



DEMANDA DE ELETRICIDADE REGIONAL NO BRASIL: UMA ANÁLISE  
ESPAÇO-TEMPORAL

Joilson de Assis Cabral

Tese de Doutorado apresentada ao Programa de Pós-graduação em Planejamento Energético, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários à obtenção do título de Doutor em Planejamento Energético.

Orientadores: Luiz Fernando Loureiro Legey  
Eduardo Simões de Almeida

Rio de Janeiro  
Março de 2017

DEMANDA DE ELETRICIDADE REGIONAL NO BRASIL: UMA ANÁLISE  
ESPAÇO-TEMPORAL

Joilson de Assis Cabral

TESE SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO LUIZ COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA (COPPE) DA UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE DOUTOR EM CIÊNCIAS EM PLANEJAMENTO ENERGÉTICO.

Examinada por:

---

Prof. Luiz Fernando Loureiro Legey, Ph.D.

---

Prof. Eduardo Simões de Almeida, D.Sc.

---

Prof. Lúcio Guido Tapia Carpio, D.Sc.

---

Prof. Amaro Olimpio Pereira Júnior, D.Sc.

---

Prof. Virgílio José Martins Ferreira Filho, D.Sc.

---

Prof. Reinaldo Castro Souza, Ph.D.

RIO DE JANEIRO, RJ - BRASIL

MARÇO DE 2017

Cabral, Joilson de Assis

Demanda de eletricidade regional no Brasil: uma análise espaço-temporal/ Joilson de Assis Cabral. – Rio de Janeiro: UFRJ/COPPE, 2017.

XIII, 79 p.: il.; 29,7 cm.

Orientadores: Luiz Fernando Loureiro Legey

Eduardo Simões de Almeida

Tese (doutorado) – UFRJ/ COPPE/ Programa de Planejamento Energético, 2017.

Referências Bibliográficas: p. 69-79.

1. Previsão de demanda regional de energia elétrica. 2. Dependência espacial. 3. Modelos espaço-temporais. I. Legey, Luiz Fernando Loureiro, *et al.* II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Planejamento Energético. III. Título.

À minha linda e amada família e aos que acreditaram.

## AGRADECIMENTOS

Em primeiro lugar agradeço à Deus e a Nossa Senhora Aparecida por ter me dado forças e me conceder a graça de concluir mais esta etapa da minha vida.

Ao meu querido orientador, Prof. Dr. Luiz Fernando Loureiro Legey, que mesmo sabendo que seria aposentado acreditou no meu potencial desde o nosso primeiro encontro. Agradeço ainda, pela confiança, paciência e todas sugestões feitas ao longo desta tese que muito contribuíram para a realização deste trabalho e do artigo. A sua humildade acadêmica e seu jeito de orientação que muito contribuiu para a minha formação acadêmica. Muito obrigado!

Ao meu coorientador e amigo Eduardo Simões de Almeida pelas contribuições, principalmente, no âmbito do projeto de qualificação que muito enriqueceram esta tese.

Aos Professores Amaro e Guido que muito contribuíram para minha formação acadêmica, principalmente, na área que ingressei no PPE, modelos energéticos. Agradeço ainda, pela presença na banca de defesa desta tese. Um agradecimento à todos os professores do PPE que de certa forma contribuíram para a minha formação acadêmica.

Aos demais membros da banca pela presteza, disponibilidade e pelas contribuições que muito enriquecerão minha tese.

A Sandrinha e ao Paulo, secretários do PPE, pela ajuda, disponibilidade e paciência de sempre.

Aos meus colegas de turma pelos momentos de estudo e descontração. Um obrigado especial para Gilberto Martins, Rita Cavaliere, Paulo Felix, Silvia Azevedo, Graziela, Cesar e Maria Beatriz. Muito obrigado, Galera!

Aos colegas de trabalho do DeCE/ICSA/UFRRJ. Em especial, Melk, Alexandre e Maxwell pela amizade, carinho e disponibilidade.

À toda minha família, tios, tias, primos, primas, afilhados pela torcida e por entenderem a minha ausência em alguns momentos.

Agradeço a minha pequena filha, Mariana, que no futuro entenderá o motivo de eu não poder brincar e estar sem paciência em alguns momentos.

Agradeço a minha mãe Ana por ter conseguido mesmo sozinha poder me mostrar à importância da educação para mudar minha condição de vida. Obrigado Ana pelo amor, dedicação e orações. Amooooo você!

Agradeço de forma especial a minha esposa, amiga, cúmplice, colega de trabalho, coautora, Maria Viviana de Freitas Cabral, pelas madrugadas e fins de semana

que passamos juntos dividindo o tempo em cuidar de nossa filha e discutir nossas teses. Obrigado por todo apoio e incentivo que foram fundamentais para o término deste trabalho. Como disse nos agradecimentos da dissertação, você foi um anjo que apareceu na minha vida. TE AMO!

Por fim, agradeço à todos que de forma direta ou indiretamente contribuíram para que eu chegasse até aqui.

Resumo da Tese apresentada à COPPE/UFRJ como parte dos requisitos necessários para a obtenção do grau de Doutor em Ciências (D.Sc.)

DEMANDA DE ELETRICIDADE REGIONAL NO BRASIL: UMA ANÁLISE  
ESPAÇO-TEMPORAL

Joilson de Assis Cabral

Março/2017

Orientadores: Luiz Fernando Loureiro Legey

Eduardo Simões de Almeida

Programa: Planejamento Energético

O Setor Elétrico Brasileiro passou por duas grandes reformas que culminaram no atual Modelo Institucional tendo como metas a universalização da oferta de energia, a segurança do sistema e a modicidade das tarifas. Neste Modelo, as Distribuidoras devem desenvolver estratégias de contratação de energia elétrica que garanta o abastecimento de 100% de seus respectivos mercados, evitando pagamento de multas e aumento dos custos. Assim, previsões precisas de demanda de energia elétrica passaram a ter um importante papel. A literatura acerca de previsão de demanda evoluiu consideravelmente, em termos metodológicos, a partir de 1951. Entretanto, somente em anos recentes, a interação espacial entre os agentes tem sido contemplada em sua modelagem na literatura internacional. Diante disso, a presente tese propõe incorporar as interações espaciais, caso existam, nas previsões de demanda regional de energia elétrica no Brasil. Os resultados mostram a existência da dependência espacial nos dados para o consumo regional de eletricidade comprovando que a interação espacial deve ser especificada nos modelos de demanda de energia elétrica. Com a inclusão da dependência espacial, os modelos de previsão de demanda obtiveram melhor *performance* preditiva tanto no contexto univariado quanto no contexto multivariado. Portanto, a dependência espacial deve ser especificada nos modelos de demanda de eletricidade utilizados pelos diversos agentes do Setor Elétrico Brasileiro de modo a melhorar a acurácia de previsão.

Abstract of Thesis presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Doctor of Science (D.Sc.)

REGIONAL DEMAND OF ELETRICITY IN BRAZIL: A SPATIO-TEMPORAL  
ANALYSIS

Joilson de Assis Cabral

March/2017

Advisors: Luiz Fernando Loureiro Legey  
Eduardo Simões de Almeida

Department: Energy Planning

The Brazilian Electricity Sector underwent two major reforms that culminated in the present Institutional Model, with its goals of security of electricity supply, affordability of tariffs and universalization of access to the Brazilian population. In this Model, Utilities must have supply contracts to meet their markets total demand or will suffer penalties if they do not. Thus, accurate forecasts of the electricity demand have come to play an essential role. The international literature on electricity demand forecasting has evolved considerably, in methodological terms, since 1951. However, only recently the spatial interaction among agents has been contemplated in demand forecasting models. In view of this, the present thesis proposes to incorporate the spatial interactions, if any, in the electricity regional demand forecasting in Brazil. Results show the existence of spatial dependence in the data for the regional consumption of electricity, thus suggesting proving that the spatial interactions must be included in models of electric power demand. With the inclusion of spatial dependence, demand forecast models can obtain better predictive performance in both univariate and multivariate contexts. Therefore, spatial dependence must be included in the specification of the models of electricity demand used by the various agents in order to increase their forecast accuracy, which is crucial to decision-making in the Brazilian Electricity Sector.



## ÍNDICE

<b>1. INTRODUÇÃO .....</b>	<b>1</b>
<b>2. EVOLUÇÃO METODOLÓGICA NA PREVISÃO DE DEMANDA DE ENERGIA ELÉTRICA.....</b>	<b>6</b>
<b>3. ENSAIO 1 - ANÁLISE DA AUTOCORRELAÇÃO ESPACIAL NA DEMANDA DE ELETRICIDADE: EVIDÊNCIA PARA AS REGIÕES BRASILEIRAS.....</b>	<b>16</b>
<b>3.1 INTRODUÇÃO .....</b>	<b>17</b>
<b>3.2 ASPECTOS METODOLÓGICOS E BASE DE DADOS .....</b>	<b>19</b>
3.2.1 Identificação da Autocorrelação Espacial em Painel de Dados .....	19
3.2.2 Descrição da Base de Dados.....	22
<b>3.3 RESULTADOS .....</b>	<b>25</b>
<b>3.4 CONSIDERAÇÕES FINAIS E IMPLICAÇÕES POLÍTICAS .....</b>	<b>31</b>
<b>4. ENSAIO 2 – PREVISÃO DE DEMANDA DE ELETRICIDADE NO BRASIL: UMA COMPARAÇÃO ENTRE OS MODELOS ARIMA E ARIMASp .....</b>	<b>33</b>
<b>4.1 INTRODUÇÃO .....</b>	<b>34</b>
<b>4.2 ESTRATÉGIA EMPÍRICA .....</b>	<b>36</b>
4.2.1 Especificação dos Modelos Univariados para a Previsão de Demanda de Eletricidade no Brasil .....	36
4.2.2 Base de Dados .....	38
<b>4.4 UMA COMPARAÇÃO ENTRE OS MODELOS ARIMA E ARIMASp .....</b>	<b>39</b>
<b>4.5 CONCLUSÕES E IMPLICAÇÕES POLÍTICAS .....</b>	<b>42</b>
<b>5. ENSAIO 3 – PREVISÃO DE DEMANDA DE ELETRICIDADE NO BRASIL: UMA COMPARAÇÃO ENTRE OS MODELOS MULTIVARIADOS PAINEL DINÂMICO, SDM DINÂMICO E SAC-AR(1).....</b>	<b>44</b>
<b>5.1 INTRODUÇÃO .....</b>	<b>45</b>
<b>5.2 ESTRATÉGIA EMPÍRICA .....</b>	<b>47</b>
5.2.1 Modelo Teórico de Previsão de Demanda de Eletricidade no Âmbito das Distribuidoras Brasileiras .....	47
5.2.2 Especificação dos Modelos Multivariados para a Previsão de Demanda de Eletricidade no Brasil .....	51
5.2.3 Descrição da Base de Dados.....	56
<b>5.3 RESULTADOS .....</b>	<b>57</b>
<b>5.4 CONSIDERAÇÕES FINAIS.....</b>	<b>64</b>
<b>6. CONCLUSÃO, IMPLICAÇÕES POLÍTICAS E AGENDA DE PESQUISA FUTURA .....</b>	<b>66</b>
<b>REFERÊNCIAS .....</b>	<b>69</b>

## LISTA DE FIGURAS

<b>Figura 3.1:</b> Mapa esquemático do Sistema Interligado Nacional.....	25
<b>Figura 3.2:</b> Mapa percentílico do consumo regional de eletricidade para os períodos inicial (janeiro de 2003) e final (dezembro de 2013) da análise. ....	27
<b>Figura 4.1:</b> Resultados da Previsão de Demanda de Eletricidade do Sudeste Brasileiro. ....	42

## LISTA DE TABELAS E QUADROS

<b>Tabela 3.1:</b> Estatística descritiva das variáveis utilizadas no modelo por Região. ....	24
<b>Tabela 3.2:</b> Estatística <i>I</i> de Moran uni e bivariada para o consumo de eletricidade regional para um painel de dados. ....	29
<b>Tabela 3.3:</b> Autocorrelação espacial global univariada para as <i>cross sections</i> de consumo regional de energia elétrica. ....	30
<b>Tabela 4.1:</b> Resultados da estimação dos modelos ARIMA e ARIMASp <sup>(a)</sup> .....	39
<b>Tabela 5.1:</b> Resultados das estimações dos modelos multivariados para a demanda regional de eletricidade. ....	58
<b>Tabela 5.2:</b> Decomposição das elasticidades de demanda regional de eletricidade no Brasil estimadas por meio do modelo SDM dinâmico. ....	61
<b>Quadro 2.1:</b> Resumo da Evolução Metodológica dos Modelos de Previsão de Demanda de Energia Elétrica. ....	11
<b>Quadro 3.1:</b> Descrição das variáveis utilizadas. ....	23
<b>Quadro 5.1:</b> Descrição das variáveis utilizadas. ....	57

## LISTA DE SIGLAS

ACL - Ambiente de Contratação Livre  
ACR - Ambiente de Contratação Regulada  
ADF - Teste Dickey-Fuller Aumentando  
AEDE - Análise Exploratória de Dados Espaciais  
ANEEL - Agência Nacional de Energia Elétrica  
AR - Modelos Auto regressivos  
ARIMA - Modelo Auto Regressivo Integrado e de Média Móvel  
ARIMASp - Modelo Auto Regressivo Integrado e de Média Móvel Espacial  
ARMAX - Modelo Auto Regressivo de Média Móvel com Variáveis Exógenas  
BC - Banco Central do Brasil  
BDMEP - Banco de Dados Meteorológicos para Ensino e Pesquisa  
CAGED - Cadastro Geral de Empregados e Desempregados  
CCEE - Câmara de Comercialização de Energia Elétrica  
CPL - Consumidor Potencialmente Livre  
EPE - Empresa Brasileira de Pesquisa Energética  
FDB - *Fast Double Bootstrap*  
FE - Efeitos Fixos  
GLS - Método de Mínimos Quadrados Generalizados  
GMM - Método dos Momentos Generalizados  
IBCR - Índice de Atividade Econômica Regional  
INMET - Instituto Nacional de Meteorologia  
INPE - Instituto Nacional de Pesquisas Espaciais  
LM - *Lagrange Multiplier*  
LR - *Likelihood Ratio*  
MA - Modelos de Médias Móveis  
MAPE - *Mean Absolute Percentage Error*  
ML - Método de Máximo Verossimilhança  
MME - Ministério de Minas e Energia  
MT - Ministério do Trabalho  
ONS - Operador Nacional do Sistema Elétrico  
OLS - *Ordinary Least Squares*

PIB - Produto Interno Bruto

POLS - *Pooled Ordinary Least Squares*

PRSEB - Projeto de Reestruturação do Setor Elétrico Brasileiro

RAIS - Relação Anual de Informações Sociais

RE - Efeitos Aleatórios

RNA - Redes Neurais Artificiais

SAC-AR - Modelo de Defasagem Espacial e Erro Auto regressivo Espacial com Componente Auto regressivo

SAD - Sistema de Apoio à Decisão

SARAR - Modelos Auto Regressivo Espacial e Erro Auto regressivo

SAR-ARMA - Modelos Auto Regressivo Espacial e Erro Auto regressivo e de Média Móvel

SDM - Modelo Durbin Espacial

SE - Região Sudeste

SEB - Setor Elétrico Brasileiro

SGS - Sistema Gerador de Séries Temporais

SIN - Sistema Interligado Nacional

SVM - *Support Vector Machine*

TSLS - Método de Mínimos Quadrados em Dois Estágios

VAR - Modelo de Vetores Auto Regressivos

VEC - Modelo Vetorial de Correção de Erro

## 1. INTRODUÇÃO

O Brasil experimentou um período de prosperidade no setor elétrico durante as décadas de 1950 a 1970. Esse crescimento deveu-se, em parte, ao Plano de Metas do Presidente Juscelino Kubitschek que tinha como um dos principais objetivos o investimento estatal em infraestrutura, com destaque para os setores de transporte e de energia elétrica.

Em particular, o setor elétrico foi bastante privilegiado nesse período dado o objetivo de ampliar a capacidade de geração do País. Tal expansão foi possível graças à facilidade de obtenção de aportes financeiros internacionais e pela abundante disponibilidade dos recursos hidrelétricos, o que permitiu incrementos de escala no setor. Assim, a geração e a distribuição de energia elétrica desenvolveram-se rapidamente a custos relativamente baixos e com significativo progresso tecnológico (IRFFI *et al.* 2009).

A partir da segunda metade da década de 1980, a expansão do Setor Elétrico Brasileiro (SEB) passou por uma crise, sobretudo por falta de recursos para investimentos. As consequências dessa crise foram atenuadas por dois fatores: o longo período recessivo em que viveu o País (“Década Perdida”) — que conteve a evolução do consumo de eletricidade — e a existência de excedentes na oferta de energia elétrica (LOTERO, 1999).

Com a implantação do Plano Real na metade da década de 1990, a estabilidade econômica foi alcançada e a economia brasileira voltou a apresentar crescimento. Entretanto, essa melhora do cenário econômico do País revelou a fragilidade da infraestrutura existente, sobretudo no que diz respeito à oferta de energia elétrica decorrente da falta de investimentos no SEB na década anterior. Já em 1995, o setor elétrico estava diante de uma grave crise, com riscos crescentes de *déficit* de energia que poderiam comprometer o abastecimento do mercado e, conseqüentemente, inviabilizar o crescimento do País. Por outro lado, a carência de recursos financeiros impôs restrições à expansão da oferta. A solução encontrada foi buscar um aporte de recursos na iniciativa privada (LOTERO, 1999).

