localização do mesmo. Se tratando de estatísticas de teste, é apresentada como hipótese nula a aleatoriedade espacial, significando que os valores observados da variável ao qual o estudo tem interesse não dependem da sua localização e possui distribuição aleatória no espaço (ALMEIDA, 2012).

3.3 Estatística I de Moran Global Univariada

O coeficiente de correlação espacial I de Moran foi pela primeira vez proposto em 1948 e, formalmente, essa estatística é apresentada como:

$$I = \frac{n}{\sum \sum w_{ij}} + \frac{\sum \sum w_{ij} (y_i - \bar{y})(y_j - \bar{y})}{\sum (y_i - \bar{y})^2}$$

Onde: n é o número de unidades espaciais, y_i é a variável de interesse, w_{ij} é o peso espacial dado ao par de unidades espaciais i e j , para medir o grau de interação entre elas.

Para Odland (1988), a estatística I de Moran é um coeficiente de associação linear do tipo cruzado, padronizado por dois termos, onde o primeiro termo faz referência a

variância dos dados de interesse e o segundo demonstra a ideia da configuração espacial dos dados. A dupla somatória significa que todos os elementos da matriz de pesos espaciais W devem ser somados, mostrando a densidade dessa matriz de peso. Dessa maneira, a estatística I de Moran é fundamentada nas somas de produtos cruzados de y_i para regiões vizinhas, obedecendo um critério de vizinhanças oferecido pela matriz de pesos espaciais W .

Segundo Krempi (2004), a autocorrelação espacial pode ter valor negativo ou positivo. Ocorrendo um elevado nível de autocorrelação espacial positiva, então os valores analisados em uma localidade deverão ser parecidos aos valores em regiões próximas ou vizinhas, sendo valores altos próximos a valores altos e valores baixos próximos a valores baixos. Se o contrário ocorrer, ou seja, autocorrelação negativa, os valores altos estão próximos de valores baixos, isso mostra que a média ponderada é menor para os vizinhos do que o valor analisado no próprio local.

O índice global de Moran (I), é uma das formas para calcular a autocorrelação espacial. Esta estatística varia entre -1 e 1, proporcionando, então, uma medida global de associação espacial entre os valores e a média ponderada dos valores da vizinhança, ou Lags espaciais. Valores próximos de zero indicam que não existe significativa autocorrelação espacial e valores próximos de um indicam que existe dependência espacial entre a variável nas áreas vizinhas (ANSELIN, 1995).

Existem duas maneiras para fazer a verificação quanto a significância estatística deste teste por meio da computação do desvio padrão de I . O pressuposto da normalidade assume que a variável padronizada, tem uma distribuição amostral seguindo uma distribuição normal com média zero e variância unitária (ALMEIDA, 2012).

3.4 Associação Espacial Global Multivariada

A associação espacial global multivariada verifica se existe um padrão de associação espacial entre duas variáveis e, segundo Anselin et al (2003), ela pode ser estudada nesse contexto multivariado e a ideia intuitiva é estudar como os valores encontrados em uma determinada região possuem uma relação com valores de uma outra variável observada nas regiões vizinhas. Para isso, calcula-se a estatística I de Moran para as duas variáveis em questão.

3.5 Estatística I de Moran Global Multivariada

A estatística I de Moran tem dois componentes diferentes. Como se trata da versão multivariada dessa estatística, o numerador mostra uma medida de associação linear do tipo produto-cruzado e o denominador representa um reescalonamento pela divisão de tal medida pela soma dos quadrados da primeira variável, que por sua vez se iguala ao tamanho da amostra n .

$$I_{kl} = \frac{z'_k W z_l}{n}$$

3.6 Associação Espacial Local Univariada

A indicação de padrões globais de associação espacial pode também aparecer em conformidade com padrões locais, embora não necessariamente seja prevalecente. Há dois casos distintos, o primeiro em que ocorre quando uma ausência de autocorrelação global esconde padrões de associação local, e o caso oposto, onde ocorre um forte indício de autocorrelação global e isso acaba ocultando padrões locais (clusters ou outliers espaciais). Por consequência, as estatísticas globais de autocorrelação não possuem capacidade de identificação de ocorrência de autocorrelação local que sejam estatisticamente significantes (ANSELIN, 1995).

3.7 Estatística I de Moran local Univariada

Com objetivo de ultrapassar o obstáculo da não identificação de autocorrelação local, foi proposto na literatura um novo indicador, com a capacidade de capturar padrões locais de associação linear que fossem estatisticamente significantes (ALMEIDA, 2012).

