

# Efeitos espaciais e elasticidades da demanda residencial de eletricidade no Brasil

Daniel Morais de Souza  
Rogério Silva de Mattos  
Eduardo Simões Almeida

## ABSTRACT

The paper presents an econometric analysis of the residential demand for electricity in Brazil that takes into account the spatial effects. A panel dataset comprising 27 Brazilian federation units in the period from 2003 to 2011 is used for the estimation of residential demand equations with focus placed on price and income elasticities. Initially, three panel data econometric methods that disregard spatial effects are used: pooled OLS, fixed effects, and random effects. The latter produced the best estimated model, but a Moran's I test run on its residuals accused the presence of spatial autocorrelation. In the sequel, a pioneering application of spatial panel data models for estimating the residential demand for electricity is presented. Seven random effects models with different types of spatial dependence are estimated, and, according to the *AIC* criterion, a random effects SAC model shows up as the best one. Estimates of -0.031 for the price demand elasticity and of 0.342 for the income-elasticity were obtained and showed to be in accordance with economic theory. A high figure of 0.796 was obtained for the spatial autoregressive coefficient, but it is similar to other estimates reported in the literature. Also, for the residential electricity demand of a particular federation unit, the estimated spatial effects model signals that changes in electricity price and consumer income in neighboring units have a greater impact than similar changes in such variables within the particular unit proper.

O artigo apresenta uma análise econométrica da demanda residencial de eletricidade no Brasil que considera os efeitos espaciais. Uma base de dados em painel para as 27 unidades da federação no período de 2003 a 2011 é usada para se estimar as equações de demanda residencial com foco sobre as elasticidades preço e renda. Inicialmente, três métodos econométricos de dados em painel que desconsideram efeitos espaciais são usados: pooled OLS, efeitos fixos e efeitos aleatórios. O último produziu o melhor modelo estimado, mas a aplicação do teste I de Moran sobre seus resíduos acusou a presença de autocorrelação espacial. Na sequência, uma aplicação pioneira da metodologia de painel de dados espaciais é apresentada. Sete modelos de efeitos aleatórios com diferentes padrões de dependência espacial são estimados e, de acordo com o critério AIC, o modelo de efeitos aleatórios SAC mostrou-se o melhor. Estimativas de -0,031 para a elasticidade-preço e de 0,342 para a elasticidade-renda são obtidas e mostram-se de acordo com a teoria econômica. Um valor elevado de 0,796 é obtido para o coeficiente de autorregressão espacial, porém é similar a outras estimativas reportadas na literatura. Além disso, para a demanda residencial de eletricidade numa unidade da federação em particular, o modelo de efeitos espaciais estimado indica que mudanças no preço da eletricidade e na renda dos consumidores em unidades vizinhas têm um impacto maior do que mudanças similares nessas variáveis dentro da própria unidade.

**Keywords:** Elasticities of demand, Electric energy, Space Panel.

**JEL Classification:** Q41, R21, C2.

# 1 INTRODUÇÃO

A energia elétrica é um insumo de uso amplamente generalizado nas economias modernas e, dentre as diferentes formas de energia disponíveis na natureza, é a que proporciona maior eficiência ao setor produtivo e maior conforto à população nas atividades de consumo residencial (SILVA, 2001). Entretanto, o elevado grau de capilaridade com que a eletricidade penetra na sociedade combinado com as limitações tecnológicas para seu armazenamento em grande escala torna o setor elétrico um segmento bastante sensível. Problemas de abastecimento de eletricidade rapidamente se convertem em “apagões”, ou seja, interrupções do processo produtivo e do consumo residencial com significativos prejuízos econômicos e sociais.

Os desafios evidenciados pelo problema do racionamento de 2001 forneceram uma importante sinalização de que dispositivos adicionais precisariam ser inseridos no funcionamento do setor elétrico de modo a se proporcionar a chamada “segurança energética”, isto é, a garantia de provimento de eletricidade com riscos mínimos de ocorrência dos apagões. Com esse intuito, o governo brasileiro adotou diversas ações, tanto do lado da oferta quanto da demanda. No caso da oferta, foram re-introduzidos o planejamento centralizado e incentivos que garantissem novos investimentos de ampliação da capacidade de geração, transmissão e distribuição. Pelo lado da demanda, foram reforçados os mecanismos de monitoramento do mercado de eletricidade através de sistemas de previsão do comportamento do consumo. Estes sistemas antecipam com máxima precisão as necessidades futuras de eletricidade a curto, médio e longo-prazos, contribuindo para o planejamento da oferta futura de eletricidade.

Uma parte importante da construção desses sistemas de previsão depende de uma adequada compreensão do comportamento do consumidor residencial, na medida em que a classe residencial é a segunda que mais demanda energia elétrica no país. Segundo a literatura, os fatores que mais afetam o consumo residencial são a renda do consumidor e o preço da energia elétrica. Contudo, recentes estudos indicam que a demanda de energia elétrica apresenta interação espacial, ou seja, a demanda de uma região pode influenciar e ser influenciada pela demanda de regiões vizinhas (Blázquez et al, 2013; Cabral, 2017; Cabral et al, 2017; Cho et al, 2015; Ohtsuka et al, 2010; Ohtsuka e Kakamu, 2013). Segundo Blázquez et al (2013), o efeito espacial da demanda de energia elétrica pode existir devido: *i*) ao fenômeno do consumidor de eletricidade imitar o comportamento dos consumidores vizinhos, *ii*) parcerias de mídia entre UFs contribuindo para o contágio espacial dos efeitos psicológicos e sociológicos de uma crise econômica e *iii*) trabalhadores viverem em uma UF porém trabalhar em outra.

Segundo Almeida (2012), desconsiderar os efeitos espaciais implica em relaxar algumas das hipóteses de Gauss-Markov e do modelo clássico de regressão linear, resultando em estimativas viesadas e inconsistentes para os coeficientes do modelo. Buscando considerar os efeitos da interação espacial sobre a demanda residencial de energia elétrica (DREE), este artigo apresenta a metodologia de painel de dados com efeitos espaciais para as 27 unidades da federação (UF) do Brasil no período de 2003 a 2011. São comparados sete modelos considerando diferentes tipos de dependência espacial para a estimação das elasticidades-preço e elasticidade-renda. O melhor modelo obtido foi o de defasagem espacial com erro autoregressivo espacial (SAC), também chamado alternativamente de *Spatial autoregressive model with autoregressive disturbances* (SARAR), que considera a dependência espacial na variável independente e no termo de erro da regressão. Adicionalmente, foram analisados os efeitos espaciais diretos e indiretos da variação do preço da energia elétrica e da renda dos consumidores na DREE. Os impactos indiretos se mostraram superiores aos impactos diretos, mostrando que mudanças no preço da energia

elétrica e na renda dos consumidores de UF vizinhas acarretam maiores variações na DREE do que mudanças das mesmas variáveis na própria UF.

Este artigo foi dividido em cinco seções, incluindo esta introdução. A segunda seção faz uma breve revisão da literatura sobre demanda de energia elétrica. A terceira seção apresenta a metodologia utilizada e os dados. A quarta seção apresenta os resultados das estimações e a quinta e última seção apresenta considerações finais.