Desse modo, pressionado pela crise fiscal, pela necessidade de grande volume de investimentos para suportar o crescimento econômico, pela globalização econômica e pelas mudanças tecnológicas, o governo brasileiro iniciou o primeiro processo de reforma no setor elétrico nacional. Essa reforma seguia uma tendência mundial de privatização (Nova Zelândia, Inglaterra e Estados Unidos), principalmente das concessionárias que atuavam no setor (LEITE, 2006). Ou seja, os serviços públicos de distribuição de energia elétrica brasileira que eram

realizados por empresas estaduais passaram a ser exercidos por empresas ou grupos privados sob a supervisão de agências reguladoras federal ou estaduais (SANTOS, 2003; LOTERO, 1999).

Conforme aponta Lotero (1999), os principais objetivos e estratégias estabelecidos pelo governo para a reestruturação e privatização da indústria de energia elétrica foram: i) ampliação da eficiência do setor elétrico; ii) estabelecimento de um mercado competitivo para assegurar a modicidade tarifária; iii) a elevação da qualidade do serviço e a eficiência dos agentes públicos e privados; iv) consecução dos investimentos necessários para a expansão do sistema com o ingresso de capitais privados; v) redução do papel do Estado como investidor.

Em outras palavras, o principal objetivo da primeira reforma do SEB foi implementar os processos de reestruturação e privatização do setor aumentando a eficiência econômica por meio de decisões mais adequadas sobre os investimentos a serem efetuados; do melhor uso das plantas de geração, transmissão e distribuição; de melhorias administrativas; e ampliação das opções de abastecimento para os consumidores finais (HUNT e SHUTTLEWORTH, 1996).

Como na maioria das reformas setoriais, o modelo institucional passou por várias modificações com o intuito de adaptar-se às necessidades de atração de investimentos. Após alguns ajustes, foi realizada a segunda reforma do SEB em 2004. Essa segunda reforma deu origem ao atual Modelo Institucional do Setor Elétrico, publicado em dezembro de 2003 pelo Ministério de Minas e Energia (MME), aprovado em março de 2004 no Congresso Nacional através da Lei nº 10.848 (BRASIL, 2004) e, regulamentado em julho de 2004 pelo Decreto nº 5.163 (BRASIL, 2005).

As metas da reforma foram a universalização da oferta de energia, a segurança do sistema e a modicidade das tarifas (SOUZA e LEGEY, 2010). Para atingir esses objetivos, a segunda reforma utilizou os mecanismos de mercado e centralizado, no que foi chamado de abordagem regulatória “híbrida”. A partir dessas metas, é necessária a ação contínua e permanente de monitoramento para o encaminhamento oportuno de ações preventivas de forma a minimizar o custo para o consumidor (SILVA, 2007).

No quadro atual do Setor, as Distribuidoras têm papel decisivo em virtude de o novo modelo impor desafios importantes para elas, principalmente a necessidade de desenvolver uma estratégia de contratação que garanta o abastecimento de 100% de seus respectivos mercados. Essa estratégia deve considerar a grande incerteza na demanda, buscando evitar uma excessiva

sobre-contratação<sup>1</sup> assim como a subcontratação<sup>2</sup> (BRASIL, 2005). A lógica por trás desse procedimento é que as Distribuidoras são os agentes na melhor posição para fazer as previsões de demanda, uma vez que conhecem seu mercado melhor do que qualquer outro agente.

O mercado das Distribuidoras é formado por consumidores cativos, consumidores livres e consumidores potencialmente livres (CPLs)<sup>3</sup>. O serviço de distribuição de energia elétrica constitui-se um monopólio natural, comprando energia de geradoras e repassando-a para o mercado consumidor. Devido a essa estrutura de mercado, as Distribuidoras são reguladas — independentemente de terem sido privatizadas ou não — para evitar a prática de tarifas abusivas que afetariam os consumidores finais.

Assim, após a implantação do Modelo Institucional do Setor Elétrico em 2004, previsões precisas de demanda de energia elétrica passaram a ter um papel importante tanto no que se refere aos investimentos na área de sistemas de distribuição como no planejamento da oferta de energia elétrica e na definição de estratégias de gerenciamento em sistemas regionais e nacional. Essa importância deve-se ao fato de previsões imprecisas de demanda de energia elétrica inviabilizarem as metas propostas pelo novo Modelo Institucional além de gerar aumento de custos operacionais e conseqüente redução dos lucros das Distribuidoras.

Diante da necessidade de modelos de previsão de demanda de energia elétrica com maior grau de precisão possível no âmbito das Distribuidoras, esta tese pretende contribuir para esta agenda de pesquisa ao propor o uso de econometria espacial como ferramenta alternativa de previsão. Conforme aponta Willis (2002), quando o objetivo das Distribuidoras é planejar a operação e a expansão do sistema de distribuição de energia elétrica de maneira eficiente, o sistema mais eficaz deveria ser capaz de antecipar a quantidade necessária de carga elétrica a ser entregue além de onde e quando serão necessárias. Tal informação é fornecida pela projeção espacial de carga. Nesta perspectiva, a contribuição de Willis (2002) é estabelecer a importância

---

<sup>1</sup> O modelo vigente impõe um limite de repasse à tarifa de, no máximo, 3% de excesso de contratação em relação à demanda efetiva.

<sup>2</sup> A distribuidora sofre penalidade sobre o montante descontratado, valorado com base no Valor de Referência, cuja *proxy* é o valor da energia nova, sendo que essa penalidade não seria repassada para a tarifa, além dos custos adicionais para compra de energia

<sup>3</sup> Consumidores cativos são aqueles não qualificados para adquirir energia de outro fornecedor além da distribuidora da área de concessão na qual está localizado. Consumidores livres são aqueles atendidos em qualquer nível de tensão de fornecimento e cuja demanda contratada seja igual ou superior a 3.000 kW. Este tipo de consumidor poderá optar ser atendido pelo distribuidor local, comprar energia diretamente de um produtor independente ou de autoprodutores com excedentes ou, ainda, comprar energia por meio de um comercializador. Consumidores potencialmente livres são aqueles que mesmo preenchendo as condições para exercer as opções de compra de energia com qualquer vendedor, continua atendido de forma regulada.



do espaço (estratégia de localização) para alcançar previsões precisas de demanda de energia elétrica. Todavia, o autor apenas evidencia a importância do espaço/localização para o planejamento do sistema de distribuição de energia elétrica, mas não utiliza nenhum método econométrico-espacial com o objetivo de incorporar as possíveis interações espaciais em seu modelo. Nesse contexto, o uso de modelos de econometria espacial podem auxiliar na captação de tais transbordamentos advindos de regiões vizinhas, caso existam.

A grande vantagem da utilização de métodos econométrico-espaciais consiste no fato de que são capazes de captar os transbordamentos espaciais que ocorrem entre as unidades regionais, garantindo estimativas de demanda custo-efetivas. Em outras palavras, a presente tese propõe um uso alternativo e pioneiro da metodologia econométrico-espacial de modo a introduzir as interações espaciais nas previsões de demanda de energia elétrica no Brasil, visando a redução do erro médio percentual absoluto da previsão (MAPE)<sup>4</sup>.

Para averiguar as hipóteses de que a demanda regional de eletricidade é espacialmente dependente e que os modelos espaço-temporais garantem maior acurácia nas previsões de demanda de energia elétrica, a presente tese apresenta três ensaios. Antes, porém, é realizado um levantamento bibliográfico acerca da evolução metodológica dos modelos utilizados para previsão de demanda de energia elétrica. A partir dessa revisão, pode-se notar o pioneirismo dos ensaios desta tese ao utilizar ferramentas espaço-temporais para modelar e prever a demanda de eletricidade no Brasil.

O primeiro ensaio realizou uma extensão da estatística de autocorrelação espacial proposta por Moran (1948) com o objetivo de verificar a possível dependência espacial na demanda regional de energia elétrica em uma estrutura de painel de dados. De posse de dados de consumo de energia elétrica, número de residências, tarifa média e PIB para as cinco regiões brasileiras, foi verificada a existência de dependência espacial negativa para todas as variáveis, exceto para o PIB que não se mostrou significativo. No que tange ao contexto bivariado, foi encontrado um padrão de dissimilaridade do consumo de energia elétrica regional com as demais variáveis macroeconômicas.

O objetivo da aplicação empírica realizada no segundo ensaio foi ajustar e comparar a acurácia de previsão entre o modelo auto regressivo integrado e de média móvel espacial

---

<sup>4</sup> O MAPE é uma medida comumente utilizada na avaliação da qualidade da previsão. O MAPE é o acrônimo de *Mean Absolute Percentage Error* que, em livre tradução, significa Erro Médio Percentual Absoluto.

(ARIMASp) e o modelo auto regressivo integrado e de média móvel (ARIMA) no contexto univariado. O modelo ARIMASp, que considera o espaço em sua modelagem, obteve melhor performance preditiva por ter sido o modelo que apresentou menor MAPE de previsão. O ARIMASp sobrestimou a demanda total de eletricidade em 214,68 GW enquanto a previsão do modelo ARIMA apresentou um déficit de 1.317,30 GW. A partir desse resultado, o modelo ARIMASp levou a uma previsão custo-efetiva de tal modo que as “Distribuidoras do Sudeste” não sofreriam qualquer perda financeira. Portanto, a interação espacial possui um papel importante na demanda de energia elétrica no Brasil.

O terceiro ensaio estendeu a análise realizada no segundo ensaio para o contexto multivariado ajustando três modelos para prever a demanda regional de eletricidade, assim como estimar as respectivas elasticidades de preço, renda, unidades conectadas e temperatura. Os modelos estimados foram painel dinâmico, modelo Durbin espacial dinâmico (SDM dinâmico) e o modelo de defasagem espacial e erro autorregressivo espacial com componente autorregressivo (SAC-AR (1)), sendo o SDM dinâmico o modelo que apresentou melhor acuraria de previsão. Assim, foi confirmada a necessidade de modelar a dependência espacial existente também no contexto multivariado. Com relação às elasticidades estimadas, verificou-se persistente inércia temporal, pouca sensibilidade da demanda em relação ao preço e à renda e um expressivo impacto sobre o consumo residencial em decorrência do maior número de unidades conectadas à rede. Além disso, o aquecimento global será responsável pelo aumento da demanda de eletricidade entre 0,90% e 1,49% nos domicílios brasileiros. Novamente, a presença de *spillovers* espaciais confirmam a existência de interação entre as regiões vizinhas resultando em padrões aglomerativos de consumo de eletricidade no setor residencial.

Diante dos resultados, a principal implicação desta tese consistiu em explicitar a importância da interação espacial para o consumo de energia elétrica no Brasil. A dependência espacial deve ser especificada nos modelos de demanda de eletricidade utilizados pelos diversos agentes do SEB de modo a melhorar a acurácia de previsão. De posse de modelos mais acurados, torna-se possível alcançar as metas do atual Modelo Institucional de modicidade das tarifas, universalização do acesso e segurança do sistema.

## **2. EVOLUÇÃO METODOLÓGICA NA PREVISÃO DE DEMANDA DE ENERGIA ELÉTRICA<sup>5</sup>**

Este capítulo revisita as literaturas internacional e nacional com o objetivo de fazer um levantamento de trabalhos que estimaram a demanda de energia elétrica utilizando diferentes métodos, de modo a evidenciar a evolução metodológica para previsão de demanda de energia elétrica.

Na área de planejamento energético, a partir dos anos de 1950, modelos de previsão de demanda de energia elétrica passaram a ser desenvolvidos. De posse da previsão de demanda de energia, é possível adequar sua estrutura de oferta, evitando prováveis gargalos e, assim, dar condições de infraestrutura para suportar o crescimento econômico de determinada região. O uso de modelos de previsão de demanda de energia elétrica tem sua origem em Houthakker (1951) com a estimação de demanda total de energia nas províncias da Grã-Bretanha no período 1938-1948. A partir desse trabalho seminal, diversos estudos têm sido empreendidos com intuito de conseguir modelos com menores erros de previsão (FISHER e KAYSEN, 1962; HOUTHAKKER e TAYLOR, 1970; WILSON, 1971; LYMAN, 1973; HOUTHAKKER *et al.*, 1974; TAYLOR, 1975; TAYLOR, 1977; MODIANO, 1984; ANDRADE e LOBÃO, 1997; GARCEZ e GHIRARDI, 2003; IRFFI *et al.*, 2009).

A previsão de demanda de eletricidade é um processo central para operações de planejamento periódico visando a utilização dos recursos de forma mais adequada em investimentos, melhor uso das plantas de geração, transmissão e distribuição, expansão das redes de transmissão e distribuição, melhor suprimento dos consumidores finais gerando ganhos de eficiência no setor e redução das tarifas de energia elétrica com vistas à modicidade tarifária. Diante da necessidade de previsões cada vez mais precisas, houve uma evolução metodológica para a previsão de demanda de energia elétrica buscando melhorar a acurácia das estimativas e, por conseguinte, a minimização do erro de previsão. Conforme aponta Hahn *et al.* (2009), encontrar uma abordagem e modelo apropriados é o núcleo central do processo de decisão no setor elétrico. Entretanto, conforme alerta Almeshaei e Soltan (2011), encontrar um método e modelos de previsão apropriados não é uma tarefa simples.

---

<sup>5</sup> Salienta-se que esta revisão de literatura não possui como objetivo esgotar o tema abordado. O propósito de tal revisão é mostrar a existência de possíveis lacunas na área de modelos de previsão de demanda de energia elétrica na qual a presente a tese pretende contribuir.

Diante disso, vários estudos empreenderam uma revisão da evolução das técnicas e modelos para previsão de energia elétrica, entre os quais podem ser citados Alfares e Nazeeruddin (2002), Hahn *et al.* (2009) e Singh *et al.* (2013). Uma variedade de metodologias e modelos de previsão de demanda de energia elétrica são encontrados na literatura especializada. Para demonstrar tal evolução metodológica, esta tese baseia-se e estende a classificação de Alfares e Nazeeruddin (2002) para ordenar as técnicas em oito categorias, a saber: i) regressão múltipla; ii) amortecimento exponencial; iii) filtro de Kalman; iv) séries temporais estocásticas; v) lógica *fuzzy*; vi) redes neurais, vii) sistemas inteligentes e de aprendizado e viii) econometria espacial.

A análise de regressão múltipla via modelos dinâmicos é um dos métodos frequentemente utilizados para previsão de demanda de energia elétrica. Os modelos de regressão múltipla, geralmente, utilizam como variáveis de controle eventos meteorológicos, PIB *per capita*, preços de eletricidade, população entre outras. Essa técnica estima os parâmetros dos modelos por meio do método de mínimos quadrados ordinários. Estudos de Houthakker (1951); Fisher e Kaysen, (1962) Houthakker e Taylor (1970); Wilson (1971); Anderson (1973); Wills (1977); Zhou e Teng (2013), entre outros, empregaram essa metodologia.

O método de amortecimento exponencial de Holt-Winters é um dos métodos utilizados para fazer previsões em séries temporais sazonais. O método consiste em utilizar médias móveis ponderadas exponencialmente para atualizar estimativas da média ajustada sazonalmente e baseia-se em três constantes de amortecimento para estacionaridade, tendência e sazonalidade. Resultados dessa análise podem ser encontrados em Christiaanse (1971); Barakat *et al.* (1990); El-Keib *et al.* (1995); Infield e Hill (1998).

O filtro de Kalman é um conjunto de equações matemáticas desenvolvidas em algoritmo computacional que formam um processo iterativo desenvolvido para realizar previsões futuras e estimar variâncias de modelos para séries temporais (GREWAL e ANDREWS, 2008). Através do processo de filtragem, parte-se de uma variável observada e consegue-se estimar outra variável não observável chamada variável de estado, podendo estimar os estados presente, passado e futuro através da previsão. Neste contexto, a previsão é adaptativa no sentido de que os parâmetros do modelo são automaticamente corrigidos para acompanhar a evolução das variações no fluxo de carga. Estudos como Moghnan e Rahman (1989); McDonald *et al.* (1989);

Park *et al.* (1991), Zheng *et al.* (2000), Inglesi-Lotz (2011) e Arisoy e Ozturk (2014) utilizaram o filtro de Kalman para prever a demanda de energia elétrica.

Os métodos de séries temporais estão entre as abordagens mais populares para a previsão e são baseados no pressuposto de que os dados possuem uma estrutura de autocorrelação, tendência e/ou variação sazonal. O método realiza a previsão em função dos dados da série passada e, para tanto, os dados devem seguir um padrão estacionário. Diversos estudos utilizaram alguma ferramenta das séries de tempo. No âmbito univariado podem ser citados os modelos AR - Auto regressivos (LIU *et al.*, 1996; HUANG, 1997), PAR – modelos auto regressivos periódicos (ZHAO *et al.*, 1997), ARMA – Modelos Auto regressivos e de Médias Móveis (CHEN *et al.*, 1995), ARIMA – Modelos Auto regressivos integrados de médias móveis (ELRAZAZ e MAZI, 1989; JUBERIAS *et al.*, 1999), técnica SVM – Máquinas de Vetores Suporte (CHEN *et al.*, 2004; TAO *et al.*, 2004). Já no contexto multivariado, são utilizados os modelos ARMAX – Auto Regressivo de Média Móvel com Variáveis Exógenas (FAN e MCDONALD, 1994; CHO *et al.*, 1995; YANG *et al.*, 1996); VAR – Vetor Auto Regressivo (MODIANO, 1984), VEC – Vetor de Correção de Erros (BAKIRTAS *et al.*, 2000; GARCEZ e GHIRARDI, 2003; JAMIL e AHMAD, 2011; LIM *et al.*, 2014).