O indicador I de Moran local faz uma decomposição do indicador global de autocorrelação na contribuição local de cada observação em quatro categorias, em que cada uma corresponde individualmente a um quadrante no diagrama de dispersão de Moran e, sua interpretação sugere uma indicação do grau de agrupamento dos valores similares em torno de uma observação, demonstrando clusters espaciais que possuem significância estatística (ANSELIN, 1995).

Ainda de acordo com Anselin (1995), para uma observação i essa estatística pode ser estabelecida como:

$$I_i = \frac{(y_i - \bar{y}) \sum_j w_{ij} (y_j - \bar{y})}{\sum_i (y_i - \bar{y}) / n}$$

Ou por:

$$I_i = z_i \sum_j w_{ij} z_j$$

Onde as variáveis padronizadas são z_i e z_j e a somatória sobre j considera somente os valores dos vizinhos $j \in J_i$ na inclusão. Assim, o conjunto J_i contém os vizinhos da observação i .

3.8 Estatística I de Moran local multivariada

Segundo Anselin (1995) e Almeida (2012), se é possível obter uma estatística de autocorrelação espacial global num contexto multivariado, também existe a possibilidade de se conseguir uma medida de autocorrelação espacial local multivariada, readaptando a fórmula da estatística I de Moran local para:

$$I_{kl}^i = z_k^i \sum_j w_{ij} z_j^i$$

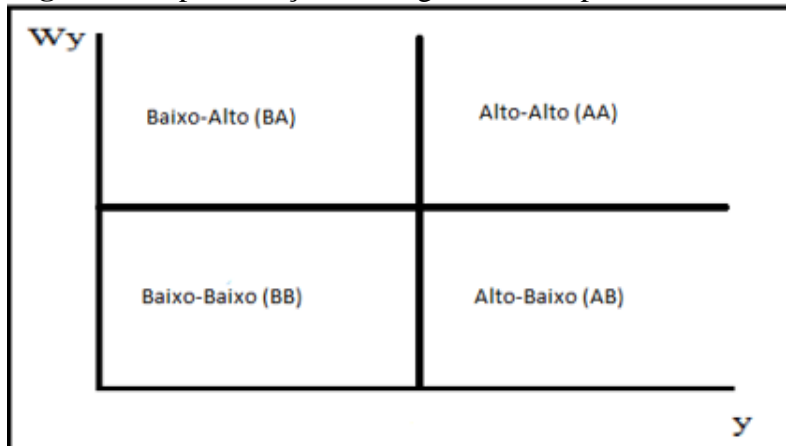
Essa estatística informa uma indicação do grau de associação linear entre o valor de uma variável no local i e a média de uma outra variável nos locais vizinhos a ela, podendo essa associação linear ser positiva ou negativa.

O diagrama de dispersão de Moran apresenta a defasagem espacial da variável ao qual o pesquisador tem interesse, que é a média no atributo nos vizinhos, no eixo vertical e o valor dessa mesma variável de interesse no eixo horizontal e, para analisar a presença de associação espacial através do diagrama, se faz necessário observar que tanto a variável de interesse y , quanto a sua defasagem espacial Wy , são padronizadas quando mostradas no diagrama. Desta maneira, pode-se interpretar o I de Moran como sendo o coeficiente angular da regressão da defasagem espacial Wy contra a variável de interesse y (ALMEIDA, 2012):

$$b = \frac{y'Wy}{y'y}$$

Para Anselin (1995), caso haja resultado positivo para o coeficiente angular, então existe autocorrelação espacial positiva, caso ocorra o contrário e o coeficiente angular seja negativo, então há evidências que a autocorrelação espacial é negativa, assim sendo é possível fazer análises sobre a presença de clusters. Para melhor explicar o diagrama de dispersão de Moran, o mesmo é representado na Figura 2.

Figura 2. Representação do diagrama de dispersão de Moran



Fonte: Elaborado pelos autores (2021).