## 2 REVISÃO DA LITERATURA

Esta seção apresenta os principais trabalhos sobre a demanda de energia elétrica focando as metodologias empregadas, os períodos de análise e as estimativas de elasticidades-preço e -renda. A primeira subseção aborda os trabalhos internacionais e a segunda os trabalhos nacionais.

### 2.1 *Trabalhos internacionais*

O primeiro trabalho a utilizar modelos de previsão para demanda de energia elétrica foi Houthakker (1951). O autor aplicou o método de regressão múltipla para a estimação das elasticidades -preço e -renda da DREE em um painel de dados de 42 cidades do Reino Unido no período de 1937 a 1938. Seguindo a mesma metodologia, Balestra e Nerlove (1966) estimaram as mesmas elasticidades para a demanda por gás natural no período de 1950 – 1962 para os estados dos Estados Unidos; Baltagi e Griggin (1983) estimaram a demanda por gasolina para os países da OCDE no período de 1960 a 1978; Chern e Bouis (1988) analisaram as mudanças estruturais nos parâmetros da DREE através da especificação e estimação de um modelo dinâmico utilizando dados por estado americano, para o período de 1955-1978; Liu (2004) estima as elasticidades -preço e -renda da energia elétrica, gás natural e óleo diesel nos países da OCDE para o período de 1978-1999 nos três segmentos: industrial, comercial e residencial; Zhou e Teng (2013) estimam as mesmas elasticidades para DREE da província de Sichuan (China), para o período de 2007 a 2009.

Após a publicação dos trabalhos de Johansen (1988 e 1991) e Johansen e Juselius (1990), que introduziram testes de cointegração e uma metodologia consistente para estimação de modelos vetoriais de correção de erros (VCE), diversos trabalhos na área de energia elétrica foram feitos visando prever a demanda de eletricidade e de calcular elasticidades -preço e -renda. Jamil e Ahmad (2011) utilizam esta metodologia para calcular as elasticidades -preço e -renda de curto e longo prazos para as seguintes classes de consumo de energia elétrica do Paquistão: residencial, comercial, industrial e agrícola. Pourazarm e Cooray (2013) estimam um modelo vetorial autoregressivo (VAR) para examinar as relações de curto e longo prazos entre a DREE e seus determinantes para o Irã no período de 1967 a 2009. Lim et al (2014) também utilizam esta metodologia para calcular as elasticidades -preço e -renda de curto e longo prazos para a demanda de energia elétrica na Coreia do Sul no período de 1970 a 2011.

Nenhum dos trabalhos mencionados anteriormente considera a presença de efeitos espaciais na demanda por energia elétrica. O primeiro a testar a existência destes efeitos foi o de Ohtsuka et al (2010). Os autores compararam a capacidade preditiva do modelo *Spatial autorregressive moving average* (SAR-ARMA) com um ARMA(1,1) para analisar a demanda de energia elétrica das dez regiões do Japão no período de Janeiro de 1992 a Janeiro de 2003. Os autores concluem que o melhor modelo é o SAR-ARMA. Posteriormente, Ohtsuka e Kakamu (2013) usaram a mesma base de dados para comparar um modelo SAR-ARMA com um modelo VAR. Os autores concluíram que o modelo VAR se adequa melhor aos dados e produz melhores previsões.

Blázquez et al (2013) apresentam uma análise empírica da DREE considerando a existência de efeitos espaciais. A análise foi realizada em uma base de dados do tipo painel, composta por 46 províncias da Espanha no período de 2001 a 2010. Os autores comparam quatro modelos: efeitos fixos, efeitos fixos com lag espacial, efeitos fixos com erro espacial e o modelo SAC, sendo melhor o último.

Cho et al (2015) analisam a demanda de eletricidade regional da Coreia do Sul para as seguintes classes de consumo: residencial, varejo, fabricação e agrícola. A metodologia proposta pelos autores foi o painel dinâmico com dependência espacial, sendo que o modelo SAC-AR(1) apresentou os melhores resultados. Além de calcular os impactos diretos e indiretos do preço da energia elétrica e renda, os autores fazem previsão da demanda de energia para o período de 2005 a 2020 para as quatro classes admitindo três cenários possíveis.

## **2.2 Trabalhos nacionais**

O primeiro trabalho de modelagem econométrica da demanda por energia elétrica no Brasil foi Modiano (1984). Neste estudo, o autor estima um modelo de regressão múltipla usando o método dos mínimos quadrados ordinários (MQO) para analisar a sensibilidade do consumo à atividade econômica e aos preços da energia elétrica para todas as classes de consumo do Brasil no período de 1963-1981.

Andrade e Lobão (1997) utilizam pela primeira vez um modelo VAR para explicar o consumo residencial de energia elétrica do Brasil. Como variáveis explicativas, os autores utilizaram o preço de eletricidade, a renda dos consumidores e o estoque de eletrodomésticos para o período de 1963 – 1995.

Após Andrade e Lobão (1997), vários outros estudos usando modelos VAR foram feitos, seja para atualizar a equação para o consumo residencial brasileiro (Silva, 2001; Schmidt e Lima, 2004; Oliveira et al, 2010; Viana e Silva, 2014), seja para estender a aplicação para outros segmentos de consumo ou ainda replicar para estados e regiões brasileiros. Nesse sentido, modelos VCE foram estimados por Garcez e Ghirardi (2003) para o consumo residencial do Estado da Bahia, Mattos (2005) para o consumo industrial brasileiro e, no caso do Estado de Minas Gerais, Mattos e Lima (2005) para o consumo residencial, Mattos et al (2005) para o consumo industrial, e Mattos et al (2006) para o consumo comercial. Siqueira et al (2006) e Irffi et al (2009) também estimam modelos VCE para os três segmentos de consumo de eletricidade no Nordeste. Seguindo a abordagem de Modiano (1984), Amaral e Monteiro (2010) estimaram as elasticidades-preço e -renda pré e pós apagão para a DREE do Brasil para o período de 1974-2008.

A literatura nacional apresenta apenas dois trabalhos empregando a metodologia de dados em painel para a previsão da demanda de energia elétrica: *i*) Gomes (2010) estima as elasticidades –preço e –renda da DREE utilizando um banco de dados formado por 63 distribuidoras de energia elétrica para o período de 1999 a 2006; *ii*) Cabral (2017) ajusta o modelo SDM (*Spatial Durbin model*) dinâmico para a demanda regional de eletricidade do Brasil utilizando um painel de dados das cinco macrorregiões do Brasil no período mensal de 2004 a 2014, sendo o primeiro trabalho a incorporar a presença de efeitos espaciais em modelos para a demanda de energia elétrica do Brasil.

Também considerando os efeitos espaciais, Cabral et al (2017) propuseram um método alternativo para aplicar o teste de *I* de Moran na análise exploratória da autocorrelação espacial. Com este novo método, os autores encontraram evidências de que o consumo regional de eletricidade no Brasil é espacialmente dependente, apresentando um padrão de dissimilaridade entre as regiões. Além disso, foram comparadas as performances preditivas de

dois modelos para o consumo regional de eletricidade: espacial ARIMA (ARIMASp) e ARIMA. O modelo ARIMASp apresentou melhores resultados preditivos.