A lógica *fuzzy* é uma metodologia baseada na teoria dos conjuntos *fuzzy* ou nebulosos. A teoria dos conjuntos nebulosos é um instrumento de trabalho eficaz no tratamento de dados vagos para a obtenção de resultados precisos (ZADEH, 1965). O conceito da lógica *fuzzy* está na possibilidade de uma variável assumir qualquer valor entre 0 e 1. Diferentemente da lógica convencional, a lógica *fuzzy* não se baseia no “princípio do terceiro excluído”, ou seja, de que dada afirmação ou é verdadeira ou é falsa, não havendo outra hipótese, mas sim de que uma afirmação pode ser ao mesmo tempo parcialmente verdadeira e parcialmente falsa, o que permite ao sistema incorporar incertezas e imperfeições (KRYKHTINE *et al.*, 2013). É uma teoria utilizada na previsão de carga devido a sua capacidade de aproximar qualquer função não linear com uma exatidão arbitrária e de encontrar padrões em grandes conjuntos de dados (KIARTZIS e BAKIRTZIS, 2000; MIRANDA e MONTEIRO, 2000; ANDRADE *et al.*, 2010; ZAHEDI *et al.*, 2013; TORRINI *et al.*, 2016).

As Redes Neurais Artificiais (RNA) são modelos matemáticos inspirados nos princípios de funcionamento dos neurônios biológicos e na estrutura do cérebro. Ou seja, são técnicas computacionais que se assemelham à estrutura neural dos organismos inteligentes e adquirem conhecimento através da experiência. Os modelos baseados em RNA vêm sendo utilizados na

previsão de séries temporais com componentes não lineares, funcionando como um aproximador universal. Ou seja, a rede pode capturar qualquer tipo de comportamento por mais complexo que seja (BAKIRTZIS *et al.*, 2006; GHIASSI *et al.*, 2006; BASSI e OLIVARES, 2006).

Vale ressaltar que, apesar da grande variedade de métodos utilizados e suas aplicações empíricas para prever a demanda de energia elétrica, todos os trabalhos citados anteriormente ignoram a possível interação espacial existente nos dados e, conseqüentemente, não consideram a influência do espaço em suas previsões, o que pode ocasionar viés nas estimativas. Diante disso, Ohtsuka *et al.* (2010) inauguram uma nova linha de modelos de previsão de demanda de energia elétrica ao considerar a interação e a dependência espacial entre agentes.

Ohtsuka *et al.* (2010) integraram os modelos auto regressivo espacial (SAR) e auto regressivo e de média móvel (ARMA) - SAR-ARMA - para prever a demanda regional de eletricidade no Japão, com a inclusão da interação espacial existente entre nove distribuidoras japonesas no período mensal compreendido entre os anos de 1992 a 2003. Os autores concluíram que o modelo SAR-ARMA (1,1) obteve melhor capacidade preditiva que o modelo ARMA (1,1), confirmando a hipótese de que autocorrelação espacial deve ser levada em consideração na previsão de demanda de eletricidade. Utilizando os dados de Ohtsuka *et al.* (2010), Ohtsuka e Kakamu (2013) concluíram que o modelo VAR (1) foi superior ao SAR-ARMA (1,1) no que se refere à performance preditiva.

Nesta mesma linha, Blásquez Gomez *et al.* (2013) analisaram a demanda residencial de eletricidade para quarenta e seis províncias espanholas no período de 2001 a 2010. A análise empírica empreendida pelos autores visava verificar a influência de preço, renda, transbordamentos espaciais e, particularmente, analisar o impacto da variação da renda disponível das famílias durante o período da crise econômica 2009-2010. A partir de um modelo SARAR (1,1), o estudo concluiu que a demanda é inelástica em relação ao preço da energia, possui baixa elasticidade-renda além de evidenciar a presença de efeitos espaciais no consumo de eletricidade residencial na Espanha. Análise similar foi realizada por Cho *et al.* (2015) para dezesseis regiões da Coreia do Sul no período anual de 2004 a 2012. Em vez de um modelo SARAR(1,1), os autores utilizaram um modelo de painel de dados com defasagem espacial e erro autorregressivo espacial com um processo AR(1) denominado SAC-AR(1). Os resultados evidenciaram a existência de *spillovers* espaciais positivos na demanda de eletricidade

residencial e na manufatura e efeitos espaciais negativos na agricultura. Para o setor varejista sul-coreano, não foram encontradas evidências de efeitos espaciais.

O Quadro 2.1 resume a evolução dos métodos de previsão aplicados ao setor elétrico mantendo uma ordem cronológica dos estudos segundo a classificação categórica estabelecida previamente, passando pela abordagem metodológica clássica (regressão múltipla, amortecimento exponencial, séries de tempo e filtro de Kalman), métodos de inteligência artificial e computacional (SVM, redes neurais e lógica *fuzzy*) e, por fim, referindo-se a trabalhos que aplicaram o ferramental econométrico-espacial (SAR-ARMA, SARAR, SAC-AR).

**Quadro 2.1:** Resumo da Evolução Metodológica dos Modelos de Previsão de Demanda de Energia Elétrica

(continua)

Autores	Data	Região Estudada	Período	Método Utilizado	Principais Resultados
Houthakker	1951	42 províncias da Inglaterra	Mensal: 03/1927 a 01/1948	MQO	O estudo estimou as elasticidades-preço e renda de longo prazo no valor de $-0,8928$ e $1,166$ , respectivamente.
Christiaanse	1971	Estados dos EUA atendidos pela American Electric Power (AEP)	Hora: 1966-1967	Amortecimento exponencial	Os resultados indicam que melhoras na previsão são alcançadas quando utiliza-se as previsões meteorológicas. O autor ressalta as previsões para feriados são difíceis de se obter.
Anderson	1973	Califórnia e 50 estados dos EUA	Anual: 1947-1969 e 1969	MQO	Os resultados para os 50 estados produzem evidência de que a demanda residencial é influenciada pelo custo da eletricidade, renda, urbanismo, clima e tamanho do agregado familiar. Quanto à Califórnia, a projeção realizada de 1970-2000 mostra que a taxa de crescimento do consumo por consumidor seria de 3,7%.
Wills	1977	Massachusetts	1975	MQO	O autor estima elasticidades-renda e preço de curto prazo de, respectivamente, $0,32$ e $-0,08$ .
Modiano	1984	Brasil	Anual: 1966-1981	MQO com correção para correlação serial;	As estimativas das elasticidades-preço variam de $-0,457$ a $-0,118$ enquanto elasticidades renda variam entre $1,116$ a $0,332$ para as quatro classes de consumidores de energia elétrica.



**Quadro 2.2:** Resumo da Evolução Metodológica dos Modelos de Previsão de Demanda de Energia Elétrica

(continuação)

Autores	Data	Região Estudada	Período	Método Utilizado	Principais Resultados
Moghran e Rahman	1989	Sudeste dos EUA	Carga horária de até quatro semanas	MQO, ARIMA, amortecimento exponencial, filtro de Kalman e abordagem baseada no conhecimento	Os autores fazem um comparativo de técnicas para previsões de carga e concluem que métodos fortemente dependentes do histórico (ARIMA) tendem a apresentar maior precisão na previsão, porém com erros expressivos durante a ocorrência de eventos extremos ou mudanças bruscas, os quais são melhor captados por métodos flexíveis, como a abordagem baseada no conhecimento.
Andrade e Lobão	1997	Brasil	Anual: 1963-1995	MQO; VEC; VAR instrumental; DOL	Os autores chegaram à conclusão de que as elasticidades-preço de curto e longo prazos eram -0,06 e -0,051; e as elasticidades-renda de curto e longo prazos eram 0,212 e 0,213.
Bakirtas <i>et al.</i>	2000	Turquia	Anual: 1962-1996	ARMA; Cointegração; VEC	O estudo não encontrou elasticidade-preço significativa visto que as tarifas de eletricidade eram subsidiadas pelo governo. A elasticidade-renda de longo e curto prazo eram cerca de 0,7 e 3,1, respectivamente. Para previsão do consumo de energia elétrica entre 1997 e 2010 por meio de um ARMA (1,1), os autores concluíram que o consumo total de eletricidade <i>per capita</i> chegaria a cerca de 2.222 KWh.

**Quadro 2.3:** Resumo da Evolução Metodológica dos Modelos de Previsão de Demanda de Energia Elétrica

(continuação)

Autores	Data	Região Estudada	Período	Método Utilizado	Principais Resultados
Garcez e Ghirardi	2003	Bahia	Mensal: 01/1994- 12/2002	VAR; Cointegração; VEC	A elasticidade-preço de curto-prazo varia de -0.03 a -0.07 enquanto a elasticidade-renda varia de 0,127 a 0,394. Os resultados confirmam a natureza inelástica para o segmento residencial.
Andrade <i>et al.</i>	2010	Subestações de Mogi-Guaçu e Votuporanga, São Paulo	Minutos: durante 7 dias em intervalo de 5 minutos.	Lógica <i>Fuzzy</i>	O MAPE obtido do sistema <i>fuzzy</i> empregado para previsão de demanda de energia elétrica no curtíssimo prazo foi de 2,24% e de 1,35% para as subestações de Mogi-Guaçu e Votuporanga, respectivamente.
Andrade	2010	Subestações de Cordeirópolis e Ubatuba, São Paulo	Minutos: durante 7 dias em intervalo de 5 minutos.	Neuro <i>Fuzzy</i>	O trabalho empregou o sistema de inferência <i>neurofuzzy</i> adaptativo (ANFIS) para previsão de demanda de energia elétrica no curtíssimo prazo estimando MAPE de, em média, 0,7264% para Cordeirópolis e 0,5163 % para Ubatuba.

**Quadro 2.4:** Resumo da Evolução Metodológica dos Modelos de Previsão de Demanda de Energia Elétrica

(conclusão)

Autores	Data	Região Estudada	Período	Método Utilizado	Principais Resultados
Ohtsuka <i>et al.</i>	2010	9 distribuidoras japonesas	Mensal: 01/1992 a 12/2003	SAR-ARMA; ARMA	Os autores concluíram que o modelo SAR-ARMA (1,1) obteve melhor capacidade preditiva que o modelo ARMA (1,1).
Ohtsuka e Kakamu	2013	9 distribuidoras japonesas	Mensal: 01/1992 a 12/2003	SAR-ARMA; VAR	Os autores concluem que o modelo VAR (1) foi superior ao SAR-ARMA (1,1) no que se refere à performance preditiva.
Blásquez Gomez <i>et al.</i>	2013	46 províncias espanholas	Anual: 2001-2010	SARAR	O estudo concluiu que a demanda é inelástica em relação ao preço da energia, possui baixa elasticidade-renda além de evidenciar a presença de efeitos espaciais no consumo de eletricidade residencial na Espanha.
Cho <i>et al.</i>	2015	16 regiões sul-coreanas	Anual: 2004-2012	SAC-AR	Os autores encontraram <i>spillovers</i> espaciais positivos na demanda de eletricidade residencial e na manufatura e efeitos espaciais negativos na agricultura. Para o setor varejista, não foram encontradas evidências de efeitos espaciais.

**Fonte:** Elaboração Própria.

Por meio desta breve revisão bibliográfica, foi possível verificar que os modelos de previsão no setor elétrico têm evoluído, nos anos recentes, no sentido de tentar incorporar as possíveis interações espaciais. Apesar de alguns trabalhos evidenciarem a importância da inclusão do espaço na regressão para previsão de demanda de energia elétrica, ainda são escassos os estudos empíricos aplicados ao setor elétrico que incorporam a interação espacial em sua modelagem. Portanto, percebem-se nichos a serem preenchidos com o intuito de realizar previsões mais precisas por intermédio da utilização das ferramentas econométrico-espaciais.

Visando contribuir para a literatura nacional de previsão de demanda de energia elétrica, esta tese propõe pioneiramente o uso de modelos econométrico-espaciais na previsão de demanda de eletricidade no Brasil. No que se refere à contribuição para a literatura internacional, esta tese avança metodologicamente ao propor o modelo ARIMASp além de utilizar pioneiramente o modelo espacial Durbin dinâmico para prever a demanda de energia elétrica.

O próximo capítulo desta tese, ensaio 1, propõe uma extensão da estatística *I* de Moran nos dados para dados em painel. Neste ensaio, será realizada uma análise empírica com o objetivo de verificar se existe dependência espacial no processo gerador dos dados de consumo regional de energia elétrica no Setor Elétrico Brasileiro (SEB) no período mensal de janeiro de 2003 a dezembro de 2013. A importância análise se deve ao fato de que, caso seja confirmada a existência de dependência espacial no consumo regional de eletricidade, a não inclusão do espaço nas previsões enviesará as estimativas o que, por sua vez, gera ineficiências produtiva, alocativa e ambiental no SEB.

### 3. ENSAIO 1 - ANÁLISE DA AUTOCORRELAÇÃO ESPACIAL NA DEMANDA DE ELETRICIDADE: EVIDÊNCIA PARA AS REGIÕES BRASILEIRAS

**Resumo:** O presente ensaio estendeu a estatística de verificação de autocorrelação espacial nos dados proposta por Moran (1948) para a estrutura de painel de dados. As principais vantagens da estatística proposta é verificar a interação espacial entre os diversos atributos no tempo e no espaço conjuntamente além de minimizar o tempo dispendido para tal verificação pelo pesquisador. Uma aplicação empírica foi realizada para verificar a existência de dependência espacial no consumo de eletricidade regional no Setor Elétrico Brasileiro. De posse de um painel de dados de consumo de energia elétrica, número de residências, tarifa média e PIB no período mensal de 2003 a 2013 para as cinco regiões brasileiras, foi verificada a existência de dependência espacial negativa para todas as variáveis, exceto para o PIB que não se mostrou significativo. No que tange ao contexto bivariado, foi evidenciado um padrão de dissimilaridade do consumo de energia elétrica regional com as demais variáveis macroeconômicas demonstrando que regiões com alto consumo de energia elétrica são circunvizinhas a regiões com baixa tarifa média, reduzido número de residências conectadas a rede, de baixo PIB e vice versa. Em termos de política pública, os resultados encontrados evidenciam a necessidade de abordar a questão das disparidades regionais no Brasil, de modo a promover iniciativas governamentais com vistas à equidade regional em relação ao acesso à energia elétrica e tarifas mais módicas.

**Palavras Chave:** Dependência Espacial; *I* de Moran para Dados em Painel; Setor Elétrico Brasileiro.

**Abstract:** This article extended the Moran's *I* statistic for verification of spatial autocorrelation in the data to the panel data structure. The main advantages of the proposed statistic is to verify that there is spatial interaction between the various attributes in time and space concomitantly besides minimizing the time spent by the researcher. An empirical exercise was made to verify the spatial dependence on the regional consumption of electricity in the Brazilian Electricity Sector. A panel of data for the five Brazilian regions in the period from 2003 to 2013 containing the variables regional electricity consumption, number of residences served in each region, average tariff in each region and regional economic activity index seasonally adjusted (IBCR), proxy of the GDP, was used in the analysis. The results showed negative spatial dependence for all variables, except for GDP that was not significant. Regarding the bivariate context, a spatial pattern of dissimilarity of the regional electricity consumption was evidenced with the other macroeconomic variables, demonstrating that regions with high electricity consumption are surrounding by regions with low average tariffs, small number of households connected to the grid, low GDP and vice versa. In terms of public policy, the results show the need to address the issue of regional disparities in Brazil in order to promote governmental initiatives with a view to regional equity in relation to access to electricity and more affordable tariffs.

**Keywords:** Spatial Autocorrelation. Moran's *I* to Panel Data. Brazilian Electricity Sector.

### 3.1 INTRODUÇÃO

Na natureza e na sociedade nada está dissociado. Os fenômenos nas diferentes unidades regionais se inter-relacionam e se completam de maneira que tais fenômenos não coexistem de forma isolada e independente no tempo e espaço. Diante disso, a interação espacial possui uma natureza multidirecional gerando efeitos espaciais (dependência e heterogeneidade espaciais) que dificultam a especificação de modelos econométricos de forma apropriada o que, por sua vez, podem acarretar ineficiência e, até mesmo, enviesamento das estimativas.

Fotheringham *et al.* (2002) orientam que, antes de utilizar modelos econométricos sofisticados, é preciso compreender a dinâmica da distribuição espacial de dados oriundos de fenômenos ocorridos no espaço. Nesse sentido, a análise exploratória de dados espaciais (AEDE) deve ser empreendida sempre que os dados estiverem espacialmente localizados e/ou quando o arranjo espacial for importante para explicar o fenômeno estudado (BAILEY e GATTREL, 1995). Portanto, a AEDE permite fazer uma análise subjacente do processo gerador dos dados espaciais buscando compreender a distribuição e o comportamento dos dados para auxiliar o processo de especificação dos modelos.