Esse diagrama fornece informações interessantes, tais como a formação de clusters, que representam a ocorrência de associação linear espacial, dos tipos Alto-Alto (AA), quando as unidades espaciais que pertencem a esse agrupamento possuem valores altos da variável estudada e está cercada de unidades espaciais que apresentam também valores altos, Baixo-Baixo (BB), que se refere a um cluster em que as unidades espaciais apresentam valores baixos e são cercadas por unidades parciais que também mostram valores baixos dessa mesma variável, Alto-Baixo (AB), que refere-se a um agrupamento em que uma unidade espacial possui alto valor da variável e possui vizinhos em que o valor da variável é baixo e Baixo-Alto (BA), que especifica um agrupamento em que uma unidade espacial que possui um valor baixo da variável observada e é cercada por unidades espaciais que possuem valores altos da mesma variável (ALMEIDA, 2012).

4. Resultados e Discussão

Nesta seção é apresentado um breve panorama do consumo de energia elétrica nos municípios paranaenses e a análise exploratória de dados espaciais do consumo de energia elétrica, que é estreitamente relacionada ao consumo de energia. O período de análise é o ano de 2018, com dados anuais.

A Figura 3 apresenta a distribuição espacial do consumo de energia elétrica per capita no estado do Paraná para o ano de 2018. Nessa análise os valores da variável são divididos em 5 intervalos (quantis), sendo que o intervalo contém o mesmo número de unidades apresentadas em cada um deles, ou seja, a mesma dimensão que se refere a municípios.

Figura 3. Distribuição espacial do consumo de energia elétrica *per capita* no estado do Paraná



Fonte: Elaborado pelos autores, com base no Software Geoda.

Nota: Aproximadamente 80 municípios por intervalo.

Os municípios com maior consumo de energia elétrica *per capita* estão concentrados em todas as bordas do estado, principalmente próximo à Região Metropolitana de Curitiba, Norte e Oeste paranaense. Toda a região central do estado é composta por municípios com baixo consumo de energia. Esse padrão de concentração de municípios com maior consumo nas bordas do estado é explicado por ali se concentrarem as cidades mais populosas do estado. Já o centro do estado, além de contar com cidades menos populosas e menos desenvolvidas.

A estatística de I de Moran global univariada para a variável dependente, os diagramas de dispersão de Moran e as estatísticas de *cluster* LISA é apresentada na Tabela 2, a fim de não tornar a análise exploratória exaustiva. As informações para o I de Moran univariado são apresentadas levando em consideração as matrizes rainha, torre, k5, k7 e k10 vizinhos, respectivamente, buscando robustez para a pesquisa. As demais análises são apresentadas apenas para uma das convenções.

A Tabela 1 apresenta o índice de Moran para a variável consumo total de energia elétrica *per capita*, em logaritmo natural, para várias matrizes de pesos espaciais diferentes. É possível verificar que em todos os anos e em todas as convenções espaciais utilizadas, o I de Moran foi estatisticamente significativo e positivo, indicando a

dependência espacial da variável. Destaca-se nessa tabela a matriz de 5 vizinhos, que conseguiu captar a máxima relação espacial em todos os anos analisados.


Tabela 1- I de Moran Global univariado para ln do consumo total de energia elétrica *per capita*

Matriz	I de Moran	p-value	z-value
Rainha	0.2012	0.001	6.6897
Torre	0.2032	0.001	6.7282
K5	0.2125	0.001	7.1782
K7	0.2033	0.001	8.1552
K10	0.1828	0.001	8.7419

Fonte: Elaborada pelos autores, com base no Software Geoda. Nota: $E(I) = -0,0025$. Pseudo p-value baseado em 999 permutações aleatórias.

A autocorrelação espacial também pode ser verificada por meio do diagrama de dispersão de Moran, conforme apresenta a Figura 4.

Figura 4 - Diagrama de Dispersão de Moran para ln consumo total de energia elétrica *per capita*



Fonte: Elaborado pelos autores, com base no Software Geoda.
Nota: Matriz k5 vizinhos. 999 permutações aleatórias.


Nele é possível verificar a relação entre uma variável de interesse e ela mesma defasada espacialmente. A Figura 4 apresenta o diagrama de dispersão de Moran para o consumo total de energia elétrica *per capita* utilizando a matriz de 5 vizinhos. Essa matriz foi escolhida para todos os diagramas por ter conseguido captar maior autocorrelação espacial dentre as várias matrizes utilizadas na análise do I de Moran univariado.

É possível identificar que os municípios paranaenses estavam bastante divididos entre os quatro quadrantes com relação ao consumo total de energia elétrica *per capita*. De forma geral, a maioria estava concentrada nos quadrantes AA e BB. Ou seja, a maioria deles possuía alto (baixo) consumo de energia *per capita* e estava rodeado por municípios que também possuíam alto (baixo) consumo de energia *per capita*.