Pode-se notar que apenas os trabalhos de Ohtsuka et al (2010), Ohtsuka e Kakamu (2013), Blázquez et al (2013), Cho et al (2015), Cabral (2017) e Cabral et al (2017) consideram a presença de efeitos espaciais na demanda de energia elétrica, sendo apenas os dois últimos para o caso brasileiro. A Tabela 1 traz uma síntese dos principais resultados dos trabalhos que não incorporaram a presença de efeitos espacial, enquanto a Tabela 2 traz a síntese dos trabalhos que consideraram estes efeitos.

Tabela 1- Trabalhos relativos à demanda por energia elétrica que não incorporam efeitos espaciais

<b>Autor</b>	<b>Metodologia</b>	<b>Elasticidade - Preço</b>	<b>Elasticidade - Renda</b>	<b>Classe</b>	<b>Região</b>
<i>Experiência Nacional</i>					
Modiano (1984)	VAR	-0,403	1,130	Residencial	Brasil
Andrade e Lobão (1997)	VAR	-0,051	0,213	Residencial	Brasil
Silva (2001)	VAR	-0,270	0,937	Residencial	Brasil
Schmidt e Lima (2004)	VAR	-0,085	0,539	Residencial	Brasil
Mattos (2005)	VAR	-0,489	1,588	Industrial	Brasil
Mattos e Lima (2005)	VAR	-0,258	0,532	Residencial	Minas Gerais
Mattos et al (2005)	VAR	-0,250	0,539	Industrial	Minas Gerais
Mattos et al (2006)	VAR	-0,772	0,778	Comercial	Minas Gerais
Siqueira et al (2006)	VAR	-0,412	1,400	Residencial	Nordeste
Irfi et al (2009)	VAR	-0,504	0,876	Residencial	Nordeste
Gomes (2010)	Painel	-0,111	0,102	Residencial	Brasil
Amaral e Monteiro (2010)	VAR	-0,431	0,613*	Residencial	Brasil
Oliveira et al (2010)	VAR	-0,391	0,964	Residencial	Brasil
Viana e Silva (2014)	VAR	-0,707	1,790	Residencial	Brasil
<i>Experiência internacional</i>					
Houthakker (1951)	Painel	-0,893	1,166	Residencial	Inglaterra
Balestra e Nerlove (1966)	Painel	-0,630	0,620	Gás natural	Estados Unidos
Acton et al (1980)	Painel	-0,350	0,400	Residencial	Estados Unidos
Baltagi e Griggin (1982)	Painel	(-0,550;-0,900)**	(0,540;0,890)**	Gasolina	Países da OCDE
Liu (2004)	Painel	-0,030	0,058	Energia elétrica	Países da OCDE
		0,070	0,490	Residencial	
Jamil e Ahmad (2011)	VAR	-0,310	0,050	Comercial	Paquistão
		-0,060	0,640	Industrial	
		-0,190	0,240	Agrícola	
Pourazarm e Cooray (2013)	VAR	0	0,580	Residencial	Irã
Zhou e Teng (2013)	Painel	(-0,35;-0,5)**	(0,14;0,33)**	Residencial	Sichuan (China)
Lim et al (2014)	VAR	-1,002	1,090	Energia elétrica	Coréia do Sul

Fonte: Elaboração própria.

Nota: \* após 2000. \*\* Limites inferior e superior das elasticidades.

Tabela 2 - Trabalhos relativos à demanda por energia elétrica que incorporam efeitos espaciais

<b>Autor</b>	<b>Metodologia</b>	<b>Região estudada</b>	<b>Principais resultados</b>
Ohtsuka et al (2010)	SAR-ARMA; ARMA	9 distribuidoras japonesas	O modelo SAR-ARMA(1,1) mostrou melhor capacidade preditiva que o modelo ARMA(1,1).
Ohtsuka e Kakamu (2013)	SAR-ARMA; VAR	9 distribuidoras japonesas	O modelo VAR(1) mostrou melhor capacidade preditiva que o modelo SAR-ARMA(1,1).
Blázquez et al (2013)	SARAR (SAC)	46 províncias espanholas	O preço da energia elétrica tem um impacto modesto na consumo residencial de eletricidade e a renda dos consumidores tem um impacto moderado. Verificou uma forte presença de efeitos espaciais.
Cho et al (2015)	SAC-AR	16 regiões sul-coreanas	Foram encontrados efeitos espaciais positivos na demanda de eletricidade residencial e manufaturada e efeitos espaciais negativos na agricultura. No setor varejista não foram encontrados efeitos espaciais.
Cabral (2017)	SDM dinâmico; SAC-AR	5 regiões brasileiras	SDM dinâmico mostrou ser o modelo com melhor capacidade preditiva.
Cabral et al (2017)	ARIMASp; ARIMA	5 regiões brasileiras	O modelo ARIMASp mostrou ser o modelo com melhor capacidade preditiva.

Fonte: Elaboração própria.

Com base na revisão da literatura nacional e internacional feita acima, é possível concluir que: *i*) a maioria dos trabalhos ignora as interações espaciais no cálculo das elasticidades da demanda. Um possível motivo para isso é o fato da econometria espacial conquistar o *mainstream* da economia apenas a partir do século XXI; *ii*) existe uma predominância em estudos na literatura nacional com dados em séries de tempo, utilizando a metodologia VAR/VCE. Só dois trabalhos no caso brasileiro estimaram elasticidades da demanda por energia elétrica utilizando painel de dados (Gomes, 2010; Cabral, 2017). Gomes (2010) não levou em conta a dependência espacial na estimação em painel, logo, não capturou os efeitos indiretos no cálculo das elasticidades tornando-as enviesadas e inconsistentes. Cabral (2017) usou um painel espacial dinâmico em que a dimensão temporal (132 meses) supera muito a dimensão regional (5 macrorregiões), o que não respeita a exigência do método de Elhorst, o qual necessita uma dimensão regional maior que a temporal (Elhorst, 2010).

Este artigo procura preencher essas lacunas. É utilizado um painel espacial em que a dimensão regional (N=27) é superior à dimensão temporal (T=9) para estimar explicitamente os efeitos espaciais diretos e indiretos que influenciam as elasticidades de demanda de energia elétrica.

### 3 METODOLOGIA E BASE DE DADOS

Esta seção está dividida em duas subseções. A primeira descreve a metodologia e o procedimento de especificação para a obtenção do melhor modelo. A segunda apresenta a base de dados e o tratamento da mesma.