De acordo com Le Gallo e Ertur (2003), a AEDE é um conjunto de técnicas voltadas a descrever e visualizar distribuições espaciais, identificar localizações atípicas ou *outliers* espaciais, detectar padrões de associação espacial e *clusters* além de sugerir outras formas de efeitos espaciais. As técnicas da AEDE usualmente tomam a forma de gráficos, mapas e medidas globais ou locais de associação espacial (ARBIA, 2006).

A partir das técnicas da AEDE, é possível computar medidas de autocorrelação espacial<sup>6</sup> global e local que permitem verificar se os dados espaciais apresentam aleatoriedade ou dependência espacial, isto é, se os valores de uma característica em uma região são independentes (ou não) dos valores dessa característica nas regiões vizinhas. De forma geral, a autocorrelação espacial pode ser definida como a coincidência de similaridade de valores com a similaridade de localização (ANSELIN, 1999; LE GALLO e ERTUR, 2003).

---

<sup>6</sup> Ressalta-se que dependência espacial e autocorrelação espacial, nesta tese, são consideradas sinônimos. Entretanto, rigorosamente, os conceitos apresentam distinção: enquanto a dependência espacial é uma propriedade de função de densidade conjunta, a autocorrelação espacial é um momento dessa função que pode ser estimada (ALMEIDA, 2012).

Segundo Fotheringham *et al.* (2002), “a estatística global de autocorrelação espacial fornece informações sobre o padrão de associação linear espacial, ou seja, o grau em que o conjunto de dados está agrupado, disperso ou distribuído aleatoriamente.” Almeida (2012) aponta que um coeficiente de autocorrelação espacial descreve um conjunto de dados que está ordenado segundo uma sequência espacial cujos coeficientes de autocorrelação espacial global mais conhecidos são as estatísticas *I* de Moran, *c* de Geary e *G* de Getis-Ord.

Entretanto, cabe enfatizar que as referidas estatísticas globais de autocorrelação espacial são apropriadas para o caso de *cross section*. Todavia, conforme apontado por Hsiao (2003), os modelos para dados em painel oferecem uma série de vantagens em relação aos modelos de *cross section* ou aos de séries temporais, a saber: os dados possuem tanto a dimensão temporal quanto a dimensão de corte transversal o que leva ao aumento do tamanho da amostra; contém maior variação e menor colinearidade entre as variáveis; possibilita a redução da influência da omissão de variáveis relevantes além de permitir o estudo de modelagens mais complexas.

Apesar de demonstrada a importância dos dados em painel para a aplicação empírica, a análise espacial não possui uma estatística de autocorrelação espacial nos dados para este tipo de estrutura de dados. Salienta-se que existe a estatística de multiplicador de Lagrange (*I* de Moran) para análise da autocorrelação espacial dos resíduos para dados em painel conforme pode ser encontrado com maiores detalhes em Baltagi *et al.* (2003), Arbia (2005), Baltagi *et al.* (2007), Salisu *et al.* (2012) e Ren *et al.* (2014). Diante da inexistência de uma estatística global de autocorrelação espacial nos dados que contemple as dinâmicas temporal e espacial concomitantemente, o presente ensaio propõe uma estatística global de *I* de Moran uni e bivariada que considera ambos os contextos seccional e temporal de maneira a preencher a lacuna existente na literatura referente às estatísticas espaciais exploratórias.

Dessa forma, vale enfatizar que a presente proposta está situada especificamente sobre os dados onde a autocorrelação nos mesmos implica que o atributo de interesse é influenciado por seus vizinhos e vice versa. Por sua vez, a autocorrelação nos resíduos evidencia que a variável de interesse em modelo econométrico-espacial é dependente dos atributos de seus vizinhos.

Além dessa seção introdutória, o presente ensaio está estruturado como segue: a segunda seção aborda a metodologia proposta, bem como a descrição dos dados utilizados para a

realização da aplicação empírica. Na terceira seção são discutidos os resultados e, por fim, as considerações finais do estudo são empreendidas na quarta seção.

## 3.2 ASPECTOS METODOLÓGICOS E BASE DE DADOS

### 3.2.1 Identificação da Autocorrelação Espacial em Painel de Dados

É quase clichê dizer que tudo na natureza ou na sociedade está interligado. Em termos de Economia Regional, os fenômenos em diferentes regiões interagem e se complementam mutuamente, de modo que coexistem no tempo e no espaço. Há a necessidade, portanto, de desenvolver um procedimento metodológico capaz de mensurar essas interações no tempo e no espaço.

A autocorrelação espacial (também chamada de dependência espacial) é um conceito-chave na análise espacial para medir a correlação entre as variáveis em estudo e a proximidade dessas variáveis no espaço geográfico (FOTHERINGHAM *et al.*, 2002; FISCHER e GETIS, 2010; FISCHER e WANG, 2011). A estatística  $I$  de Moran é a medida de autocorrelação espacial mais comum para descrever o grau de dependência espacial nas variáveis de interesse (FISCHER e GETIS, 2010). Moran (1948) formalizou uma estatística para um conjunto de dados estruturados em *cross section* cuja estatística depende da definição do arranjo espacial das observações expressa por uma matriz de pesos espaciais  $W$ .

A matriz de pesos espaciais contém a informação do quanto a interação é mais forte no caso de regiões próximas (geográfica ou economicamente), e mais fraca no caso de regiões mais distantes. Os pesos são não-nulos quando as observações são contíguas ou quando estão dentro de uma distância  $d$  em relação à outra. Há várias formas de definição da matriz de pesos espaciais: com base na contiguidade (“torre” ou “rainha”), na distância geográfica, no inverso da distância, matriz binária com  $n$  vizinhos mais próximos, distância econômica entre outras (ANSELIN, 1988; ANSELIN e BERA, 1998; LE GALLO e ERTHUR, 2003; LESAGE e PACE, 2009).

Arbia e Piras (2005) sugeriram o cálculo da estatística  $I$  de Moran utilizando os resíduos do modelo especificado na *cross section* associada a cada período de tempo. Ren *et al.* (2014) também utilizaram os resíduos para realizar uma análise empírica do método chamado pelos autores de FDB (*Fast Double Bootstrap*). O método de Arbia e Piras (2005) pode ser considerado dispendioso porque requer repetitivos cálculos. Por outro lado, o método FDB é



muito complexo e custoso em termos computacionais, pois demanda sete etapas para computar a estatística  $I$  de Moran. Além da estatística  $I$  de Moran, vale ressaltar que existem outras estatísticas, como o *Lagrange Multiplier* (LM) e *Likelihood Ratio* (LR), que analisam a autocorrelação espacial nos resíduos para modelos de dados de painel (BALTAGI *et al.*, 2003; BALTAGI *et al.* 2007).

Contudo, o método proposto por este ensaio revisita a ideia original de Moran (1948) que consiste em verificar a autocorrelação espacial nos dados no contexto da análise exploratória de dados espaciais. Nesse sentido, este ensaio propõe uma extensão da estatística global  $I$  de Moran uni e bivariada para dados de painel, isto é, quando as dinâmicas temporal e espacial estão presentes concomitantemente. A implementação do método proposto é bastante simples e fácil, uma característica que pode ser considerada sua principal vantagem em relação aos métodos descritos anteriormente. Além disso, diferentemente de outros testes, a estatística proposta pode ser aplicada nos contextos uni e bivariados.

A estatística  $I$  de Moran proposta é computada da seguinte forma: primeiro, os dados são agrupados em blocos de acordo com seu tempo de referencia (*stacked by date*) e padronizados na *cross section* em cada bloco. Este procedimento gera a variável  $z_{kgt}$ , que denota uma observação padronizada da variável  $k$  ( $k = 1, 2, \dots, K$ ) na unidade regional  $g$  ( $g = 1, 2, \dots, G$ ) no tempo  $t$  ( $t = 1, 2, \dots, T$ ).

Agora defina  $\mathbf{z}_{kt} = [z_{k1t}, \dots, z_{kgt}, \dots, z_{kGt}]'$  como um vetor coluna nas regiões  $G$  na variável  $k$  no tempo  $t$ . Ademais, defina  $\tilde{\mathbf{z}}_{kt}$ , como as observações de  $\mathbf{z}_{kt}$  defasadas espacialmente, ou seja,  $\tilde{\mathbf{z}}_{kt} = \mathbf{W}\mathbf{z}_{kt}$  ( $\tilde{\mathbf{z}}_{kt} = [\tilde{z}_{k1t}, \dots, \tilde{z}_{kgt}, \dots, \tilde{z}_{kGt}]$ ), onde  $\mathbf{W}$  é uma matriz de pesos espaciais normalizada na linha com dimensão  $G \times G$ .

A estatística  $I$  de Moran univariada para a variável  $k$  será o parâmetro  $\beta$  estimado pelo método de *Pooled Ordinary Least Squares* (POLS) no modelo de regressão que segue:

$$\tilde{\mathbf{z}}_k = \mu + \beta \mathbf{z}_k + \boldsymbol{\varepsilon}_k \quad (3.1)$$

onde  $\tilde{\mathbf{z}}_k = (\tilde{z}_{k1}', \dots, \tilde{z}_{kt}', \dots, \tilde{z}_{kT}')'$  e  $\mathbf{z}_k = (z_{k1}', \dots, z_{kt}', \dots, z_{kT}')'$  são vetores coluna de dimensão  $(G \times T)$  e  $\boldsymbol{\varepsilon}_k = (\boldsymbol{\varepsilon}_{k1}', \dots, \boldsymbol{\varepsilon}_{kt}', \dots, \boldsymbol{\varepsilon}_{kT}')'$  é um ruído branco de dimensão  $(G \times T)$ .

A estatística  $I$  de Moran bivariada para as variáveis  $\ell$  e  $k$  será o parâmetro  $\beta$  no modelo de regressão abaixo:

$$\tilde{\mathbf{z}}_{\ell} = \mu + \beta \mathbf{z}_k + \varepsilon_k \quad (3.2)$$

Uma estimativa de  $\beta$  na Equação 3.2 também é obtida pelo método de POLS.  $\tilde{\mathbf{z}}_{\ell} = (\tilde{\mathbf{z}}_{\ell 1}', \dots, \tilde{\mathbf{z}}_{\ell t}', \dots, \tilde{\mathbf{z}}_{\ell T}')'$  e  $\mathbf{z}_k = (\mathbf{z}_{k1}', \dots, \mathbf{z}_{kt}', \dots, \mathbf{z}_{kT}')'$  possuem dimensão  $(G \times T)$  e denotam as variáveis  $\ell$  e  $k$ , respectivamente. Já  $\boldsymbol{\varepsilon}_k = (\boldsymbol{\varepsilon}_{k1}', \dots, \boldsymbol{\varepsilon}_{kt}', \dots, \boldsymbol{\varepsilon}_{kT}')'$  assim como na Equação 3.1 é um ruído branco de dimensão  $(G \times T)$ .

Para encontrar estimativas consistentes dos coeficientes  $\beta$ s nas Equações 3.1 e 3.2 por meio do método POLS, é necessário garantir as hipóteses de homocedasticidade e inexistência de autocorrelação serial além da condição de ortogonalidade populacional, que requer  $E(\mathbf{z}_t \boldsymbol{\varepsilon}_t') = 0$ ,  $t = 1, 2, \dots, T$  (WOOLDRIDGE, 2002). Esta última hipótese implica que a variável explicativa não é correlacionada com termo de erro no mesmo período, o que significa exogeneidade contemporânea. Note contudo, que esta hipótese não diz nada sobre a relação entre  $\mathbf{z}_s$  e  $\boldsymbol{\varepsilon}_t$ , quando  $s \neq t$ .

O estimador POLS é definido como segue:

$$\hat{\beta} = (\mathbf{z}_k' \mathbf{z}_k)^{-1} \mathbf{z}_k' \tilde{\mathbf{z}}_{\ell} \quad (3.3)$$

Como mencionado anteriormente, quando  $\ell \neq k$  ( $\ell = k$ ), o coeficiente  $\hat{\beta}$  estimado, pode ser interpretado como a estatística  $I$  de Moran bivariada (univariada) para um painel de dados. Em outras palavras:

$$I = \hat{\beta} \quad (3.4)$$

Devido ao processo de padronização, o valor da estatística  $I$  de Moran está compreendido dentro do intervalo  $-1 \leq I \leq 1$  (Cf. MORAN, 1948). A hipótese nula ( $H_0$ ) referente aos modelos 1 e 2 pode ser definida como “aleatoriedade espacial” e a hipótese alternativa ( $H_a$ ) como “existência de dependência espacial” nos dados. Baseado nas Equações 3.3 e 3.4 as hipóteses a serem testadas por meio de um teste  $t$  padrão são as que seguem:

$$H_0: \hat{\beta} = I = 0 \Rightarrow \text{aleatoriedade espacial} \quad (3.5)$$

$$H_a: \hat{\beta} = I \neq 0 \Rightarrow \text{dependência espacial} \quad (3.6)$$

Se  $H_0$  é rejeitada ao nível de significância  $\alpha$ , o coeficiente  $\hat{\beta}$  nas Equações 3.3 e 3.4 é estatisticamente significativo a este nível, sugerindo a existência de dependência espacial nos

dados em painel. No caso univariado, se  $\hat{\beta}$  é positivo, há evidência de autocorrelação espacial positiva indicando um padrão de similaridade entre os valores de um atributo particular em relação as localizações contíguas no conjunto de painel de dados. Por outro lado, se  $\hat{\beta}$  é negativo, a evidência sugere uma autocorrelação espacial negativa e, conseqüentemente, um padrão de dissimilaridade para os atributos.

Analogamente, no contexto bivariado, se o coeficiente  $\hat{\beta}$  é positivo e estatisticamente significativo, há evidências de que altos (baixos) valores de um atributo de uma região tende associada com altos (baixos) valores de outro atributo sob análise nas regiões vizinhas. Quando o  $\hat{\beta}$  é negativo e estatisticamente significativo, a evidência sugere uma autocorrelação espacial negativa, isto é altos (baixos) valores de um atributo tendem a ser vizinhos de baixos (altos) valores de outro atributo.

Em síntese, a estatística  $I$  de Moran proposta para a estrutura de dados em painel fornece três tipos de informação: i) o nível de significância mostra se o atributo analisado está distribuído aleatoriamente (ou não) no espaço e ao longo do tempo; ii) o sinal da estatística  $I$  de Moran, desde que significativa, revela um padrão de similaridade ( $\hat{\beta}$  positivo) ou dissimilaridade ( $\hat{\beta}$  negativo); iii) a magnitude do coeficiente  $\hat{\beta}$  fornece o grau da dependência espacial entre os atributos e sua localização.

### **3.2.2 Descrição da Base de Dados**

Com o intuito de verificar a existência de dependência espacial no processo gerador dos dados de consumo residencial de energia elétrica no SEB, este ensaio utiliza um painel de dados contendo as cinco macro regiões brasileiras (Norte, Nordeste, Centro-Oeste, Sudeste e Sul) no período mensal de janeiro de 2003 a dezembro de 2013, totalizando 660 observações. Ressalta-se que foi utilizado os dados de consumo residencial das cinco regiões brasileiras devido a indisponibilidade dos dados das Distribuidoras de energia elétrica no Brasil. Sendo assim, este ensaio considera as cinco regiões brasileiras como Distribuidoras Equivalentes.

Para estimar as estatísticas  $I$  de Moran uni e bivariada, serão utilizados os dados de consumo regional de energia elétrica, número de residências atendidas em cada região, tarifa média regional, índice de atividade econômica regional com ajuste sazonal.

Em relação à fonte dos dados, as variáveis consumo regional de energia elétrica, número de residências atendidas em cada região e tarifa média regional são oriundas do Sistema de

Apoio à Decisão (SAD) da Agência Nacional de Energia Elétrica (ANEEL). O Banco Central, por meio do sistema gerador de séries temporais (SGS), disponibiliza o Índice de Atividade Econômica Regional (IBCR) com ajuste sazonal. Este índice foi utilizado como *proxy* para o PIB regional, uma vez que o mesmo não é divulgado mensalmente. O Quadro 3.1 resume as variáveis utilizadas na aplicação empírica deste ensaio.

**Quadro 3.1:** Descrição das variáveis utilizadas.

Variável	Descrição	Unidade	Fonte dos dados
<i>CONS</i>	Consumo de energia elétrica regional	GWh	SAD/ANEEL
<i>RESID</i>	Número de residências atendidas	Quantidade	SAD/ANEEL
<i>TARIFA</i>	Tarifa média regional	R\$	SAD/ANEEL
<i>PIB</i>	Índice de atividade econômica regional com ajuste sazonal	Índice (Jan 2003 = 100)	SGS/BC

**Fonte:** Elaboração Própria.

A Tabela 3.1 evidencia algumas estatísticas descritivas das variáveis, tais como média, desvio padrão, valores mínimo e máximo. É possível perceber que o consumo de energia elétrica é discrepante entre as regiões visto que a média de consumo varia consideravelmente no contexto inter-regional para o período analisado. Este fato pode ser visualizado por meio da comparação do consumo médio de energia elétrica da região Sudeste comparado ao consumo das demais regiões do País. O alto consumo de energia elétrica da região Sudeste pode ser devido ao fato de que o número de residências atendidas nessa região tem média bem acima quando comparado às demais regiões. Além disso, essa região é a mais desenvolvida no País.