A estatística *I* de Moran local univariada, chamada de mapa de *cluster* LISA, permite a decomposição do *I* de Moran na contribuição de cada observação individual. Esta serve para avaliar a influência de cada município na magnitude da estatística global e para identificar *clusters* e *outliers* espaciais. A Figura 5 apresenta o mapa de *cluster* para a variável consumo de energia elétrica total *per capita* para os municípios paranaenses no ano de 2018. Todos os mapas LISA foram elaborados com a matriz k5 vizinhos.

Verifica-se a existência principalmente de *clusters* BAIXO-BAIXO e ALTOALTO para o consumo total de energia elétrica *per capita* no estado do Paraná. Alguns municípios pertencentes às mesorregiões Centro Ocidental, Centro Oriental e Centro Sul, em sua maioria, possuíam baixo consumo de energia e eram rodeados por municípios também com baixo consumo. Destaca-se no *cluster* ALTO-ALTO, na mesorregião Oeste, os municípios de Toledo, Marechal Cândido Rondon, Assis Chateaubriand e Matelândia, além destes, os municípios de Verê e São Jorge do Oeste pertenciam ao *clusters* ALTO-ALTO.

Figura 5 - Mapa de *cluster* LISA para ln consumo total de energia elétrica *per capita*



Fonte: Elaborado pelos autores, com base no Software Geoda.
Nota: Matriz k5 vizinhos. 999 permutações aleatórias.

Por meio da estatística *I* de Moran bivariada é possível analisar a existência ou não de autocorrelação espacial entre duas variáveis. De acordo com o resultado do *I* de Moran da Tabela 2, observa-se que há autocorrelação espacial positiva, com significância estatística, entre o consumo *per capita* de energia elétrica e as variáveis PIB *per capita*, densidade demográfica, índice IPDM de educação e proporção de trabalhadores da indústria.

Verifica-se então que municípios com maior consumo *per capita* de energia elétrica, tendem a ser cercados por municípios que apresentam maior PIB *per capita*, densidade demográfica, índice IPDM de educação e proporção de trabalhadores na indústria, o que sugere que sejam municípios mais desenvolvidos, por outro lado, municípios com consumo *per capita* baixo de energia elétrica tendem a ser cercados de municípios mais pobres e menos desenvolvidos. Nota-se também a existência de autocorrelação espacial negativa entre a variável consumo *per capita* de energia elétrica e a

proporção de trabalhadores na agropecuária, ademais, as outras variáveis não apresentaram significância estatística.

Tabela 2- I de Moran Global univariado para Ln do consumo total de energia elétrica *per capita*

Variáveis	I de Moran	p-value	z-value
Ln Consumo <i>per capita</i> x Ln PIB <i>per capita</i>	0.1383	0.001	5.7777
Ln Consumo <i>per capita</i> x Ln Dens Demográfica	0.0902	0.002	4.0075
Ln Consumo <i>per capita</i> x IPDM-Educação	0.0865	0.001	3.7439
Ln Consumo <i>per capita</i> x Prop Trab Indústria	0.1154	0.001	4.7352
Ln Consumo <i>per capita</i> x Prop Trab Comércio	-0.0163	0.232	-0.7466
Ln Consumo <i>per capita</i> x Prop Trab Serviços	0.0171	0.225	0.7630
Ln Consumo <i>per capita</i> x Prop Trab Agropecuária	-0.03111	0.083	-1.3622

Fonte: Elaborada pelos autores, com base no Software Geoda. Nota: E(I) = -0,0025.