#### 3.1 Metodologia

##### 3.1.1 Especificação da Demanda Residencial por Energia Elétrica (DREE)

Nesta subseção, o modelo teórico da demanda de energia elétrica proposto por Andrade e Lobão (1997) é apresentado. As hipóteses básicas propostas pelos autores adaptadas para o intuito deste artigo são:

- i. A energia elétrica demandada pelos consumidores residenciais ligados à rede de distribuição é plenamente atendida. Ou seja, de uma forma geral ou para grande parte dos consumidores, é admitido que não existe o problema de demanda reprimida e que a oferta do serviço é infinitamente elástica. Com esta hipótese, pode-se utilizar a quantidade consumida como uma boa aproximação para a quantidade demandada;
- ii. A demanda residencial das UFs é influenciada por duas variáveis fundamentais: o preço cobrado pelo serviço e a renda familiar das unidades da federação. Teoricamente, espera-se que o consumo reaja negativamente às variações do preço e positivamente às variações da renda.

Com base nestas hipóteses, a representação da DREE pode assumir a seguinte forma genérica:

$$Y_t = f(P_t, R_t) \quad (1)$$

Sendo  $Y_t$  a quantidade demandada de energia elétrica,  $P_t$  o preço de energia elétrica,  $R_t$  a renda dos consumidores e  $t$  um índice de tempo. Para a função  $f(\cdot)$ , Andrade e Lobão assumem a seguinte especificação:

$$Y_t = \beta_0 P_t^{\beta_1} R_t^{\beta_2} e_t \quad (2)$$

Onde  $\beta_0$ ,  $\beta_1$  e  $\beta_2$  são parâmetros a serem estimados e  $e_t$  é o termo de erro aleatório. A equação (2) constitui um modelo de elasticidade constante no tempo, sendo  $\beta_1$  a elasticidade-preço e  $\beta_2$  a elasticidade-renda. Para obter as elasticidades, basta estimar (2) na forma logarítmica:

$$\log(Y_t) = \log(\beta_0) + \beta_1 \log(P_t) + \beta_2 \log(R_t) + \log(e_t) \quad (3)$$

A equação (3) assim se constitui num modelo de regressão linear múltipla que pode ser estimado por diferentes métodos. Por sua vez, os parâmetros estimados  $\beta_1$  e  $\beta_2$  seriam aproximações das elasticidades-preço e -renda da DREE. Na próxima subseção, será incorporada a dimensão espacial (UF) no modelo.

### 3.1.2 Modelos de dados em painel

Esta subseção apresenta os principais métodos de estimação de modelos de dados em painel e painel espacial com base em Wooldridge (2001) e em Almeida (2012). Os dados em painel possuem tanto a dimensão de corte transversal (27 UFs) quanto a temporal (2003-2011). Isto permite que modelos utilizando este tipo de dados consigam captar as variações das UFs e variações no tempo. Outra vantagem que os modelos de dados em painel possuem é o controle da regressão por características não observáveis, isto é, a heterogeneidade dos indivíduos é controlada (Gomes 2010).

Seguindo a metodologia de Wooldridge (2001), o modelo de dados em painel para a DREE seria:

$$Y_{it} = X'_{it}\beta + \alpha'_i + e_{it} \quad (4)$$

Em que  $Y_{it}$  representa a DREE para a UF  $i$  no tempo  $t$ . O termo  $X'_{it}$  possui três regressores: o vetor de 1's para a constante, o vetor da renda dos consumidores residenciais ( $R_{it}$ ) e o vetor dos preços médios de energia elétrica ( $P_{it}$ ). O efeito específico da UF é representado por  $\alpha'_i$ ,

chamado de componente não observado. O termo de erro  $e_{it}$  é identicamente e independentemente distribuído com média zero e variância constante.

O primeiro passo é examinar se os efeitos não observados das UFs são relevantes ao modelo. Para isto, foi aplicado o teste de Breusch-Pagan. Este é um teste de multiplicador de Lagrange cuja hipótese nula é de que a variância dos resíduos devidos aos efeitos individuais é zero, ou seja,  $\sigma_{\alpha}^2 = 0$  (Almeida, 2012). Se for rejeitada essa hipótese nula, é aconselhado estimar o modelo por MQO para dados agrupados (*Pooled OLS*); caso contrário, deve-se estimar o modelo de efeitos fixos e o modelo de efeitos aleatórios.

Caso seja necessário estimar os modelos de efeitos fixos e aleatórios, após a estimação dos mesmos aplica-se o teste de Hausman para descobrir qual o modelo mais apropriado de efeitos não observados. A diferença entre o modelo de efeitos fixos e o de efeitos aleatórios é que no primeiro a correlação entre os regressores e os efeitos específicos (heterogeneidades individuais) é diferente de zero, enquanto que no segundo é igual a zero. As hipóteses do teste de Hausman captam esta diferença:  $H_0: Cor(X_{it}, \alpha_i) = 0$  significa que as estimativas de ambos modelos são iguais, porém o modelo de efeitos aleatórios produz estimativas mais eficientes dado que utiliza o método de mínimos quadrados generalizados;  $H_1: Cor(X_{it}, \alpha_i) \neq 0$  significa que o modelo de efeitos aleatórios é inconsistente e o de efeitos fixos é consistente.

Determinando-se o modelo que melhor se adequa aos dados, deve ser feita então uma inspeção em seus resíduos para averiguar a presença de dependência espacial. Para isso, aplica-se o teste I de Moran<sup>1</sup> nos resíduos das unidades do corte transversal no intuito de verificar se os mesmos são autocorrelacionados espacialmente. Este teste necessita da especificação de uma matriz de ponderação espacial ( $W$ ), que funciona como um operador de defasagem espacial, ou seja, fornece o grau de conexão entre as regiões. Para a especificação de  $W$  utiliza-se o procedimento de Baumont (2004)<sup>2</sup>, procedimento que captura o máximo de dependência espacial. Se caso não for rejeitada a hipótese de autocorrelação espacial, é necessário introduzir alguma defasagem espacial no modelo. Na próxima subseção apresenta-se os modelos de dados em painel considerando as possíveis dependências espaciais.

### 3.1.3 Modelos de dados em painel com dependência espacial

O modelo de dados agrupados com dependência espacial geral é representado por:

$$Y_{it} = \rho WY_{it} + X_{it}\beta + WX_{it}\tau + \xi_{it} \quad (5)$$

$$\xi_{it} = \lambda W\xi_{it} + e_{it} \quad (6)$$

em que a matriz  $W$  é uma matriz quadrada de dimensão  $27 \times 27$ , sendo  $w_{ij}$  o grau de conexão entre as UFs  $i$  e  $j$ ,  $WY_{it}$  é a defasagem espacial da DREE para a UF  $i$  no tempo  $t$ . As variáveis explicativas exógenas (constante, renda dos consumidores residenciais e preço médio de energia elétrica) defasadas espacialmente são representadas por  $WX_{it}$ , os erros defasados espacialmente são simbolizados por  $W\xi_{it}$ . Os parâmetros  $\rho$  e  $\lambda$  são escalares espaciais, ao passo que  $\tau$  é um vetor de coeficientes espaciais. Os modelos de efeitos fixos com dependência espacial são representados pelas equações (7) e (8).

$$Y_{it} = \alpha_i + \rho WY_{it} + X_{it}\beta + WX_{it}\tau + \xi_{it} \quad (7)$$

<sup>1</sup> Para mais detalhes sobre o teste I de Moran ver capítulo 4 de Almeida (2012).