À mercê do fato supracitado, a região Sudeste não apresenta a maior tarifa média no Brasil. Cabe à região Centro-Oeste a primeira posição no que tange à maior tarifa média de energia elétrica. É interessante notar também que as tarifas médias mais baratas concentram-se nas regiões Nordeste e Sul, regiões possuidoras de grandes reservatórios além de importantes hidrelétricas situadas nas bacias dos rios Paraná e São Francisco.

**Tabela 3.1:** Estatística descritiva das variáveis utilizadas no modelo por Região.

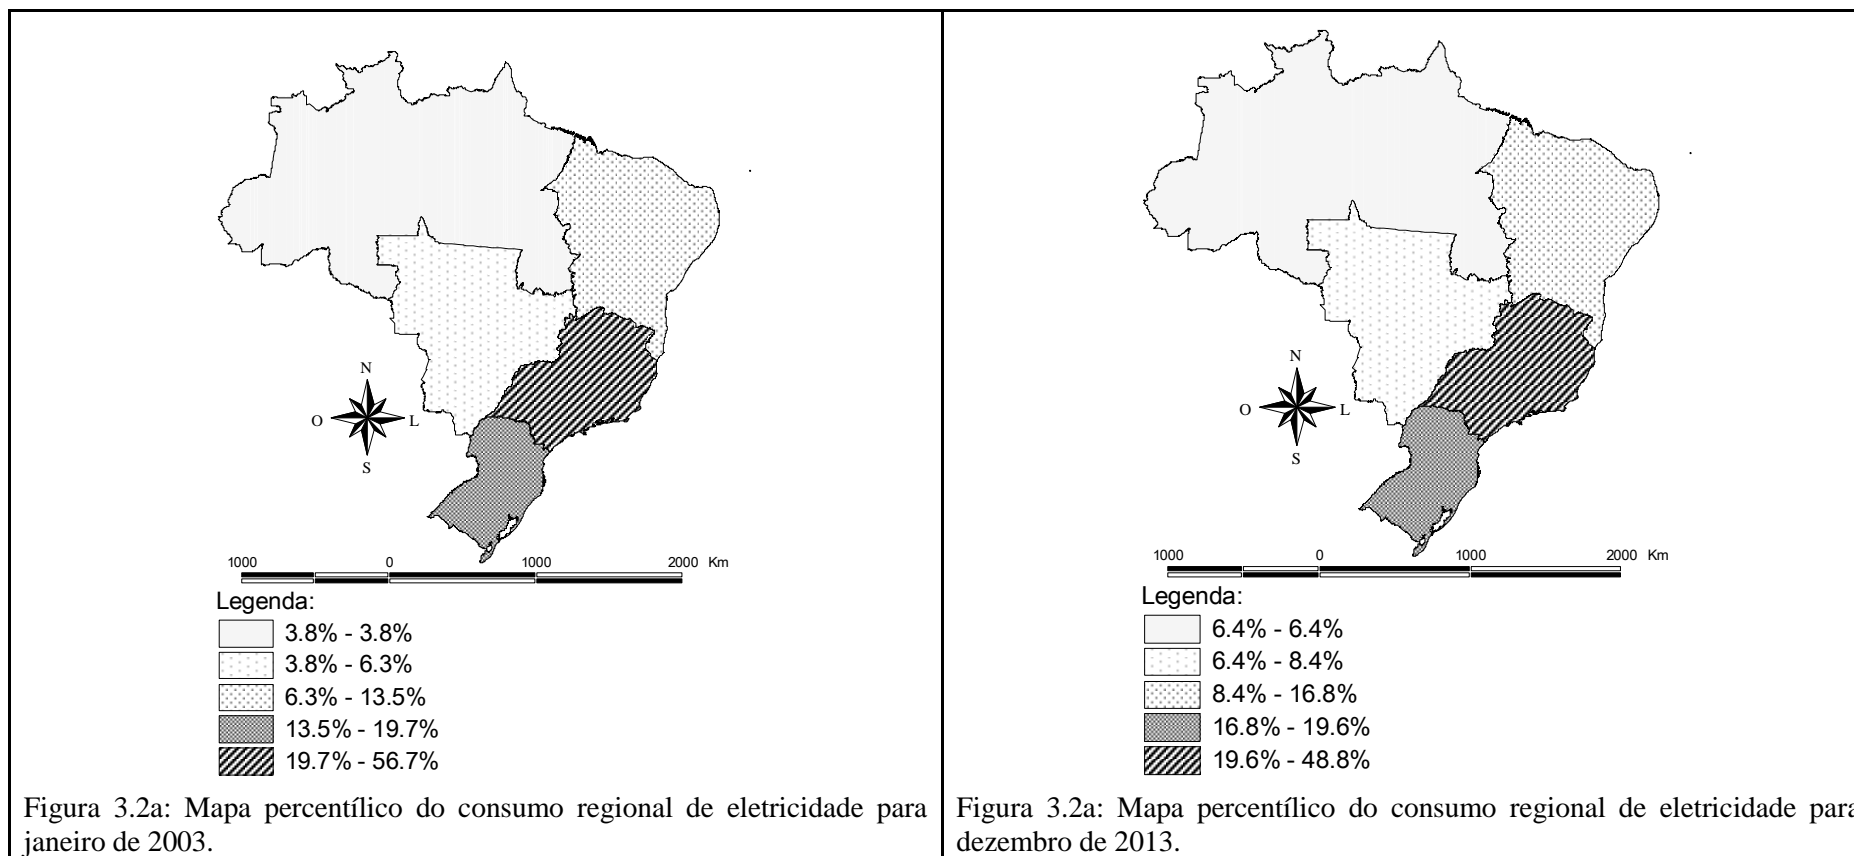
Variável	Observações	Média	Desvio-Padrão	Mínimo	Máximo
<i>CONS_CO</i>	132	1765,32	300,01	1331,66	2430,10
<i>CONS_NE</i>	132	3809,90	630,67	2617,57	5084,28
<i>CONS_N</i>	132	1236,99	254,19	838,42	1815,18
<i>CONS_SE</i>	132	12157,43	851,37	10572,53	13810,56
<i>CONS_S</i>	132	4728,33	453,81	3778,66	5874,21
<i>RESID_CO</i>	132	4606721	595837	3679179	5718941
<i>RESID_NE</i>	132	15597021	2355368	10296757	19504843
<i>RESID_N</i>	132	3432692	556314	2532148	4449536
<i>RESID_SE</i>	132	28957601	2324522	24734796	33240720
<i>RESID_S</i>	132	9796441	1005403	6895799	11637771
<i>TARIFA_CO</i>	132	346,10	44,38	223,78	458,12
<i>TARIFA_NE</i>	132	330,46	54,76	186,65	413,24
<i>TARIFA_N</i>	132	340,37	46,52	228,56	441,00
<i>TARIFA_SE</i>	132	344,19	46,35	218,99	413,19
<i>TARIFA_S</i>	132	315,31	48,49	195,86	395,96
<i>PIB_CO</i>	132	124,57	15,42	100,84	149,28
<i>PIB_NE</i>	132	127,12	16,97	97,87	154,55
<i>PIB_N</i>	132	132,10	16,78	100,68	158,07
<i>PIB_SE</i>	132	125,20	15,41	98,00	147,73
<i>PIB_S</i>	132	120,98	13,70	100,31	157,74

Fonte: Elaboração Própria.



No período analisado, o consumo total de eletricidade aumentou 44%, de 365,873.10 GWh em 2003 para 526,166.72 GWh em 2013. A distribuição espacial do consumo de eletricidade regional brasileiro é descrito na Figura 3.2. Por intermédio desta figura, fica evidente que as regiões Sul e Sudeste apresentaram altos níveis de consumo de eletricidade contrapondo os baixos níveis de consumo das regiões Norte e Centro-Oeste, sugerindo um padrão espacial de dissimilaridade entre o consumo regional de eletricidade no Brasil. Entretanto, vale apontar que a região Sudeste perde participação no consumo total de eletricidade no país (de 67% para 49%), enquanto houve um aumento no consumo nas demais regiões (Sul: de 9,5% para 20%; Norte: de 4% para 6%; Nordeste: de 13,5% para 17% e Centro-Oeste: 6% para 8%). Esse aumento nas regiões Norte, Nordeste e Centro-Oeste pode ser atribuído à melhora econômica e ao Programa “Luz para Todos”, cujo objetivo é levar acesso à eletricidade a todos os domicílios no Brasil, um dos pilares do atual modelo institucional do SEB implementado em 2004.

**Figura 3.2:** Mapa percentílico do consumo regional de eletricidade para os períodos inicial (janeiro de 2003) e final (dezembro de 2013) da análise.



**Fonte:** Elaboração Própria.



Com o objetivo de computar a estatística  $I$  de Moran para investigar a dependência espacial no consumo de eletricidade regional no Brasil, de acordo com o procedimento descrito na seção 3.2.1, é necessário definir uma matriz de ponderação espacial  $W$ . Com o intuito de tornar menos arbitrária a escolha da matriz  $W$ , três tipos de matrizes foram testados, “torre”, “rainha” e “ $n$  vizinhos mais próximos” ( $n = 1, 2$  e  $3$ ). A matriz de contiguidade do tipo “torre” foi a matriz escolhida, pois apresentou o maior valor absoluto da estatística  $I$  de Moran estatisticamente significativa (BAUMONT, 2004). Neste tipo de matriz, duas regiões são vizinhas se compartilham a mesma fronteira física e, assim, parece apropriada para representar as interações espaciais no SIN. Os pesos espaciais em  $W$  são definidos como:

$$w_{ij} = \begin{cases} 1, & \text{se as regiões } i \text{ e } j \text{ são contíguas} \\ 0, & \text{caso contrário} \end{cases} \quad (3.7)$$

Vale ressaltar que uma das propriedades das matrizes de pesos espaciais é que nenhuma região é contígua a si própria, logo, a diagonal principal da matriz  $W$  é nula. A vantagem de utilizar matrizes de pesos espaciais de contiguidade deve-se ao fato de definir com mais facilidade contiguidade de ordens superiores. Por outro lado, a principal desvantagem deste tipo de matriz reside no fato de que não é garantida uma conectividade balanceada, ou seja, pode haver uma região com muitos vizinhos e uma região com poucos vizinhos. Entretanto, cabe salientar que no caso das regiões brasileiras, cada região tem, pelo menos, dois vizinhos e não sofre do problema de “ilhas”<sup>7</sup>.

A Tabela 3.2 apresenta os diferentes valores da estatística  $I$  de Moran uni e bivariado para o painel de dados. Os resultados confirmam a existência de dependência espacial no consumo regional de eletricidade no período analisado. Os valores negativos e estatisticamente significativos do  $I$  de Moran sugerem um padrão de dissimilaridade em todos os casos. No contexto univariado (Tabela 3.2a), regiões com maior consumo de eletricidade tendem a ser circunvizinhas de regiões com menores níveis de consumo e vice-versa.

Um padrão espacial de dissimilaridade também é observado no contexto bivariado (Tabela 3.2b). O mesmo tipo de dependência espacial foi encontrado por Tian *et al.*

---

<sup>7</sup> São chamadas “ilhas” aquelas regiões que não possuem fronteira geográfica com nenhuma outra localidade.

(2014) em um estudo sobre consumo de energia residencial (eletricidade e gás) nas áreas urbanas de Londres. Nos Estados Unidos, Wang e Wang (2011) encontraram evidências de que a interação espacial de biomassa está relacionada com a localização geográfica, preço da biomassa e a renda pessoal total disponível. Por outro lado, Long *et al.* (2016) encontraram dependência espacial positiva e características aglomerativas na produtividade industrial do carbono nas províncias da China.

**Tabela 3.2:** Estatística *I* de Moran uni e bivariada para o consumo de eletricidade regional para um painel de dados.

<i>I</i> de Moran univariado (a)			<i>I</i> de Moran bivariado (b)		
Variável	Coefficiente	<i>p</i> -valor	Variável	Coefficiente	<i>p</i> -valor
<i>CONS</i>	-0,07	0,00	<i>CONS x RESID</i>	-0,09	0,00
<i>RESID</i>	-0,11	0,00	<i>CONS x TARIFA</i>	-0,15	0,00
<i>TARIFA</i>	-0,32	0,00	<i>CONS x IBCR</i>	-0,16	0,00
<i>PIB</i>	0,00	0,87			

**Fonte:** Elaboração Própria.

O padrão de dispersão encontrado entre Consumo e IBCR sugere que as regiões com baixo consumo de eletricidade possuem vizinhos com alto PIB. Um fato interessante é que existe um padrão espacial de dissimilaridade entre o consumo regional de eletricidade e a tarifa média, implicando que as regiões com maior consumo de eletricidade pagam tarifas mais baixas, talvez devido às economias de escala. Em linhas gerais, o padrão de dissimilaridade encontrado por este ensaio evidencia as disparidades regionais existentes no Brasil.

Com o intuito de comparar, validar e dar robustez à estatística *I* de Moran proposta para dados em painel, a estatística *I* de Moran foi computada para cada unidade seccional. A Tabela 3.3 explicita os valores estatisticamente significativos da autocorrelação global univariada (*I* de Moran), considerando o nível de significância de 10%, na variável consumo de energia elétrica regional para as unidades seccionais no início e fim da série em questão<sup>8</sup>.

Os resultados da estatística *I* de Moran para cada *cross section* confirmam a existência de autocorrelação espacial negativa nos dados de consumo regional de energia

<sup>8</sup> Por questões de espaço, a Tabela 3.2 apresenta somente as estatísticas *I* de Moran global univariada para as *cross sections* para os meses dos anos de 2003 e 2013. Entretanto, vale dizer que foi realizado o teste em todos os anos confirmando a evidência de dependência espacial nos dados de consumo de energia elétrica regional.

elétrica. Os resultados para cada unidade seccional validam a estatística *I* de Moran proposta por este ensaio.

**Tabela 3.3:** Autocorrelação espacial global univariada para as *cross sections* de consumo regional de energia elétrica.

Variáveis/Ano	Coefficiente	<i>p</i> -valor
<i>CONS</i> JAN03	-0,0826	0,09
<i>CONS</i> MAR03	-0,0886	0,09
<i>CONS</i> ABR03	-0,0901	0,09
<i>CONS</i> JUL03	-0,0922	0,08
<i>CONS</i> OUT03	-0,1043	0,09
<i>CONS</i> NOV03	-0,1037	0,09
<i>CONS</i> DEZ03	-0,0963	0,08
<i>CONS</i> JAN13	-0,0668	0,05
<i>CONS</i> FEV13	-0,0514	0,06
<i>CONS</i> MAR13	-0,0606	0,05
<i>CONS</i> ABR13	-0,0780	0,06
<i>CONS</i> MAI13	-0,0743	0,06
<i>CONS</i> JUN13	-0,0773	0,06
<i>CONS</i> JUL13	-0,0727	0,05
<i>CONS</i> AGO13	-0,0669	0,05
<i>CONS</i> SET13	-0,0804	0,05
<i>CONS</i> OUT13	-0,0869	0,06
<i>CONS</i> NOV13	-0,0808	0,06
<i>CONS</i> DEZ13	-0,0750	0,08

**Fonte:** Elaboração Própria.

### 3.4 CONSIDERAÇÕES FINAIS E IMPLICAÇÕES POLÍTICAS

São conhecidas na literatura econométrica as vantagens da estrutura de painel de dados para análise de fenômenos socioeconômicos. Os analistas regionais passaram a utilizar em suas análises dados em painel de modo a beneficiar-se de tais vantagens, uma vez que, por meio dessa estrutura de dados, é possível acompanhar o atributo estudado no espaço e ao longo do tempo. Entretanto, a medida amplamente utilizada para verificar a existência (ou não) da interação entre os diversos agentes no espaço, a estatística *I* de Moran, não contempla a dinâmica temporal o que, por conseguinte, limita a captação da magnitude da dependência espacial para todo o painel de dados.

Diante disso, o presente ensaio estendeu a estatística proposta por Moran (1948) para a estrutura de painel de dados permitindo o acompanhamento da interação entre os diversos atributos no tempo e no espaço conjuntamente além de minimizar o tempo dispendido para a verificação de tal dependência espacial pelo pesquisador.

Uma aplicação empírica foi realizada para a cinco regiões brasileiras com os dados de consumo de energia elétrica, número de residências, tarifa média e PIB no período mensal de janeiro de 2003 a dezembro de 2013. Por meio da estatística *I* de Moran univariada foi possível verificar a existência de dependência espacial negativa ao longo de todo o período observado para todas as variáveis, exceto para o PIB que não se mostrou significativo. No que tange ao contexto bivariado, foi evidenciado o padrão de dissimilaridade do consumo de energia elétrica regional com as demais variáveis macroeconômicas demonstrando que regiões com alto consumo de energia elétrica são circunvizinhas a regiões com baixa tarifa média de energia elétrica, reduzido número de residências, de baixo PIB e vice versa.

Em termos de política pública, os resultados encontrados evidenciam a necessidade de abordar a questão das disparidades regionais no Brasil, de modo a promover iniciativas governamentais com vistas à equidade regional em relação ao acesso à energia elétrica e tarifas mais módicas.

A existência de dependência espacial no consumo regional de eletricidade no Brasil confirma, ainda, a necessidade de incluir interações espaciais nas previsões de demanda de eletricidade por parte dos agentes do SEB. A omissão dessa dependência nos modelos de previsão, atualmente utilizados pelas Distribuidoras, pode gerar estimativas

enviesadas e ineficientes. Previsões menos acuradas, possivelmente, implicam em custos mais altos, tarifas menos módicas, perda de eficiências produtiva, alocativa e ambiental, além de menor segurança para o Sistema Elétrico Brasileiro.