Pseudo p-value baseado em 999 permutações aleatórias

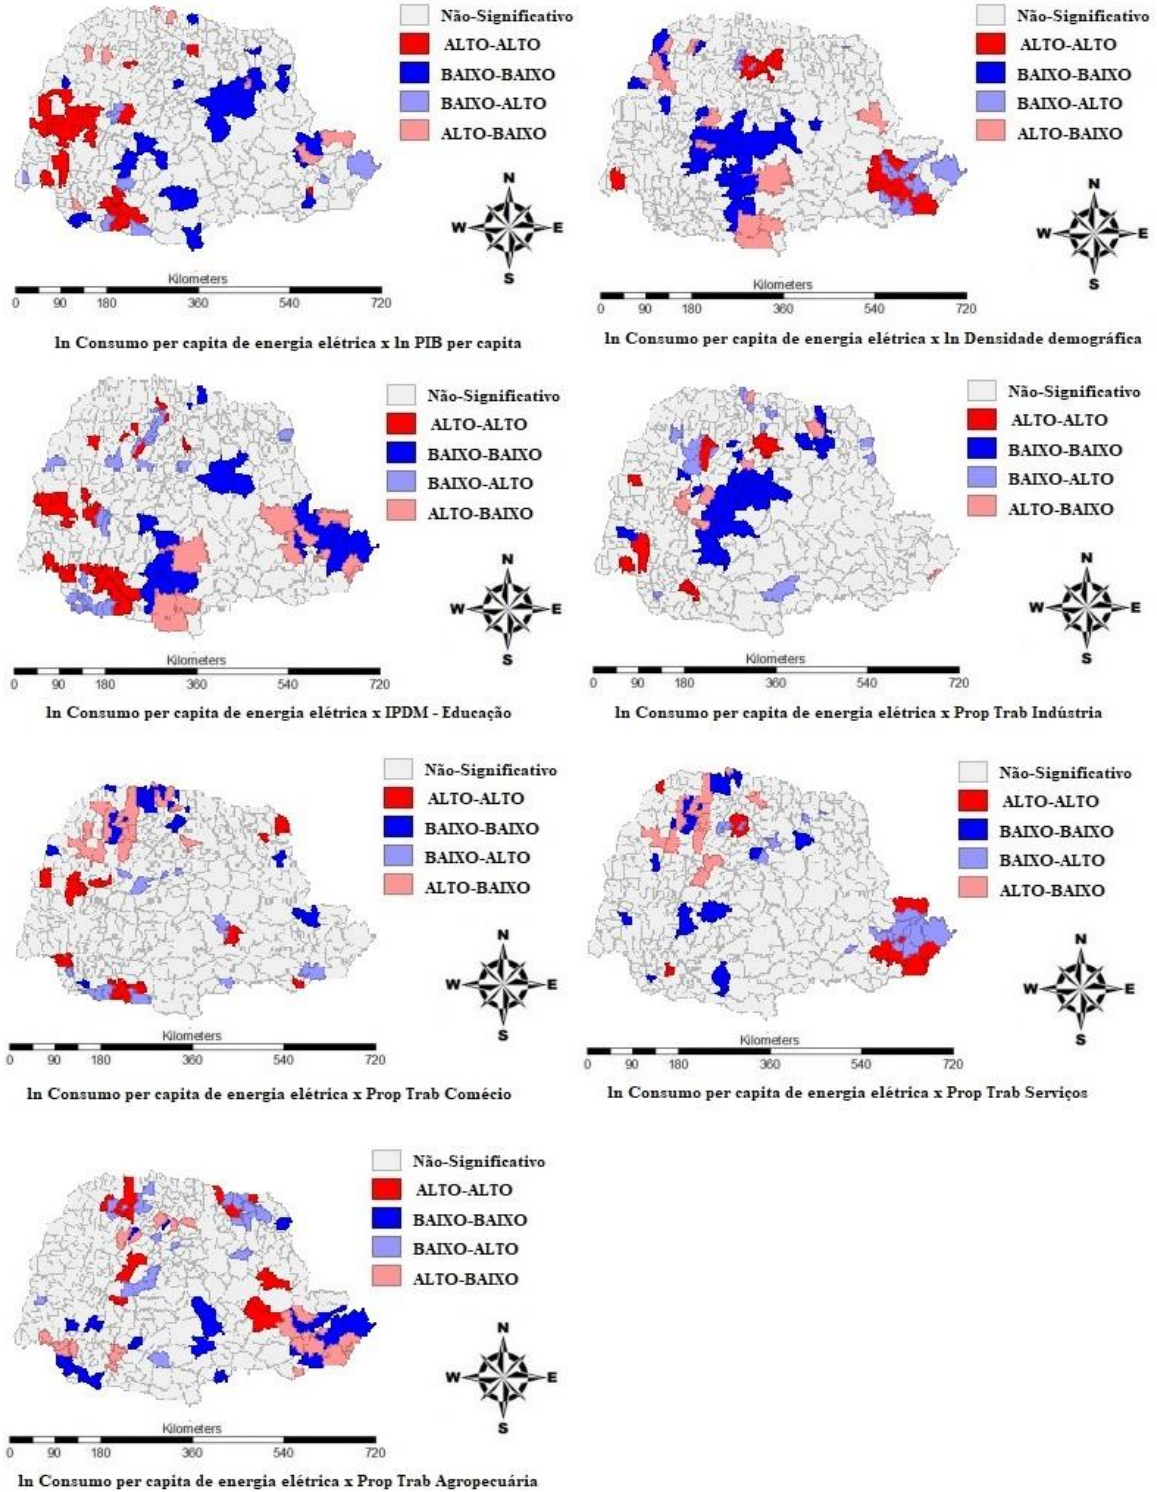
Na Figura 6, é possível verificar os *clusters* ALTO-ALTO e BAIXO-BAIXO na relação entre as variáveis consumo *per capita* de energia elétrica e PIB *per capita*, o que corrobora com o que já foi citado nos resultados da Tabela 2, onde regiões com maior consumo *per capita* de energia elétrica, também possuem municípios com maiores PIB *per capita*, assim como, municípios com baixo consumo *per capita* de energia elétrica, estão cercados de municípios com PIB *per capita* baixo, os *clusters* ALTO-ALTO localizam-se nas regiões Oeste e Sudoeste, enquanto que o *cluster* BAIXO-BAIXO localiza-se na região Nordeste do estado.