<sup>2</sup> O procedimento de Baumont (2004) possui três passos: *i*) estima-se o modelo clássico de regressão linear; *ii*) testam-se os resíduos deste modelo para a autocorrelação espacial usando o I de Moran para um conjunto de matrizes  $W$ ; *iii*) seleciona-se a matriz de pesos espaciais que tenha gerado o mais alto valor do teste I de Moran, e que seja significativo estatisticamente.



$$\xi_{it} = \lambda W \xi_{it} + e_{it} \quad (8)$$

em que  $\alpha_i$  é o efeito específico da  $i$ -ésima UF. O modelo de efeitos aleatórios com dependência espacial é representado por:

$$Y_{it} = \rho W Y_{it} + X_{it} \beta + W X_{it} \tau + \xi_{it} \quad (9)$$

$$\xi_{it} = \alpha_i + \lambda W \xi_{it} + e_{it} \quad (10)$$

É possível extrair vários modelos de painel de dados com dependência espacial. Para isto, basta impor diferentes restrições nos parâmetros espaciais dos modelos acima. Neste artigo serão considerados sete modelos de painel de dados espaciais: *i*) modelo geral, que considera a dependência espacial da variável dependente ( $\rho W$ ), das variáveis explicativas ( $W\tau$ ) e dos termos de erro ( $\lambda W$ ); *ii*) modelo SAR (*Spatial Autoregressive*), que considera apenas a dependência espacial da variável dependente; *iii*) modelo SEM (*Spatial error model*), que considera apenas a dependência espacial dos termos de erro; *iv*) modelo SAC, que considera a dependência espacial da variável dependente e dos termos de erro; *v*) modelo SDM (*Spatial Durbin model*), que considera a dependência espacial da variável dependente e das variáveis explicativas; *vi*) SDEM (*Spatial Durbin error model*), que considera a dependência espacial das variáveis explicativas e dos termos de erro; e *vii*) SLX (*Spatial cross-regressive*), que considera apenas a dependência espacial das variáveis explicativas.

De posse dos modelos de efeitos não observados com dependência espacial, a escolha do melhor modelo para explicar a DREE se dá pelo critério AIC (*Akaike information criteria*), o mais comum na literatura. Adicionalmente, este artigo calcula os impactos espaciais diretos e indiretos das variáveis explicativas seguindo a abordagem de LeSage e Pace (2009).

### 3.2 Base de dados

As variáveis utilizadas na estimação da DREE foram: consumo residencial de energia elétrica (em MWh), preço de energia elétrica (em R\$/MWh) e PIB (em R\$ de 2010). As observações são em nível de UF (N=27) e compreendem o período de 2003 a 2011 (T=9).

Os dados anuais de consumo de energia elétrica residencial foram obtidos na Eletrobrás<sup>3</sup> e os de PIB per capita (em R\$) foram retirados do IBGE. Não foi possível obter dados anuais para o preço residencial de energia elétrica em nível de UF. Contudo, foram obtidos na ANEEL<sup>4</sup> os valores anuais dos preços residenciais de energia elétrica e o número de unidades consumidoras para cada distribuidora. Como cada distribuidora pertence a apenas um estado, atendendo a um certo número de unidades consumidoras, foi possível construir uma estimativa de preço médio para cada UF. Os seguintes passos foram adotados para se produzir essa estimativa: *i*) Separação das distribuidoras de energia elétrica por UF; *ii*) se a UF possuir apenas uma distribuidora de energia elétrica, o preço da UF é igual ao preço desta distribuidora; *iii*) se a UF possuir mais de uma distribuidora, é calculada uma média ponderada dos preços de energia elétrica das distribuidoras pelo seu número de unidades consumidoras, resultando no preço médio residencial de energia elétrica da UF.<sup>5</sup>

Para trabalhar com valores reais de preço de energia elétrica e PIB foi utilizado o IPCA do IBGE para deflacionar as séries, utilizando como ano base o ano de 2010.

<sup>3</sup> www.eletrobras.com

<sup>4</sup> www.aneel.gov.br

<sup>5</sup> Também foi calculada a média ponderada das tarifas de energia elétrica pela quantidade consumida de energia de cada distribuidora. As estimações com as diferentes médias ponderadas obtiveram coeficientes semelhantes.

## 4 RESULTADOS

Para a estimação dos modelos, as variáveis explicativas renda dos consumidores residenciais e preço residencial da energia elétrica foram representadas pelas séries do PIB per capita e preço médio residencial respectivamente. A variável dependente DREE foi representada pelo consumo de energia elétrica residencial, pois é assumido que toda quantidade de energia elétrica demandada pelos consumidores residenciais é efetivamente fornecida, ou seja, pode-se utilizar a quantidade consumida como uma boa aproximação para a quantidade demandada.

Primeiramente, foram ajustados três modelos sem dependência espacial utilizando os seguintes métodos de estimação: *Pooled OLS*, o de efeitos fixos e o de efeitos aleatórios. Todos os testes e estimações deste artigo foram construídos utilizando o software R. As estimativas para estes modelos foram obtidas através do método de máxima verossimilhança<sup>6</sup> e estão dispostas na Tabela 3.

Tabela 3 – Estimativas dos modelos de painel sem dependência espacial

Parâmetros	<i>Pooled OLS</i>	Efeitos Fixos	Efeitos Aleatórios
Constante	0,133 (1,111)	-	2,08* (0,170)
Preço	0,754 (0,134)	-0,223* (0,047)	-0,223* (0,047)
Renda	1,056* (0,445)	1,509* (0,050)	1,503* (0,050)
Qualidade de ajustamento			
$R^2$	0,221	0,831	0,815
$\bar{R}^2$	0,215	0,809	0,814

Fonte: Elaboração própria.

Nota: Valores com \* significam ser significativos a 5% e valores entre parênteses representam o erro padrão da estimativa.

Pela Tabela 3, nota-se um bom ajustamento por parte dos modelos de Efeito Fixos e o de Aleatórios, sendo um indício de que os efeitos não observados são relevantes. Para verificar se estes efeitos são estatisticamente significativos, foi empregado o teste de Breusch-Pagan no modelo *Pooled OLS*, encontrando-se um valor da estatística de teste de 17.649 com um p-valor de  $2,2 * 10^{-16}$ . Com isto, pode-se concluir a um nível de 5% de significância que há evidências para rejeitar a hipótese de que a variância dos resíduos devido aos efeitos individuais (UF) é zero, ou seja, há fortes indícios de haver efeitos não observados no modelo.

Verificada a presença dos efeitos não observados no modelo, o teste de Hausman indicou um  $\chi$ -valor de 2,4416, com um p-valor de 0,295. Logo, conclui-se que não há evidências para rejeitar a hipótese de que a correlação entre as variáveis explicativas e os efeitos específicos seja igual a zero, ou seja, é preferível o modelo de efeitos aleatórios.