Os ensaios dois e três desta tese demonstrarão como é possível modelar a dependência espacial existente na demanda de eletricidade regional nas previsões de demanda. Nestes ensaios serão comparados os modelos que incorporam a dependência espacial em sua modelagem com os modelos que não são capazes de modelar a dependência espacial existente de modo a averiguar a acurácia de previsão. A hipótese a ser testada é a de que os modelos espaciais possuem melhor *performance* preditiva e, assim, são os mais indicados para prever a demanda de energia elétrica regional no Brasil.

#### 4. ENSAIO 2 – PREVISÃO DE DEMANDA DE ELETRICIDADE NO BRASIL: UMA COMPARAÇÃO ENTRE OS MODELOS ARIMA E ARIMASp

**Resumo:** O objetivo deste ensaio foi avaliar a importância da inclusão da dimensão espacial na especificação de modelos de previsão de demanda de eletricidade regional no Setor Elétrico Brasileiro. Um exercício empírico de comparação entre o modelo auto regressivo integrado e de média móvel (ARIMA) e o modelo auto regressivo integrado e de média móvel espacial (ARIMASp) foi realizado com dados de consumo de eletricidade da região Sudeste no período mensal de 2003 a 2013. O modelo ARIMASp, que considera o espaço em sua modelagem, obteve melhor *performance* preditiva por ter sido o modelo que apresentou menor MAPE de previsão. Em termos quantitativos, o modelo ARIMASp sobrestimou a demanda total de eletricidade no período analisado em 214,68 GWh enquanto a previsão do modelo ARIMA apresentou um déficit de 1.317,30 GWh. A partir desses resultados, o modelo ARIMASp levou a uma previsão custo-efetiva de tal modo que as “Distribuidoras do Sudeste” não sofreriam qualquer perda financeira. Portanto, a interação espacial possui um papel importante na demanda de energia elétrica no Brasil e deveria ser considerada pelos agentes para melhorar as previsões de demanda de eletricidade no SEB.

**Palavras chave:** Previsão de demanda de energia elétrica; Setor Elétrico Brasileiro; Modelo espaço-temporal; ARIMASp

**Abstract:** The objective of this paper was to evaluate the importance of including the spatial dimension in the specification of forecasting models of regional electricity demand in the Brazilian Electricity Sector. An empirical comparison between the integrated autoregressive and moving-average models (ARIMA) and the integrated auto regression and spatial moving average model (ARIMASp) was performed with data on the electricity consumption from the Southeast region in the monthly period from 2003 to 2013. The model ARIMASp, which considers the space in its modeling, obtained better predictive performance because it was the model with the lowest MAPE for the forecast. In quantitative terms, the ARIMASp model overestimated the electricity demand by 214.68 GWh while the ARIMA forecast presented a deficit of 1,317.30 GWh. From these results, the ARIMASp model led to a cost effective forecast, so that Southeast Utilities would not suffer any financial loss. From these results, the ARIMASp model led to a cost-effective forecast so that the Utilities in the Southeast would not suffer any financial loss. Therefore, spatial interaction plays an important role in the electricity demand in Brazil and should be considered by agents to improve the electricity demand forecasting in Brazilian Electricity Sector.

**Keywords:** Electricity demand forecasting; Brazilian Electricity Sector; Spatio-temporal models; ARIMASp

## 4.1 INTRODUÇÃO

O Setor Elétrico Brasileiro (SEB) passou por duas grandes reformas que culminaram no atual modelo institucional do Setor. O Projeto de Reestruturação do Setor Elétrico Brasileiro (PRSEB), primeira fase da reforma do SEB iniciada em 1994, visava alcançar eficiência e autonomia econômica, seguindo uma tendência mundial da indústria de energia elétrica. Os principais resultados do PRSEB foram a desverticalização dos segmentos de geração, transporte (transmissão e distribuição) e comercialização, privatização do setor (especialmente no segmento de distribuição) e a criação da Agência Nacional de Energia Elétrica (ANEEL) (PIRES, 1999). Apesar das reformas implementadas, o PRSEB não garantiu expansão suficiente do setor, levando o Brasil a um racionamento de energia e *blackouts* em 2001.

Dada a incapacidade do PRSEB em satisfazer a demanda de eletricidade, a segunda fase da reforma, implementada em 2004, baseou-se em três tipos de eficiências como diretrizes: a universalização da oferta, a segurança do sistema e a modicidade tarifária. Para alcançar essas metas, a reforma utilizou mecanismos centralizados e de mercado, no que foi chamado de abordagem regulatória “híbrida”. O mercado consumidor foi dividido em duas categorias: uma chamada Ambiente de Contratação Regulada (ACR) e outra denominada Ambiente de Contratação Livre (ACL). O ACL é composto por consumidores “livres” - que podem comprar eletricidade de qualquer ofertante, desde que possuam uma carga igual ou superior a 3 MW a qualquer nível de tensão -, comercializadores, produtores independentes, autoprodutores e importadores. Por outro lado, o ACR é composto pelas Distribuidoras que adquirem energia elétrica para atender seu mercado - “consumidores cativos” – majoritariamente por meio de leilões públicos promovidos pela ANEEL e pela Câmara de Comercialização de Energia Elétrica (CCEE) (SOUZA e LEGY, 2010).

Considerando que a eletricidade não pode ser armazenada de maneira economicamente viável, deve haver constante equilíbrio entre oferta e demanda de eletricidade. No ACR, a responsabilidade pela definição do nível de demanda a ser contratado nos leilões cabe às Distribuidoras. Elas devem ter contratos de oferta que satisfaçam a demanda total de seus mercados ou, caso contrário, sofrem penalidades. Em outras palavras, se suas previsões de demanda forem erradas - acima de 3% ou abaixo da demanda observada -, as Distribuidoras pagam uma multa. A racionalidade por trás desse

procedimento é que as Distribuidoras estão em melhor posição para fazer previsões acuradas pelo fato de conhecerem seus mercados melhor do que qualquer outro agente. No entanto, para fazer um uso eficiente deste conhecimento e garantir lucro, segurança do sistema, bem como modicidade das tarifas, as Distribuidoras devem possuir as melhores ferramentas de previsão disponíveis.

Assim, a habilidade de fazer boas previsões é, sem dúvida, um dos maiores desafios das Distribuidoras. Na indústria de energia elétrica, previsões mais precisas podem significar a diferença entre uma solução custo-efetiva e outras que não são produtivas, alocativas e ambientalmente eficientes. A eficiência alocativa é essencial para garantir o acesso à eletricidade, enquanto a eficiência ambiental garante uma produção de energia ambientalmente sustentável (BLUM e LEGEY, 2012). Em adição, a eficiência produtiva garante que os desperdícios do setor elétrico sejam minimizados permitindo menores custos de produção e, conseqüentemente, tarifas mais módicas. Garantindo estes três tipos de eficiência há impacto direto sobre a segurança energética da economia. Em outras palavras, quando o sistema elétrico é produtivo, alocativo e ambientalmente eficiente, há também um alto nível de segurança.

Dada a importância de previsões de demanda acuradas para a segurança do sistema, o presente ensaio propõe um método de previsão univariado de fácil utilização capaz de fornecer previsões mais precisas ao modelar a dependência espacial existente no SEB, conforme verificado no primeiro ensaio desta tese. Tal método será chamado de modelo auto regressivo integrado e de média móvel espacial (ARIMASp). A capacidade preditiva do ARIMASp será comparada com o modelo auto regressivo integrado e de média móvel (ARIMA) por meio do MAPE (*Mean Absolute Percentage Error*)<sup>9</sup> de previsão.

O objetivo desta comparação é verificar se o modelo que contempla a dinâmica espaço-temporal em suas previsões (ARIMASp) possui melhor acurácia de previsão do que o modelo que considera somente a dinâmica temporal (ARIMA). Diante disso, este ensaio contribui para a literatura de previsão do setor de energia, uma vez que, como evidenciado na revisão bibliográfica desta tese, o uso da econometria espacial no setor de energia tem sido incipiente no mundo e, principalmente no Brasil onde não foi encontrado

---

<sup>9</sup> Em livre tradução: Erro Percentual Absoluto Médio.



nenhum estudo que utiliza tal ferramenta para previsão de demanda de eletricidade. Cabe ressaltar que o ARIMASp pode ser utilizado em outras áreas do setor elétrico onde previsões acuradas são importantes como é o caso de previsão de vazões.

Este ensaio está organizado em três seções, além desta Introdução. A segunda seção especifica a estratégia empírica descrevendo os modelos ARIMA e ARIMASp, bem como a base de dados utilizada para comparação entre os dois modelos. Cabe à terceira seção apresentar o exercício de comparação da capacidade preditiva dos modelos ARIMA e ARIMASp. Por fim, cabe à quarta seção tecer algumas conclusões e as implicações políticas do ensaio.

## 4.2 ESTRATÉGIA EMPÍRICA

### 4.2.1 Especificação dos Modelos Univariados para a Previsão de Demanda de Eletricidade no Brasil

Os modelos de séries temporais usando a abordagem de Box-Jenkins foi proposta por esses autores em 1970. Essa abordagem tem sido amplamente utilizada na literatura por causa da simplicidade de estimação, interpretação dos parâmetros e sua *performance* preditiva. A maioria das séries de tempo podem ser descritas como um modelo auto regressivo e de média móvel (ARMA) (HAMILTON, 1994; ENDERS, 2010). A série temporal estacionária  $Y_t$  segue um  $ARMA(p, q)$  se:

$$Y_t - \phi_1 Y_{t-1} - \dots - \phi_p Y_{t-p} = \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} \quad (4.1)$$

Onde  $Y_t$  é uma série temporal;  $\varepsilon_t$  é um ruído branco. A Equação (4.1) pode ser representada por um polinômio auto regressivo,  $(1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p)$  e um polinômio de média móvel,  $(1 + \theta_1 L + \theta_2 L^2 + \dots + \theta_q L^q)$ , em que  $L$  é um operador de defasagem. Esses polinômios também podem ser representados por  $\phi(L)$  and  $\theta(L)$ , respectivamente.

Caso as séries sejam estacionárias em diferenças, o modelo auto regressivo integrado de média móvel (ARIMA) é implementado. A série  $Y_t$  é dita seguir um  $ARIMA(p, d, q)$  se:

$$ARIMA(p, d, q): \phi(L)(1 - L)^d Y_t = \theta(L)\varepsilon_t \quad (4.2)$$

Onde  $d$  é o  $d^{\acute{e}simo}$  operador de diferença. Os parâmetros do modelo ARIMA podem ser estimados por *Ordinary Least Squares* (OLS).

Para propósito de comparação, o modelo ARIMASp baseia-se na estrutura proposta por Box e Jenkins (1976) com a adição da variável dependente defasada espacialmente utilizada como controle. O objetivo da inclusão dessa covariada consiste em modelar a natureza espaço-temporal da variável dependente. Formalmente, o modelo ARIMASp pode ser descrito como segue:

$$ARIMASp(p, d, q): \phi(L)(1 - L)^d Y_t = \gamma \tilde{Y}_t + \theta(L)\varepsilon_t \quad (4.3)$$

Onde  $\tilde{Y}_t$  é a defasagem espacial de  $Y_t$ . No caso estudado,  $Y_t$  representa a demanda de eletricidade no tempo  $t$  e  $\tilde{Y}_t$  é a demanda de eletricidade defasada espacialmente na região  $g$ , isto é,  $\tilde{Y}_t = \widehat{CONS}_{gt}$ . Pelo fato de  $\tilde{Y}_t$  ser uma variável endógena, a estimação por OLS não é mais apropriada (ANSELIN, 1988; ANSELIN e BERA, 1998). Diante disso, o método de mínimos quadrados em dois estágios (TSLS) será o método empregado para estimar o ARIMASp. A defasagem temporal do consumo de eletricidade defasado espacialmente  $\widehat{CONS}_{gt-1}$  será o instrumento para a variável endógena  $\widehat{CONS}_{gt}$ .

Cabe ressaltar que este ensaio ajustará os modelos ARIMA e ARIMASp com correção para a sazonalidade além de incluir um termo de tendência de modo a captar a queda no consumo de energia elétrica ocorrida em 2005. De posse dos modelos mais apropriados, uma comparação da *performance* de previsão *out-of-sample* entre os modelos ARIMA e ARIMASp será feita por meio da análise da medida de desempenho de previsão, MAPE, computado como segue:

$$MAPE = \left( \frac{1}{N} \sum_1^N \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right| \right) * 100 \quad (4.4)$$

Em resumo, o processo de especificação e estimação dos modelos é implementado em quatro passos, como segue:

i) Verificação da estacionariedade da série: o teste Dickey-Fuller aumentando (ADF) proposto por Dickey e Fuller (1981) foi calculado para a série de consumo de energia elétrica do Sudeste indicando que a série é não estacionária em nível (possui uma raiz unitária), mas é estacionária em primeira diferença. Sendo assim, ambos os modelos ARIMA e ARIMASp, são integrados de ordem 1 ( $d = 1$ );

ii) Construção do modelo: para especificar a ordem do modelo será empregado o método *stepwise* para selecionar as defasagens dos polinômios auto regressivos e de média móvel ( $p, q$ );

iii) Escolha e Validação do modelo: a escolha do modelo apropriado levará em consideração os diagnósticos dos resíduos, os critérios de informação (AIC e BIC) e parcimônia;

iv) Comparação da *performance* preditiva: os modelos ARIMA e ARIMASp serão utilizados para previsão com vistas a compará-los em termos da acurácia da previsão. Para avaliar o modelo que fornecerá a melhor previsão, será utilizado o MAPE de previsão.

#### 4.2.2 Base de Dados

A variável dependente utilizada no exercício empírico de comparação da *performance* preditiva entre os modelos ARIMA e ARIMASp refere-se a uma série temporal mensal do consumo de eletricidade da região Sudeste (SE) iniciada em janeiro de 2003 e finalizada em dezembro de 2013. Portanto, a série temporal  $Y_t$  possui 132 observações e tem como fonte dos dados o Sistema de Apoio da Decisão (SAD) da ANEEL.

A variável endógena consumo de eletricidade defasado espacialmente ( $\widehat{CONS}_{gt}$ ), capaz de modelar a interação espaço-temporal no modelo ARIMASp, foi construída organizando a variável  $WCONS_{kt}$  empilhada por data (*stacked by date*) – a mesma variável do ensaio 1 – por região ao longo do tempo. Esse procedimento gerou uma série temporal  $\widehat{CONS}_{gt}$  para cada uma das cinco regiões brasileiras. Pelo fato de o exercício empírico ser aplicado ao Sudeste brasileiro, a variável  $\widehat{CONS}_{gt}$  refere-se ao consumo de eletricidade defasado espacialmente da região Sudeste.

A razão pela escolha da região Sudeste (SE) é devido ao fato de o Sudeste ser o mercado consumidor de eletricidade mais importante do Brasil além de ser a região com maior dinamismo econômico. Uma análise similar pode ser estendida para as demais regiões do Brasil de forma análoga.

#### 4.4 UMA COMPARAÇÃO ENTRE OS MODELOS ARIMA E ARIMASp

Encontrar uma abordagem e modelo apropriados é crucial para a tomada de decisões custo-efetivas no setor elétrico (HAHN *et al.*, 2009). No caso do SEB, parece importante considerar a dependência espacial para aumentar a acurácia das previsões de demanda de eletricidade, como sugerido pelos resultados do ensaio 1. Entretanto, o uso de modelos espaço-temporais é incipiente no setor elétrico tanto nacional quanto internacionalmente. A maioria das abordagens utilizadas para previsão de demanda de eletricidade consideram somente a dependência temporal.

Visando verificar a importância da inclusão da dependência espacial nos modelos de previsão de demanda de eletricidade, Ohtsuka *et al.* (2010) compararam um modelo autorregressivo espacial – SAR-ARMA (1,1) – com o modelo ARMA (1,1). Os resultados do estudo mostraram que o SAR-ARMA (1,1) teve desempenho de previsão superior ao ARMA (1,1) para o Japão. Contudo, Ohtsuka e Kakamu (2013), usando a mesma base de dados de Ohtsuka *et al.* (2010), concluíram que a *performance* preditiva de um VAR (1) foi superior ao do modelo SAR-ARMA (1,1).

Para avaliar como a dependência espacial pode afetar a acurácia de previsão de energia elétrica no SEB, uma comparação empírica entre os modelos ARIMA e ARIMASp foi realizada utilizando os dados de consumo de energia elétrica da região SE. Os resultados dos modelos mais apropriados estão reportados na Tabela 4.1.

Nota-se que ambos os modelos são satisfatórios, pois apresentam os sinais esperados e os resíduos não possuem autocorrelação. Mais especificamente, pode-se inferir sobre a existência de uma correlação temporal forte devido aos altos valores dos componentes autorregressivos (AR). Em relação ao coeficiente de média móvel (MA), é possível inferir que eventos aleatórios e inesperados diminuíram a demanda corrente de energia elétrica do Sudeste.