Em relação a densidade demográfica, nota-se a presença de *cluster* BAIXO-BAIXO na região Centro-Sul e de ALTO-ALTO na Região Metropolitana de Curitiba, além da presença de um *cluster* BAIXO-ALTO na região Sudeste. No que diz respeito a relação entre o consumo *per capita* de energia elétrica e o índice IPDM-Educação, observa-se a presença de *clusters* BAIXO-BAIXO nas regiões Centro-Sul e Sudeste e ALTO-ALTO nas regiões Sudoeste e Oeste, além de um *cluster* ALTO-BAIXO na região Sul do estado.

Ainda na Figura 6, observa-se na relação entre consumo *per capita* de energia elétrica e Proporção de Trabalhadores na Indústria, a presença de um *cluster* BAIXO-BAIXO na região Central do estado, o que corrobora com o fato de ser a região menos industrializada do Paraná. Seguido com a relação entre consumo *per capita* e Proporção de Trabalhadores no Comércio, é possível perceber que não há nenhum grande *cluster* em nenhuma região do estado, o que explica a variável ter sido não-significativa na Tabela 2.

Em que se analise a relação entre o consumo *per capita* de energia elétrica e a Proporção de Trabalhadores em Serviços, é possível destacar a presença de *clusters* ALTO-ALTO e BAIXO-ALTO, nas regiões Sudeste e do Litoral, respectivamente, ainda que não seja uma variável com significância estatística. Em seguida, observa-se na relação entre consumo *per capita* de energia elétrica e Proporção de Trabalhadores na Agricultura, a presença de *clusters* BAIXO-BAIXO no Litoral e de ALTO-BAIXO na Região Metropolitana de Curitiba, visto que são regiões com baixa presença do setor agrícola.

Figura 6 - Mapa de clusters LISA



Fonte: Elaborada pelos autores, com base no Software Geoda.

Nota: Matriz k5 vizinhos. 999 permutações aleatórias.

5. Considerações Finais

O consumo de energia elétrica sofre influência do espaço geográfico. Como os agentes econômicos se movem no espaço, as pessoas podem morar em um lugar, trabalhar em outro, e se deslocar frequentemente, com isso, regiões próximas umas das outras tendem a ser mais integradas economicamente e socialmente, de tal maneira que pode acontecer difusão no consumo de energia.

Assim, esse artigo teve por objetivo analisar a distribuição espacial do consumo de energia elétrica nos municípios paranaenses no ano de 2018, assim como de seus determinantes. O consumo de energia elétrica é fundamental para muitas atividades econômicas e para a sobrevivência das pessoas, pois facilita o acesso aos bens e serviços e melhora a qualidade de vidas das pessoas e, devido a sua importância, é visto também como indicador de crescimento e desenvolvimento econômico.

Pela sua importância na geração e no consumo de energia elétrica para o Brasil, foi estudado o setor elétrico do estado do Paraná e feito uma análise da distribuição espacial do consumo de energia e de seus determinantes. O consumo de energia elétrica foi espacialmente correlacionado no estado do Paraná. Existia concentração de municípios com alto consumo de energia *per capita* em todas as bordas do estado do Paraná, principalmente próximo à Região Metropolitana de Curitiba, Norte, Campos Gerais e Oeste paranaense.