De posse do modelo de efeitos aleatórios, aplicou-se o teste de I de Moran nos 9 cortes transversais de tempo (2003 a 2011) para checar se existe autocorrelação espacial em seus resíduos. De acordo com o procedimento de Baumont (2004), a matriz de ponderação espacial

<sup>6</sup> Maiores detalhes sobre o método de máxima verossimilhança para estes modelos, ver Millo e Piras (2012).

de 3 vizinhos mais próximos foi a que gerou o mais alto valor de I de Moran e foi estatisticamente significativo<sup>7</sup>. O sinal das estatísticas de I de Moran indica uma similaridade entre os valores das DREE e da localização espacial da mesma, ou seja, UFs com altos (baixos) valores de DREE tendem a estar próximas umas das outras. A magnitude média das estatísticas de I de Moran utilizando a matriz de 3 vizinhos mais próximos foi de 0,276, evidenciando que existe uma forte autocorrelação espacial dos resíduos do modelo de efeitos aleatórios sem considerar nenhum tipo de dependência espacial.

Foram estimados, então, sete modelos de efeitos aleatórios considerando diferentes tipos de dependência espacial. O método de estimação utilizado foi o de máxima verossimilhança, que é o método alternativo ao MQO mais eficiente. Segundo Millo e Piras (2012), o MQO é ineficiente para modelos com componente de erros autocorrelacionados espacialmente.

Na Tabela 4, WDREE representa a DREE defasada espacialmente, WResíduos representa o termo de erro defasado espacial, WPreço representa o preço da energia elétrica defasado espacialmente, WRenda representa a renda dos consumidores defasada espacialmente e AIC representa o critério de informação de Akaike.

Os resultados dos modelos de painel espacial são satisfatórios dado que a maior parte dos coeficientes são significativos, relativamente semelhantes e possuem os sinais esperados. Em todos os modelos, os coeficientes da variável renda, da variável dependente espacialmente defasada e do termo de erro espacialmente defasado são significativos. Apenas no modelo SAC o coeficiente da variável preço não foi significativo. Já o coeficiente da variável preço espacialmente defasada foi significativo nos modelos Geral e SDM, enquanto que o da variável renda espacialmente defasada foi significativo apenas no modelo SLX.

De acordo com a Tabela 4, o melhor modelo segundo o critério de informação de Akaike é o de efeitos aleatórios SAC, modelo que considera a dependência espacial na variável dependente e no termo de erro aleatório. Portanto, todas as análises futuras se concentrarão nos resultados obtidos do modelo SAC.

Tabela 4 – Estimativas dos coeficientes para os modelos de efeitos aleatórios com dependência espacial

Variáveis	Geral	SAR	SEM	SAC	SDM	SDM	SLX
Constante	0,261*	0,733**	3,03**	<b>0,302**</b>	0,06**	3,243**	2,284**
	-0,109	-0,125	-0,171	<b>-0,101</b>	-0,146	-0,357	-0,202
Preço	-0,143**	-0,097**	-0,169**	<b>-0,031</b>	-0,166**	-0,186**	-0,236**
	(0,04)	(0,032)	(0,042)	<b>(0,021)</b>	(0,041)	(0,048)	(0,060)
Renda	0,369**	0,576**	0,538**	<b>0,342**</b>	0,59**	0,552**	1,512**
	(0,021)	(0,034)	(0,093)	<b>(0,020)</b>	(0,034)	(0,094)	(0,050)
WDREE	0,786**	0,635**	-	<b>0,796**</b>	0,64**	-	-
	(0,044)	(0,040)	-	<b>(0,047)</b>	(0,042)	-	-
WResíduos	-0,529**	-	0,866**	<b>-0,569**</b>	-	0,862**	-
	(0,144)	-	(0,028)	<b>(0,167)</b>	-	(0,031)	-
WPreço	0,129**	-	-	-	0,107*	-0,073	-0,077
	(0,046)	-	-	-	(0,052)	(0,108)	(0,077)
WRenda	0,001	-	-	-	0,002	-0,002	0,007**
	(0,0008)	-	-	-	(0,001)	(0,008)	(0,002)
AIC	-939,59	-933,56	-879,54	<b>-941,47</b>	-940,59	-940,59	-

<sup>7</sup> Ver anexo A1.

Fonte: Elaboração própria.

Nota: Valores com \* significativos a 5% e com \*\* significativos a 1%. Valores entre parênteses representam o erro padrão da estimativa.

Nota-se que a DREE responde ao nível de renda dos consumidores residenciais com uma elasticidade de 0,342. Este valor é similar aos encontrados por Andrade e Lobão (1997), Schmidt e Lima (2004) e Gomes (2010), respectivamente 0,213, 0,539 e 0,102 e indica que uma variação na renda dos consumidores residenciais tem um efeito positivo na DREE. O valor da elasticidade-preço foi relativamente baixo ( $-0,031$ ), não sendo significativo. Os estudos realizados no Brasil mostram similaridade nas elasticidades-preço,  $-0,051$  por Andrade e Lobão (1997),  $-0,085$  por Schmidt e Lima (2004) e  $-0,111$  por Gomes (2010), sendo todas significativas. Deve ser observado que as estimativas dos estudos anteriores sobre as elasticidades da demanda não consideram os efeitos espaciais indiretos. Comparando os resultados do modelo SAC com os do modelo de efeitos aleatórios sem dependência espacial, pode-se concluir que as estimativas das elasticidades são estatisticamente diferentes para o preço (SAC:  $-0,031$ , Efeitos aleatórios:  $-0,223$ ) e para a renda (SAC: 0,342, Efeitos aleatórios: 1,503).

A estimativa do coeficiente autorregressivo espacial da DREE foi relativamente alta (0,796), sendo semelhante à estimativa encontrada por Blázquez et al (2013), de 0,677. Este coeficiente estimado implica que, mantido tudo constante, se as DREE das UFs vizinhas aumentarem em 1%, a DREE da UF considerada aumenta em quase 0,8%. A estimativa do erro autorregressivo espacial é de  $-0,569$ , sugerindo que um choque aleatório em alguma variável omitida espacialmente significativa em uma determinada UF desencadeia uma mudança negativa na DREE desta UF e de suas vizinhas.

Os impactos espaciais direto, indireto e total do preço médio de energia elétrica e da renda dos consumidores residenciais são calculadas de acordo com LeSage e Pace (2009). A Tabela 5 apresenta os resultados dos impactos para o Modelo SAC.

Tabela 5 – Decomposição do efeito espacial total do modelo de efeitos aleatórios SAC.

Variáveis	SAC	Efeitos-SAC		
		Direto	Indireto	Total
Constante	0,302**	- <sup>c</sup>	-	-
	-0,101	-	-	-
Preço	-0,031	-0,033	-0,119	-0,153
	(0,021)	(0,023)	(0,113)	(0,134)
Renda	0,342**	0,367**	1,315**	1,685**
	(0,020)	(0,024)	(0,545)	(0,557)
WDREE	0,796**	-	-	-
	(0,047)	-	-	-
WResíduos	-0,569**	-	-	-
	(0,167)	-	-	-

Fonte: Elaboração própria.

Nota: Valores com \* significativos a 5% e com \*\* significativos a 1%. Valores entre parênteses representam o erro padrão da estimativa.