**Tabela 4.1:** Resultados da estimação dos modelos ARIMA e ARIMASp<sup>(a)</sup>

Variáveis	ARIMA	ARIMASp
$\widehat{CONS}_{gt-1}$	—	0,43*** (0,111)
AR(1)	0,78*** (0,074)	0,91*** (0,052)
AR(3)	-0,16** (0,080)	—
AR(5)	0,20*** (0,072)	—
MA(1)	-0,98*** (0,019)	-0,41*** (0,168)
Adjusted R <sup>2</sup>	0,17	0,87
AIC	3,70	3,62
BIC	3,71	3,63
Diagnóstico dos resíduos		
Autocorrelação serial	Ausente	Ausente

**Fonte:** Elaboração própria.

**Notas:** <sup>(a)</sup>Erros padrão entre parênteses.

\*\*\* p<0,01; \*\* p<0,05; \* p<0,10

A significância do parâmetro de defasagem espacial no modelo ARIMASp (1,1,1) confirma a hipótese de que o consumo de eletricidade do Sudeste brasileiro é espacialmente dependente ao longo do tempo. Em outras palavras, a demanda de energia elétrica da região Sudeste é positivamente influenciada pela demanda de eletricidade das demais regiões brasileiras.

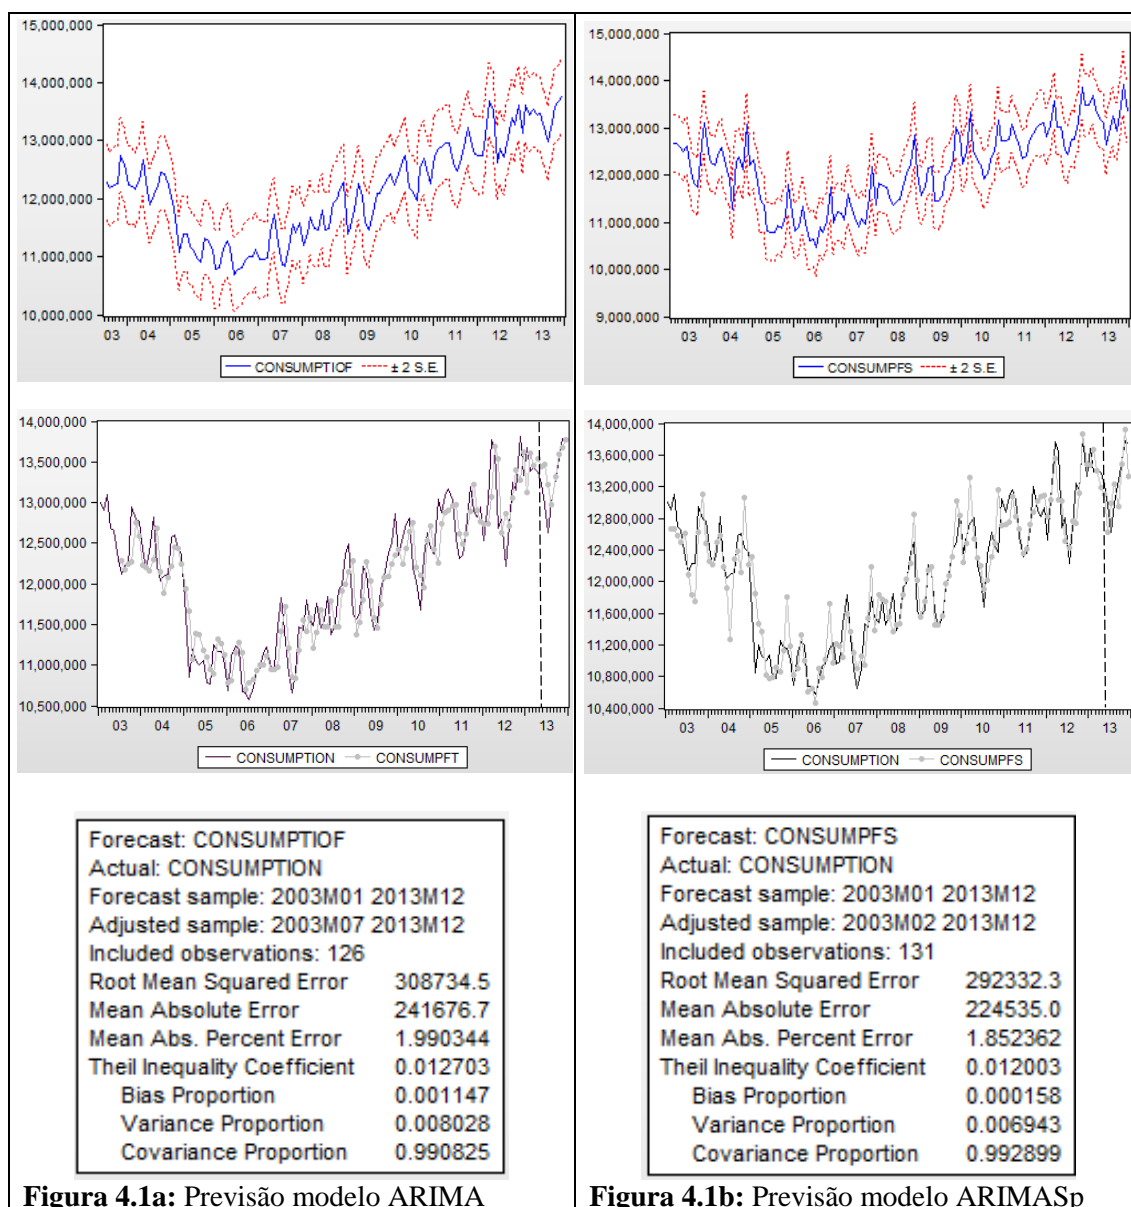
No que se refere à qualidade de ajuste dos dois modelos, o modelo ARIMASp (1,1,1) possui melhor qualidade de ajuste que o modelo ARIMA (5,1,1), pois apresentou os menores critérios de informação AIC e BIC. Vale observar que o modelo que o ARIMASp (1,1,1) é o modelo mais parcimonioso.

Comprovada a inexistência de autocorrelação serial e assumindo normalidade assintótica, os modelos foram utilizados para analisar a capacidade preditiva *out-of-sample*, na qual as últimas seis observações foram retiradas da amostra (julho de 2013 a dezembro de 2013). O objetivo da previsão foi verificar se o ARIMASp foi capaz de reduzir o MAPE em relação ao ARIMA. A Figura 4.1 resume as projeções de demanda de energia elétrica com um horizonte de previsão seis meses à frente e seus respectivos diagnósticos.

Analisando a Figura 4.1, é possível perceber que o modelo ARIMASp é, de fato, capaz de melhorar a *performance* preditiva da demanda de eletricidade para a região Sudeste, visto que possui menor MAPE. Comparando as previsões dos modelos ARIMA e ARIMASp em termos de demanda total de eletricidade no Sudeste no período analisado, o modelo ARIMASp superestimou a demanda de eletricidade em 214,68 GWh. Em contrapartida, a previsão por meio do modelo ARIMA apresentou déficit de 1.317,30 GWh. A partir desses resultados, pode-se afirmar que a previsão do modelo ARIMASp foi custo-efetiva, uma vez que a “Distribuidora Equivalente do Sudeste” não sofreria qualquer prejuízo financeiro. Como a demanda adicional contratada (0,014%) estaria abaixo do limite de 3% definido pelo atual modelo institucional, os custos da sobrecontratação poderiam ser repassados aos consumidores. Por outro lado, se o modelo ARIMA fosse utilizado, as “Distribuidoras Equivalentes” pagariam uma multa por não conseguir suprir a demanda observada. Esse déficit de energia elétrica causaria perdas econômicas e *blackouts* nas áreas de concessão da “Distribuidora”.

Estes resultados confirmam a hipótese de que os modelos espaço-temporais melhoram a capacidade preditiva e, assim, podem ser úteis para a previsão de demanda de energia elétrica no Brasil.

**Figura 4.1:** Resultados da Previsão de Demanda de Eletricidade do Sudeste Brasileiro.



**Figura 4.1a:** Previsão modelo ARIMA

**Figura 4.1b:** Previsão modelo ARIMASp

Fonte: Elaboração própria.

## 4.5 CONCLUSÕES E IMPLICAÇÕES POLÍTICAS

Este ensaio teve como o objetivo avaliar a importância da inclusão da dimensão espacial na especificação de modelos de previsão de demanda de eletricidade regional no Setor Elétrico Brasileiro (SEB). Para atingir o objetivo proposto foi realizado um exercício empírico comparando os modelos com e sem a modelagem da interação espacial.

O modelo ARIMASp, que considera o espaço em sua modelagem, obteve melhor *performance* preditiva por ter sido o modelo que apresentou menor MAPE de previsão

*out-sample*. Em termos quantitativos, o modelo ARIMASp sobrestimou a demanda total de eletricidade no período analisado em 214,68 GWh enquanto a previsão do modelo ARIMA apresentou um déficit de 1.317,30 GWh. A partir desses resultados, o modelo ARIMASp levou a uma previsão custo-efetiva de tal modo que as “Distribuidoras do Sudeste” não sofreriam qualquer perda financeira.

Portanto, este ensaio demonstrou que a interação espacial possui um papel importante na demanda de energia elétrica no Brasil. Este resultado confirma que os modelos espaço-temporais podem melhorar as previsões de demanda de eletricidade no SEB. Além disso, evidenciam que a consideração das correlações espaciais na previsão de demanda de eletricidade é fundamental para alcançar a segurança do sistema, objetivo do atual modelo institucional do SEB.

Como implicações políticas, esses modelos poderiam ser testados, inicialmente, no âmbito do Programa de Pesquisa e Desenvolvimento Tecnológico do Setor de Energia Elétrica da Agência Nacional de Energia Elétrica (ANEEL). Estes modelos teriam um papel importante entre as ferramentas de previsão sugeridas pela ANEEL, a Empresa Brasileira de Pesquisa Energética (EPE) e o Operador Nacional do Sistema Elétrico (ONS) para os agentes do SEB. Em outras palavras, a presente lista de métodos empregados pela EPE, bem como as ferramentas recomendadas pela ANEEL e pelo ONS, deveriam ser revisadas de modo a considerar, além da dinâmica temporal, a interação espacial entre as regiões e entre os agentes do SEB.

A consideração da dinâmica espacial também pode ser importante fator para melhorar a acurácia das previsões em outras áreas do SEB como, por exemplo, previsões de vazões, da oferta de energia entre outros.

Como agenda de pesquisa futura, a *performance* preditiva de modelos multivariados também será comparada utilizando os modelos de painel dinâmico, modelo Durbin espacial dinâmico (SDM dinâmico) e modelo de defasagem espacial e erro autorregressivo espacial com componente autorregressivo (SAC-AR(1)).



## 5. ENSAIO 3 – PREVISÃO DE DEMANDA DE ELETRICIDADE NO BRASIL: UMA COMPARAÇÃO ENTRE OS MODELOS MULTIVARIADOS PAINEL DINÂMICO, SDM DINÂMICO E SAC-AR(1)

**Resumo:** O setor residencial é o segundo maior demandante de energia elétrica no Brasil. Diante da importância desse setor, este estudo objetivou ajustar três modelos para prever a demanda regional de eletricidade, assim como estimar as respectivas elasticidades no período mensal de 2004 a 2014. Foi confirmada a necessidade de modelar a dependência espacial existente, sendo o SDM dinâmico o modelo com melhor *performance* preditiva. A alta inércia temporal verificada no consumo regional indica que as residências brasileiras possuem hábitos de consumo relativamente estáveis. Por outro lado, a demanda de eletricidade mostrou-se pouco sensível em relação ao preço e a renda. Assim, políticas de aumento das tarifas residenciais terão um efeito inexpressivo sobre a conservação de energia elétrica. Já programas de acesso à eletricidade e legalização do consumo impactam substancialmente a demanda de energia elétrica, como apontado pela elasticidade referente ao número de unidades conectadas à rede. Devido às mudanças climáticas globais, a temperatura tornou-se um importante *driver* para os agentes do setor elétrico planejarem as variações na demanda. No caso brasileiro, o aumento da demanda de eletricidade ficará compreendido entre 0,90% e 1,49% como consequência do aquecimento global. Por fim, a presença de *spillovers* espaciais sugerem a existência de interação entre regiões vizinhas resultando em padrões aglomerativos de demanda regional de eletricidade residencial.

**Palavras-chave:** Demanda regional de Eletricidade; Previsão de demanda; Elasticidade; Modelos espaço-temporais

**Abstract:** Households are the second largest consumer of electricity in Brazil. Given its significance the forecast of electricity regional demand of this sector as well as the estimation of the respective elasticities are of paramount importance. This study aims to adjust three models to predict households' electricity demand using monthly data for the period from 2004 to 2014. The need to model existing spatial dependence was confirmed, and the dynamic SDM was the model with better predictive performance. The high temporal inertia observed in regional consumption indicates that Brazilian households have relatively stable consumption habits. On the other hand, electricity demand shows little sensitivity to price and income. Thus, policies to increase household tariffs should have limited effect on the conservation of electricity. Programs for increasing electricity access and load curve smoothing have a substantial impact on demand, as indicated by the elasticity relative to the number of units connected to the grid. Due to global climate change, temperature has become an important driver for electricity sector agents to plan for variations in demand. In the Brazilian case, the increase in electricity demand will be between 0.90% and 1.49% because of global warming. Finally, the presence of spatial spillovers suggests the existence of interaction between neighbouring regions resulting in clusters of household electricity consumption.

**Keywords:** Electricity regional demand; Demand forecasting; Elasticity; Spatio-temporal models.

## 5.1 INTRODUÇÃO

O Setor Elétrico Brasileiro (SEB) é um sistema hidrotérmico complexo de dimensões continentais e pode ser considerado único no mundo. O Sistema Interligado Nacional (SIN) aumenta a segurança do SEB, pois permite que o sistema opere com sinergia e confiabilidade por meio de trocas regionais de energia (FRANCISCO, 2012). O atual modelo institucional do SEB tem como objetivo a universalização da oferta, a segurança do sistema e a modicidade das tarifas (SOUZA e LEGEY, 2008). Para alcançar esses objetivos, o SEB utiliza abordagem regulatória “híbrida” com mecanismos centralizados e de mercado.

Nesta abordagem, as Distribuidoras possuem importante papel na garantia da segurança do SEB, uma vez que o setor residencial, seu principal mercado consumidor, é o segundo maior demandante de energia elétrica no Brasil. Este setor demanda, aproximadamente, 25% da oferta total de energia elétrica no País, ficando atrás somente do setor industrial cuja demanda corresponde a 37,6% da oferta total de eletricidade (EPE, 2016). No ambiente de contratação regulado (ACR), as Distribuidoras devem realizar contratos de oferta que satisfaçam a demanda total de seus mercados, pois, caso contrário, sofrem penalidades. Assim, as Distribuidoras são responsáveis por manter e melhorar seu planejamento e operação continuamente de modo a manter um equilíbrio entre a oferta e a demanda de eletricidade.

Caso haja desequilíbrio entre oferta e demanda, há ocorrência de *blackouts* de energia elétrica causando perdas econômicas e sociais. Neste contexto, previsões de demanda de energia elétrica têm um papel essencial no planejamento e operação das Distribuidoras e constituem a base para a tomada de decisões deste agente do setor elétrico (GARCÍA-ASCANIO e MATÉ, 2010). Previsões precisas de demanda permitem às Distribuidoras planejar seus contratos futuros de eletricidade e expandir sua rede de distribuição de modo a garantir eficiências produtiva, alocativa e ambiental.

Dada a importância de previsões cada vez mais precisas para o setor elétrico, uma grande variedade de métodos estatísticos tem sido usado para a previsão da demanda. Os modelos de previsão de demanda de eletricidade foram iniciados por Houthakker (1951) e a análise de regressão têm sido a técnica de modelagem mais popular na previsão do consumo de eletricidade. O desenvolvimento e aperfeiçoamento contínuos das

ferramentas estatísticas apropriadas são fundamentais para fornecer técnicas de previsão de demanda cada vez mais precisas. Atualmente, as Distribuidoras usam vários métodos de previsão para estimar sua demanda de eletricidade, como exemplo, regressão múltipla (HOUTHAKKER, 1951; ANDERSON, 1973; ZHOU e TENG, 2013), amortecimento exponencial (CHRISTIAANSE, 1971; EL-KEIB *et al.*, 1995; INFELD e HILL, 1998), modelo ARIMA (ELRAZAZ E MAZI, 1989; JUBERIAS *et al.*, 1999) modelos VAR/VEC (MODIANO, 1984; GARCEZ e GHIRARDI, 2003; LIM *et al.*, 2014). Portanto, encontrar um modelo adequado de previsão da demanda no setor elétrico não é uma tarefa simples (ALMESHAI EI e SOLTAN, 2011).

Diante da necessidade de modelos que forneçam previsões precisas de demanda de eletricidade e dos resultados encontrados nos ensaios 1 e 2 desta tese, é de interesse examinar a influência das interações espaciais na demanda de eletricidade das Distribuidoras também no contexto multivariado. Em outras palavras, este ensaio estende o segundo ensaio ao realizar uma comparação da acurácia de previsão de demanda de eletricidade entre modelos multivariados sob a estrutura de dados em painel. Para testar a hipótese de que as interações espaciais devem ser incluídas nas previsões de demanda de eletricidade no SEB, foram ajustados três diferentes métodos multivariados: painel dinâmico, modelo Durbin espacial dinâmico (SDM dinâmico) e o modelo de defasagem espacial e erro autorregressivo espacial com componente autorregressivo (SAC-AR (1)). Além de inferir sobre a importância da interação espacial nos modelos de previsão de demanda de eletricidade no SEB, é possível também estimar as elasticidades de preço, renda, número de unidades atendidas e de temperatura por meio dos referidos modelos. Conforme apontado por Baltagi (2008), a literatura sobre previsão é vasta em aplicações de séries temporais, mas ainda é incipiente em aplicações na estrutura de dados em painel.