Toda a região central do estado era composta por municípios com baixo consumo de energia. O *I* de Moran revelou dois *clusters* sendo um ALTO-ALTO na região Oeste onde municípios com alto consumo de energia elétrica *per capita* eram rodeados de municípios com alto consumo *per capita*. Também apresentou um *cluster* BAIXO-BAIXO na região central, onde municípios com baixo consumo *per capita* de energia elétrica eram cercados de municípios com baixo consumo *per capita*.

Na análise Bivariada, observa-se que há autocorrelação espacial positiva, com significância estatística, entre o consumo *per capita* de energia elétrica e as variáveis PIB *per capita*, densidade demográfica, índice IPDM de educação e proporção de trabalhadores da indústria. Os resultados apresentaram que municípios com maior consumo *per capita* de energia elétrica, tendem a ser cercados por municípios que apresentam maior PIB *per capita*, densidade demográfica, índice IPDM de educação e proporção de trabalhadores na indústria, o que sugere que sejam municípios mais desenvolvidos, por outro lado, municípios com consumo *per capita* baixo de energia elétrica tendem a ser cercados de municípios mais pobres e menos desenvolvidos. Nota-se também a existência de autocorrelação espacial negativa entre a variável consumo *per capita* de energia elétrica e a proporção de trabalhadores na agropecuária, ademais, as outras variáveis não apresentaram significância estatística.

Os resultados apresentaram *clusters* ALTO-ALTO e BAIXO-BAIXO na relação entre as variáveis consumo *per capita* de energia elétrica e PIB *per capita*, os *clusters* ALTO-ALTO localizam-se nas regiões Oeste e Sudoeste, enquanto que o *cluster* BAIXO-BAIXO localiza-se na região Nordeste do estado. Em relação a densidade demográfica, nota-se a presença de *cluster* BAIXO-BAIXO na região Centro-Sul e de ALTO-ALTO na

Região Metropolitana de Curitiba, além da presença de um *cluster* BAIXO-ALTO na região Sudeste. No que diz respeito a relação entre o consumo *per capita* de energia elétrica e o índice IPDM-Educação, observa-se a presença de *clusters* BAIXO-BAIXO nas regiões Centro-Sul e Sudeste e ALTO-ALTO nas regiões Sudoeste e Oeste, além de um *cluster* ALTO-BAIXO na região Sul do estado.

Ainda se observa nos resultados, na relação entre consumo *per capita* de energia elétrica e Proporção de Trabalhadores na Indústria, a presença de um *cluster* BAIXO-BAIXO na região Central do estado, o que corrobora com o fato de ser a região menos industrializada do Paraná. Em seguida, verifica-se na relação entre consumo *per capita* de energia elétrica e Proporção de Trabalhadores na Agricultura, a presença de *clusters* BAIXO-BAIXO no Litoral e de ALTO-BAIXO na Região Metropolitana de Curitiba, visto que são regiões com baixa presença do setor agrícola.

Este trabalho contribuiu para a literatura pelo fato da escassez de análises do setor de energia elétrica para estados ou regiões, especificamente para o estado do Paraná. A análise do setor elétrico brasileiro é comumente feita em pesquisas qualitativas, não tendo até o momento análise espacial ampla dessa natureza. Para estudos futuros orienta-se acompanhar a divulgação das informações para possível atualização dos dados. Essa pesquisa pode ser aplicada também para outros estados brasileiros, a fim de conhecimento do setor, para embasar a tomada de decisão e justificar políticas públicas.

Referências

ANEEL- Agência Nacional de Energia Elétrica. *Atlas da Energia Elétrica do Brasil*. 3º edição. 2008.

ANEEL - AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA. *Boletim de Informações Gerenciais*. p. 1131–1141, 2019. Relatório Técnico.

ANEEL - AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA. *BIG- Banco de Informações de Geração*. 2020. Disponível em:

<<https://app.powerbi.com/view?r=eyJrIjoiNjc4OGYyYjQtYWM2ZC00YjllLWJlYmEtYzdkNTQ1MTc1NjM2IiwidCI6IjQwZDZmOWI4LWVjYTctNDZhMi05MmQ0LWVhNGU5YzAxNzBIMSIsImMiOiJR9>>. Acesso em: 25 jun. 2021.

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

ANSELIN, L. *Spatial Data Analysis with GIS: An Introduction to Application in the Social Sciences*. 1992. Disponível em: <

http://www.ncgia.ucsb.edu/Publications/Tech_Reports/92/92-10.PDF >. Acesso: 10 de mai. De 2021.