A análise dos impactos diretos revela que: *i*) um aumento de 1% na renda dos consumidores de uma UF aumenta em quase 0,37% a DREE da mesma; *ii*) um aumento de 1% no preço médio da energia elétrica de uma UF diminui 0,03% na DREE da mesma. Os impactos indiretos apresentam que: *i*) um aumento de 1% na renda dos consumidores das UFs

vizinhas aumenta em 1,31% da DREE da UF considerada; *ii*) um aumento de 1% no preço médio da energia elétrica das UFs vizinhas diminui em quase 0,12% a DREE da UF considerada. A um nível de 5% de significância, pode-se concluir que os impactos direto, indireto e total do preço da energia elétrica na DREE não são significativos, resultado igual ao encontrado por Pourazarm e Cooray (2013), que também concluíram que a variável preço de energia elétrica não é significativa para um modelo de demanda de energia elétrica. Nota-se que os impactos indiretos são superiores aos impactos diretos, representando cerca de 78% do impacto total para ambas as variáveis. Isto indica que mudanças nas variáveis renda e preço de energia elétrica de UF vizinhas podem acarretar em maiores mudanças na DREE de uma UF do que mudanças nas variáveis na mesma UF.

Os resultados encontrados neste artigo mostram que negligenciar a presença de efeitos espaciais na estimação de modelos para a DREE pode acarretar estimativas enviesadas e inconsistentes. Nota-se que o efeito espacial na demanda residencial de energia elétrica, como discutido na introdução, pode existir devido ao fenômeno do consumidor residencial de eletricidade imitar o comportamento dos consumidores vizinhos, ou pela existência de parcerias de mídia entre UFs que contribuem para o contágio espacial dos efeitos psicológicos e sociológicos de uma crise econômica, ou pelo fato de trabalhadores viverem em uma UF porém trabalhar em outra (Blázquez et al, 2013).

## 5 CONSIDERAÇÕES FINAIS

Este artigo apresentou uma análise econométrica da demanda residencial de energia elétrica no Brasil que considera os efeitos espaciais. Para isto, uma base de dados em painel para as 27 unidades da federação no período de 2003 a 2011 é utilizada para a estimação das equações de demanda residencial com foco sobre as elasticidades-preço e -renda. Inicialmente foram comparado três métodos de estimação sem efeitos espaciais: *Pooled OLS*, Efeitos Fixos e Efeitos Aleatórios. Visto que o modelo de efeitos aleatórios se adequou melhor aos dados, foi verificado que os resíduos deste modelo eram espacialmente dependentes, logo, foram propostos sete modelos de efeitos aleatórios incorporando diferentes tipos de dependência espacial com o intuito de eliminar a autocorrelação espacial. O melhor modelo econométrico espacial encontrado segundo o critério AIC foi o SAC.

Como principal contribuição, este artigo incorporou a questão da dependência espacial das unidades da federação na demanda residencial de energia elétrica brasileira. Visto que foi constatado uma forte autocorrelação espacial positiva dos resíduos, negligenciar a presença de efeitos espaciais pode resultar em estimativas enviesadas e inconsistentes. As estimativas geradas pelo modelo SAC são não enviesadas e consistentes. A estimativa da elasticidade-preço foi muito baixa (-0,031), sendo não significativa; já a estimativa da elasticidade-renda foi de 0,342, sendo significativa ao modelo. O alto valor encontrado da estimativa do coeficiente autorregressivo espacial indica que existe um grande efeito espacial na variação da demanda residencial de energia elétrica entre as unidades da federação vizinhas.

As análises empíricas dos efeitos espaciais mostram que os impactos indiretos de uma variação no preço e renda possuem maior magnitude do que os impactos diretos, mostrando a forte interação das demandas residenciais por energia elétrica de UFs vizinhas.

Até o momento, poucos trabalhos consideraram os efeitos espaciais na demanda de energia elétrica para sua previsão e estimação das elasticidades -preço e -renda. Este artigo trata pioneiramente da dependência espacial da demanda residencial de energia elétrica brasileira, chegando a conclusão de que o Brasil possui um padrão de similaridade na demanda residencial de energia elétrica entre as 27 unidades da federação.

Como possíveis trabalhos futuros pode-se apontar: *i*) a comparação do desempenho preditivo de modelos econométricos que não incorporam versus que incorporam efeitos espaciais na DREE; *ii*) a construção de um modelo econométrico espacial da DREE do Brasil sendo as distribuidoras de energia elétrica as observações do corte transversal, possibilitando capturar a dependência entre as mesmas.

## REFERÊNCIAS

ACTON, Jan Paul; MITCHELL, Bridger M.; SOHLBERG, Ragnhild. Estimating residential electricity demand under declining-block tariffs: an econometric study using micro-data. **Applied Economics**, v. 12, n. 2, p. 145-161, 1980.

ALMEIDA, E. **Econometria Espacial Aplicada**. Campinas: Alínea Editora, 2012.

AMARAL, R. M.; MONTEIRO, MVSP. A demanda por energia elétrica residencial no Brasil: Estimativa das elasticidades renda e preço após o apagão. **XXX Encontro Nacional de Engenharia de Produção. Maturidade e desafios da Engenharia de Produção: competitividade das empresas, condições de trabalho, meio ambiente**. Anais. São Carlos, São Paulo, 2010.

ANDRADE, T. A & LOBÃO, W. J. A. **Elasticidade renda e preço da demanda residencial de Energia Elétrica no Brasil**. Texto para discussão n° 489. Rio de Janeiro, IPEA, 1997.

BALESTRA, P.; NERLOVE, M. Pooling cross-section and time-series data in the estimation of a dynamic model: The demand for natural gas, **Econometrica**. v. 34, p. 585-612, 1966.

BALTAGI, B. H.; Griffin, J. M. Gasoline demand in the OECD: Na application of pooling and testing procedures. **European Economic Review**. v. 22, p. 117-137, 1983.

BAUMONT, C. **Spatial effects in housing price models: do house prices capitalize urban development policies in the agglomeration os Dijon (1999)?** Mimeo. Université de Bourgogne, 2004.

BLÁZQUEZ, L. M. G., FILIPPINI, M., HEIMSCH, F. Regional impact of changes in disposable income on Spanish electricity demand: A spatial econometric analysis. **Energy Economics**. v. 40, P. S58-S66, 2013.

CABRAL, J. A. **Demanda de eletricidade regional no Brasil: uma análise espaço-temporal**. Tese de Doutorado apresentada ao Programa de Pós-graduação em Planejamento Energético, COPPE, da Universidade Federal do Rio de Janeiro, 2017.

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.

CHERN, W.; BOUIS, H. E. Structural changes in residential electricity demand. **Energy Economics**. v. 10, n. 3. P. 213-222, 1988.

CHO, S. -H., TAEYOUNG, K., HYUN, J. K., KIHUN, P., ROLAND, K. R. Regionally-varying and regionally-uniform electricity pricing policies compared across four usage categories. **Energy Economics**. v. 49, P. 182-191, 2015.

CLIFF, A.; ORD, J. K. **Spatial processes, models and applications**. Londres: Pion, 1981.

ELHORST, J. P. Spatial panel data models. In: FISCHER, M. M.; GETIS, A. (ed). *Handbook of Applied Spatial Analysis: Software Tools, Methods and Applications*. Berlin: Springer, 2010.

GARCEZ, E.W. e GHIRARDI, A. G. **Elasticidades da demanda residencial de energia elétrica**. Manuscrito. 2003.

GOMES, L. S. F. **A demanda por energia elétrica residencial no Brasil: 1999-2006: uma estimativa das elasticidades-preço e renda por meio de painel**. 2010. Tese de Doutorado. Universidade de São Paulo.

IRFFI, G., CASTELAR, I., SIQUEIRA, M. L. e LINHARES, F. Previsão da demanda por energia elétrica na Região Nordeste, usando OLS dinâmico e mudança de regime. **Economia Aplicada**, 13(1). 2009. 69-98.

JAMIL, F.; AHMAD, E. Income and price elasticities of electricity demand: Aggregate and sector-wise analyses. **Energy Policy**, v. 39, P. 5519 – 5527, 2011.

JOHANSEN, S. Estimation and hypothesis testing of cointegrating vectors in Gaussian vector autoregressive models. **Econometrica**. v. 59, P. 1551 – 1580, 1991.

JOHANSEN, S. Statistical analysis of cointegration vectors. **Journal of Economic Dynamics and Control**. V. 12, P. 231-254, 1988.

JOHANSEN, S., JUSELIUS, K. Maximum likelihood estimation and inference on cointegration, with application to the demand for Money. **Oxford Bulletin of Economics and Statistics**. V. 52, P. 169-210, 1990.

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

LIM, K-M.; LIM, S-Y.; YOO, S-H. Short- and long-run elasticities of electricity demand in the Korean servisse sector. **Energy Policy**. V. 67, P. 517-521, 2014.

LIU, Gang. Estimating Energy Demand Elasticities for OECD Countries – A Dynamic Panel Data Approach. Statistics Norway, Research Department – **Discussion Papers**. n. 373, 2004.

MATTOS, L. B. Uma Estimativa da Demanda Industrial de Energia Elétrica no Brasil: 1974-2002. **Organizações Rurais e Agroindustriais**. Vol. 7, nº 2, 2005.

MATTOS, L. B. e LIMA, J. E. Demanda Residencial de energia elétrica em Minas Gerais. **Nova Economia**. Vol. 15, no. 3, 2005.

MATTOS, L.B., REIS, B. S., LIMA, J. E. e LÍRIO, V. S. Demanda industrial de energia elétrica em Minas Gerais, 1970-2002. **Revista de Economia e Agronegócio**, 3 (1). 2005. 97-120.

MATTOS, L.B., REIS, B. S., LIMA, J. E., LÍRIO, V. S. Demanda de energia elétrica pelo setor comercial em Minas Gerais, 1970-2002. **Revista GEPEC** 10, 1. 2006. 9-27.

MILLO, G., PIRAS, G. splm: Spatial Panel Data Models in R. **Journal of statistical software**. Issue 1. V. 47, Abril 2012.

MODIANO, E. M. **Elasticidades-renda e preços da demanda de energia elétrica no Brasil**. PUC-Rio/Departamento de Economia. Texto para Discussão 68. 1984.

OHTSUKA, Y.; KAKAMU, K. Space-Time Model Versus VAR Model: Forecasting Electricity Demand in Japan. **Journal of Forecasting**. V. 32, P. 75-85, 2013.

OHTSUKA, Y.; OGA, T.; KAKAMU, K. Forecasting electricity demand in Japan: A Bayesian spatial autoregressive ARMA approach. **Computational Statistics and Data Analysis**. V. 54, P. 2721-35, 2010.

OLIVEIRA, B. H. A. M., DAMÁZIO, J. M., LEONE, R. J. G., LERMONTOV, M., MACHADO, M. A. S. Um modelo de previsão do consumo residencial de energia elétrica no Brasil. **Cadernos do IME – Série Estatística**. ISSN 1413-9022, V. 28, P. 15 – 31, 2010.

POURAZARM, E., COORAY, A. Estimating and forecasting residential electricity demand in Iran. **Economic Modelling**. V.35, P. 546-558, 2013.

PIRES, J. C. L. O processo de reformas do setor elétrico brasileiro. **Revista do BNDES**, Rio de Janeiro, v.6, n. 12, p. 137-168, 1999.

SCHMIDT, C. A. J. & LIMA, M. A. M. A demanda por energia elétrica no Brasil. **Revista Brasileira de Economia**. v. 58, n. 1, 2004.

SILVA, S.M. **Análise econométrica da demanda de energia elétrica nos setores residencial-urbano e rural do Brasil, 1970/1999**. Dissertação de Mestrado. Viçosa: UFV. 2001.



SIQUEIRA, M. L., CORDEIRO JR. e CASTELLAR. A demanda por energia elétrica no Nordeste brasileiro após o racionamento de 2001-2002: previsões de longo prazo. **Pesquisa e Planejamento Econômico**, 36(1). 2006. 131-178.

VIANA, G. I. M. N.; SILVA, Alexandre Lima Marques. Um modelo para projeções para demanda por energia elétrica, 2009–2017 para o setor residencial no Brasil. **Rev. Bras. Energy**, v. 20, p. 107-126, 2014.

WOOLDRIDGE, J. M. **Econometrics Analysis of Croos Section and Panel Data**. The Massachusetts Institute of Technology Press, 2001.

ZHOU, S.; TENG, F. Estimation of urban residential electricity demand in China using household survey data. **Energy Policy**, v. 61, P. 394-402, 2013.

## ANEXO

### A.1 - Valores da estatística I de Moran com diferentes matrizes de ponderação espacial.

Matriz de Ponderação	2003	2004	2005	2006	2007	2008	2009	2010	2011
Rainha	0,07	0,135	0,184*	0,103	0,113	0,101	0,106	0,106	0,111
Rainha padronizada na linha	0,07	0,135	0,184*	0,103	0,113	0,101	0,106	0,106	0,111
Torre	0,07	0,135	0,184*	0,103	0,113	0,101	0,106	0,106	0,111
Torre padronizada globalmente	0,063	0,136*	1,166*	0,084	0,111	0,111	0,124	0,089	0,109
Distância inversa	0,022*	0,048**	0,062**	0,042**	0,042**	0,039**	0,039**	0,034**	0,036**
Distância inversa padronizada pelo número de vizinhos	0,014	0,039**	0,046**	0,027*	0,026*	0,023*	0,021*	0,019*	0,020*
3 vizinhos mais próximos	0,179*	0,275**	0,348**	0,292**	0,298**	0,285**	0,287**	0,255**	0,265**

Fonte: Elaboração própria.

\* significam ser significativos a 5% e com \*\* significam ser significativos a 1%.

Nota: A matriz de 3 vizinhos mais próximos também foi a matriz de ponderação espacial que maximizou o valor do I de Moran dentre as matrizes de  $k$  vizinhos mais próximos, considerando um valor de  $k$  de 1 a 20.