ANSELIN, L. Exploratory spatial data analysis and geographic information systems. In: PAINHO, M. (Ed.) *New tools for spatial analysis: proceedings of the workshop*. Luxemburgo: EuroStat. p.45-54. 1994.

ANSELIN, L. *Local indicators of spatial association - LISA*. Geographical Analysis, Ohio/USA, 27:91-115, 1995.

ANSELIN, L. Interactive techniques and exploratory spatial data analysis. LONGLEY, P.A, GOODCHILD, M. F.; MAGUIRE, D.J.; WIND, D. W. (eds). *Geographical information system: principles, techniques, management and applications*. Wiley: New York. p 253-365, 1998.1

ARAÚJO, E. C; URIBE-OPAZO, M. A; JOHANN, J. A. Modelo de regressão espacial para estimativa da produtividade da soja associada a variáveis agrometeorológicas na região oeste do estado do paraná. *Eng. Agríc.*, Jaboticabal, v.34, n.2, p.286-299, mar./abr. 2014.

CABRAL, J. A.; LEGEY, L. F. L.; CABRAL, M. V. F. Electricity consumption forecasting in Brazil: A spatial econometrics approach. *Energy*, v. 126, p. 124-131, 2017.

CEPEL- Centro de Pesquisa em Energia Elétrica. *Atlas do potencial eólico brasileiro*. 2002.

EPE- Empresa de Pesquisa Energética. *Anuário Estatístico de Energia Elétrica 2018, ano base 2017*. 2018.

EPE - EMPRESA DE PESQUISA ENERGÉTICA. *Matriz energética e elétrica*. Linhas de Transmissão. 2019.

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.

GIL, A. C. *Métodos e Técnicas de pesquisa Social* - 6 Ed. São Paulo: Editora Atlas, 2008.

GOODCHILD, M., ANSELIN, L., APPELBAUM, R. AND HARTHORN, B. Towards spatially integrated social science. *International Regional Science Review* 23, 139- 159. 2000.

HAINING, R., *Spatial Data Analysis in the Social and Environmental Sciences*, Cambridge University Press. 1997 INSTITUTO NACIONAL DE ESTATÍSTICA. Cartografia da pobreza. Cabo Verde. 2004.

HUANG, J., LIU, C., CHEN, S., HUANG, X., HAO, Y. The convergence characteristics of China's carbon intensity: Evidence from a dynamic spatial panel approach. *Science of The Total Environment*, v. 668, p. 685-695, 2019.

IBGE- Instituto Brasileiro de Geografia e Estatística. *IBGE Cidades*.

HAO, Y., LIU, Y., WENG, J., GAO, Y. Does the Environmental Kuznets Curve for coal consumption in China exist? New evidence from spatial econometric analysis. *Energy Economics*, v. 114, p. 1214-1223, 2016.

IEA (2020), *Key World Energy Statistics 2020*, IEA, Paris. Disponível em: <<https://www.iea.org/reports/key-world-energy-statistics-2020>> Acesso em: 10 mai. 2021.

KREMPI, A. P. *Explorando Recursos de Estatística Espacial para Análise da Acessibilidade da Cidade de Bauru*. 2004. 80 f. Dissertação (Mestrado em Engenharia Civil) - Escola de Engenharia de São Carlos, Universidade de São Paulo USP, São Carlos, 2004.

ODLAND J. *Spatial Autocorrelation*. SAGE Publications, 1 de fev de 1988 - 87 páginas.

PEROBELLI, F. S., HADDAD, E. A., FERREIRA NETO, A. B., VILELA, L. P.
Interdependência energética: uma análise inter-regional. *Texto para Discussão, n. 009/2010*. Juiz de Fora: Programa de Pós-Graduação em Economia Aplicada, Faculdade de Economia, Universidade de Juíz de Fora, 2010. 1-21 p.

TOBLER, W. R. A computer movie simulating urban growth in the Detroit region, *Economic Geography*. V.46, p. 234–240, 1970.

TIEPOLO, G. M., PEREIRA, E. B., URBANETZ JUNIOR, J., PEREIRA, S. V.,
GONÇALVES, A. R., LIMA, F. J. L., COSTA, R. S., ALVES, A. R. Atlas de Energia Solar do Estado do Paraná - Resultados. *Revista Brasileira de Energia Solar*, v. 9, n. 1, p. 01-10, 2018.

Recebido em 29/11/2021
Aprovado em 26/01/2022