Este ensaio contribui para a literatura de previsão e de modelagem de demanda de eletricidade em, pelo menos, cinco aspectos. Primeiro, a comparação da *performance* de previsão de modelos multivariados espaciais e não espaciais é pioneira em âmbito nacional. Segundo, estimar as elasticidades da demanda é importante, pois permite às Distribuidoras antecipar variações na demanda de eletricidade melhorando, por conseguinte, o planejamento da oferta. Terceiro, este ensaio apresenta um modelo teórico de demanda de eletricidade que considera a possível dependência espacial existente no SEB. Quarto, a análise empírica empreendida neste ensaio provê uma ferramenta de

previsão alternativa à Agência Nacional de Energia Elétrica (ANEEL), à Empresa Brasileira de Pesquisa Energética (EPE) e ao Operador Nacional do Sistema Elétrico Brasileiro (ONS). Por fim, os resultados da análise empírica inauguram uma nova agenda de pesquisa para outras áreas do setor de energia nas quais previsões acuradas são importantes, tais como previsões de vazões, de radiação solar e de vento.

Além desta Introdução, este ensaio está organizado em outras três seções. Na segunda seção é apresentada a estratégia empírica, por meio da construção de um modelo teórico de demanda de eletricidade para as Distribuidoras capaz de modelar a interação espacial existente no SEB. Nessa seção, são descritas ainda a metodologia e a base de dados utilizadas. Cabe à terceira seção a discussão dos resultados encontrados, enquanto na quarta são tecidas as considerações finais.

## **5.2 ESTRATÉGIA EMPÍRICA**

### **5.2.1 Modelo Teórico de Previsão de Demanda de Eletricidade no Âmbito das Distribuidoras Brasileiras**

A análise da modelagem do consumo de eletricidade foi inaugurada pelo artigo seminal de Houthakker (1951). Desde então, muitos artigos têm contribuído para a literatura de previsão de demanda de eletricidade (WILSON, 1971; TAYLOR, 1975; MODIANO, 1984; IRFFI *et al.*, 2009; ZHOU e TENG, 2013; LIM *et al.*, 2014; CHO *et al.*, 2015). Com o intuito de contribuir para esta literatura, é possível derivar um modelo microeconômico de demanda de eletricidade para as Distribuidoras brasileiras.

Sabe-se que as Distribuidoras atuam no “Ambiente de Contratação Regulada” (ACR) do SEB. Neste mercado, os consumidores são “cativos”, ou seja, os consumidores só podem comprar energia elétrica da Distribuidora que possui a concessão de fornecimento de sua região. Sendo assim, o ACR é composto por Distribuidoras e seus consumidores “cativos”, para os quais as transações seguem os acordos estabelecidos pela ANEEL (SOUZA e LEGY, 2010).

Como supracitado, as Distribuidoras devem ter contratos de energia elétrica que satisfaçam totalmente seus mercados. Caso as Distribuidoras contratem energia elétrica acima de 3% ou abaixo de sua demanda observada, elas são penalizadas e, com isso, aumentam seus custos de operação. Portanto, previsões de demanda têm um papel

essencial no planejamento e operação, constituindo a base para a tomada de decisões das Distribuidoras (GARCÍA-ASCANIO e MATÉ, 2010).

Diante do exposto, torna-se fundamental para as Distribuidoras especificar adequadamente o modelo de demanda de energia elétrica. De posse de um modelo de demanda bem especificado, as Distribuidoras são capazes de realizar previsões acuradas de modo a garantir eficiências produtiva, alocativa e ambiental. Baseado em Houthakker e Taylor (1970), Wilson (1971), Houthakker *et al.* (1974), Houthakker (1980), Modiano (1984), Amarawickrama e Hunt (2008) e Arisoy e Ozturk (2014), pode-se especificar uma função individual de demanda de energia elétrica ( $D_t$ ) para as Distribuidoras brasileiras como segue:

$$D_t = f(D_{t-1}, P_t, I_t, U_t, T_t) \quad (5.1)$$

Onde  $D_{t-1}$  é a demanda de eletricidade do período anterior;  $P$  é o preço da eletricidade;  $I$  denota a renda média dos consumidores;  $U$  representa o número de residências conectadas à rede e  $T$  é a temperatura. O subscrito  $t$  indica o tempo. Vale apontar que não foi incluído na Equação (5.1) o preço de um possível bem substituto para a eletricidade como, por exemplo, o gás natural ou GLP, uma vez que uma possível substituição acarretaria a necessidade de troca de equipamento<sup>10</sup>.

Assumindo  $D_t$  como uma função multiplicativa, a Equação (5.1) pode ser rescrita da seguinte maneira:

$$D_t = f(D_{t-1}, P_t, I_t, U_t, T_t) = AD_{t-1}^{\emptyset} P_t^{\beta_1} I_t^{\beta_2} U_t^{\beta_3} T_t^{\beta_4} \quad (5.2)$$

Em que  $(\emptyset + \beta_1 + \beta_2 + \beta_3 + \beta_4) < 1$ . Assim,  $D_t$  apresenta retornos decrescentes de escala.

---

<sup>10</sup> Nesta tese dois bens são ditos substitutos quando a variação do preço de um bem gera variação proporcional na demanda do outro bem, sem implicar em troca de equipamentos ou tecnologia para estabelecer a substituição de um bem pelo outro. No presente caso, eletricidade e gás natural/GLP não foram considerados bens substitutos uma vez que, caso haja aumento do preço da eletricidade, por exemplo, a elevação na demanda de gás natural/GLP só será possível mediante a troca de tecnologia. No curto prazo, essa troca de tecnologia pode não ser economicamente viável para o consumidor.

Com o objetivo de estimar e prever a demanda de eletricidade das Distribuidoras foi realizada uma transformação monotônica crescente do tipo *log-log* na Equação (5.2). Após alguns rearranjos algébricos, obtém-se:

$$\ln(D_t) = \mu + \emptyset \ln(D_{t-1}) + \beta_1 \ln(P_t) + \beta_2 \ln(I_t) + \beta_3 \ln(U_t) + \beta_4 \ln(T_t) + \varepsilon_t \quad (5.3)$$

Onde  $\mu = \ln(A)$  é um termo constante.

A Equação (5.3) pode ser entendida como a equação de demanda de eletricidade a ser estimada no âmbito das Distribuidoras. Pelo fato da forma funcional especificada na Equação (5.3) ser *log-log*, os coeficientes estimados podem ser interpretados como elasticidades e representam os efeitos diretos de uma variação percentual em uma dada variável explicativa sobre a variação percentual do consumo de eletricidade. Assim,  $\beta_1$ ,  $\beta_2$ ,  $\beta_3$  e  $\beta_4$  referem-se às elasticidades preço, renda, de unidades conectadas à rede e de temperatura, respectivamente. Espera-se um sinal negativo para a elasticidade-preço da demanda ( $\beta_1$ ) e um sinal positivo para os coeficientes relativos à elasticidade-renda ( $\beta_2$ ), elasticidade referente às unidades conectadas à rede ( $\beta_3$ ) e elasticidade de temperatura ( $\beta_4$ ). Ademais, espera-se ainda que  $\emptyset$  seja positivo.

Vale salientar que os modelos utilizados pelas Distribuidoras possuem erro ( $\varepsilon$ ) em suas previsões de demanda de eletricidade. Os erros de previsão podem diferenciar um modelo custo-efetivo de outro que não o seja. Estes erros de previsão são mensurados, geralmente, por meio do MAPE de previsão.

Para evitar o pagamento de multas decorrentes dos erros nas previsões, as Distribuidoras procuram se beneficiar dos intercâmbios regionais de energia elétrica em seus contratos de compra de energia. Cabe lembrar que o resultado da estatística *I* de Moran, computado no ensaio 1 desta tese, confirmou a presença de dependência espacial nos dados de consumo regional de eletricidade. Além disso, o ensaio 2 evidenciou a importância das interações espaciais para a acurácia dos modelos de previsão de demanda de eletricidade no contexto univariado.

Diante do exposto, a dependência espacial existente deveria ser modelada na função de demanda das Distribuidoras. Esta dependência pode ser modelada por meio da defasagem espacial da demanda de eletricidade ( $W \ln(D_t)$ ) e/ou pelos transbordamentos espaciais ( $W \ln(X_t)$  onde  $X = W \ln(P_t), W \ln(I_t), W \ln(U_t)$  e  $W \ln(T_t)$ ) e/ou por meio de

choques aleatórios das regiões vizinhas ( $\mathbf{W}\varepsilon_t$ ). Neste sentido, a função geral de demanda capaz de modelar os efeitos espaciais na demanda de eletricidade pode ser especificada como segue:

$$\begin{aligned} \ln(D_t) = & \mu + \phi \ln(D_{t-1}) + \rho \mathbf{W} \ln(D_t) + \beta_1 \ln(P_t) + \beta_2 \ln(I_t) + \beta_3 \ln(U_t) + \\ & \beta_4 \ln(T_t) + \Psi_1 \mathbf{W} \ln(P_t) + \Psi_2 \mathbf{W} \ln(I_t) + \Psi_3 \mathbf{W} \ln(U_t) + \Psi_4 \mathbf{W} \ln(T_t) + \\ & \varepsilon_t \end{aligned}$$

$$\varepsilon_t = \lambda \mathbf{W} \varepsilon_t + v_t \quad (5.4)$$

Onde  $\rho$  é o coeficiente autorregressivo espacial que captura a importância das interações espaciais existentes (intercâmbios de energia elétrica) na demanda de eletricidade das Distribuidoras.  $\mathbf{W}$  é uma matriz de ponderação espacial constante no tempo.  $\Psi$  mensura a importância das interações espaciais exógenas.  $\lambda$  é o parâmetro de erro autorregressivo espacial. O restante da notação permanece a mesma da Equação (5.3).

Para fins de planejamento da operação e de expansão do SIN, é possível propor um modelo agregado, capaz de modelar a demanda de eletricidade para as 62 distribuidoras de energia elétrica atuantes no SEB, baseado no modelo individual de demanda de eletricidade especificado na Equação (5.3). Aplicando o somatório, tem-se:

$$\begin{aligned} \sum_{n=1}^N \ln(D_t) = \ln(D_{gt}) = & \mu_g + \phi \ln(D_{gt-1}) + \beta_1 \ln(P_{gt}) + \beta_2 \ln(I_{gt}) + \\ & \beta_3 \ln(U_{gt}) + \beta_4 \ln(T_{gt}) + \varepsilon_{gt} \end{aligned} \quad (5.5)$$

Onde  $g = (1, \dots, G)$  refere-se às Distribuidoras e  $D_{gt}$  denota a demanda de eletricidade da Distribuidora  $g$  ao longo do tempo  $t$ . A Equação (5.5) pode ser entendida como demanda de eletricidade sob a estrutura de painel de dados.

Analogamente, é possível especificar uma função de demanda de eletricidade para as Distribuidoras na presença de dependência espacial da seguinte forma:

$$\begin{aligned} \sum_{n=1}^N \ln(D_t) = \ln(D_{gt}) = & \mu_g + \phi \ln(D_{gt-1}) + \rho \mathbf{W} \ln(D_{gt}) + \beta_1 \ln(P_{gt}) + \\ & \beta_2 \ln(I_{gt}) + \beta_3 \ln(U_{gt}) + \beta_4 \ln(T_{gt}) + \\ & \Psi_1 \mathbf{W} \ln(P_{gt}) + \Psi_2 \mathbf{W} \ln(I_{gt}) + \Psi_3 \mathbf{W} \ln(U_{gt}) + \\ & \Psi_4 \mathbf{W} \ln(T_{gt}) + \varepsilon_{gt} \end{aligned}$$

$$\varepsilon_{gt} = \lambda \mathbf{W} \varepsilon_{gt} + v_{gt} \quad (5.6)$$

Caso seja verificado que a demanda de eletricidade regional seja distribuída aleatoriamente no tempo e no espaço, a Equação (5.5) deve ser a equação de demanda de eletricidade a ser estimada pelas Distribuidoras.

### 5.2.2 Especificação dos Modelos Multivariados para a Previsão de Demanda de Eletricidade no Brasil

Os modelos de painel de dados dinâmico têm sido amplamente estudados nas últimas décadas, porque além de esses modelos captarem a dinâmica da variável de interesse, também controlam a heterogeneidade não observável entre as unidades regionais estudadas. Entretanto, ao se utilizar dados regionais, a literatura econométrica, teórica e empírica, tem enfatizado a importância da inclusão dos efeitos espaciais para se obter estimativas consistentes e eficientes nas análises. Sendo assim, é bastante compreensível o recente interesse dos pesquisadores por modelos espaço-temporais.

Nesse contexto, com o objetivo de identificar o modelo de previsão de demanda que minimiza os custos de operação das Distribuidoras (modelo que apresentar menor MAPE de previsão), o presente ensaio estimará três modelos, a saber: painel de dados dinâmico, modelo Durbin espacial dinâmico (SDM dinâmico) e modelo de defasagem espacial e erro autorregressivo espacial com componente autorregressivo (SAC-AR(1)). O modelo de painel de dados será estimado com base na Equação (5.5) enquanto os modelos SDM dinâmico e SAC-AR(1) serão estimados a partir na Equação (5.6).

#### 5.2.2.1 Painel Dinâmico

Um painel de dados é um conjunto que inclui dados de corte transversal ao longo do tempo. Como aponta Wooldridge (2002), a motivação primária para uso de painel de dados é atenuar o problema de viés de variáveis omitidas. Na estrutura de painel de dados, a questão central é saber se os efeitos não observados são (ou não) correlacionados com as variáveis explicativas ou com o termo de erro. Diante disso, considere um modelo linear de painel de dados representado por:

$$\begin{aligned} Y_{gt} &= \mu_g + \mathbf{X}_{gt} \boldsymbol{\beta} + v_{gt} \\ v_{gt} &\sim N(0, \sigma^2) \end{aligned} \quad (5.7)$$



Onde  $g = (1, \dots, G)$  são as regiões observadas ao longo de  $t = (1, \dots, T)$  períodos de tempo.  $Y_{nt}$  é um vetor  $GT \times 1$  que denota a variável dependente;  $\beta$  é um vetor de coeficientes exógenos  $K \times 1$  associados a uma matriz de covariadas exógenas  $X$  de dimensão  $GT \times K$ ;  $\mu_n$  é um vetor  $GT \times 1$  de efeitos não-observados, constantes no tempo, específicos a cada unidade *cross-sectional* (efeitos individuais);  $v_{gt}$  é um ruído branco de dimensão  $GT \times 1$ .

Os efeitos não observados enviesam as estimativas por *Ordinary Least Squares* (OLS) e devem ser tratados utilizando os modelos de efeitos fixos (FE) ou de efeitos aleatórios (RE), conforme escolha indicada pelo teste de Hausman (1978). FE é estimado por OLS que usa uma transformação *within* para remover o efeito não observado ( $\mu_g$ ). Já a estimação por RE é utilizada quando o efeito não observado é não correlacionado com todas as variáveis explicativas e envolve a estimação por mínimos quadrados generalizados (GLS).

Entretanto, uma limitação dos modelos de painel de dados consiste em não incorporarem a possível dinâmica temporal da variável dependente. Tal limitação é superada através das estimações dos modelos dinâmicos com dados em painel desenvolvidas a partir das estimações pelo método dos momentos generalizados (GMM). A estimação de dados em painel dinâmico por GMM está associada aos trabalhos de Arellano e Bond (1991), Arellano e Bover (1995) e Blundell e Bond (1998).

A utilização de modelos dinâmicos para dados em painel tem sua justificativa pelo fato de que muitas variáveis de interesse se relacionam umas às outras e com seus valores passados. Nesse sentido, modelos que consideram a variável dependente defasada temporalmente como sendo uma variável explicativa parecem aderir melhor ao comportamento das séries ao longo do tempo. Nesse caso, a estimação por GMM em diferença permite levar em conta a persistência da variável dependente no tempo.

Assim, as relações dinâmicas podem ser especificadas em um modelo de painel de dados por meio da inclusão de uma variável dependente defasada temporalmente da seguinte forma:

$$\begin{aligned} Y_{gt} &= \mu_g + \alpha Y_{gt-1} + X_{gt}\beta + v_{gt} \\ v_{gt} &\sim N(0, \sigma^2) \end{aligned} \tag{5.8}$$

Onde  $Y_{gt-1}$  refere-se à defasagem temporal da variável dependente e  $\alpha$  é o coeficiente associado. O restante da notação permanece a mesma da Equação (5.7).

Considerando a provável inércia, bem como os determinantes do consumo regional de eletricidade especificados na Equação (5.5), o modelo de painel dinâmico expresso pela Equação (5.8) pode ser reescrito da seguinte forma:

$$\begin{aligned} \ln(D)_{gt} &= \mu_g + \alpha \ln(D)_{gt-1} + \beta_1 \ln(P_{gt}) + \beta_2 \ln(I_{gt}) + \beta_3 \ln(U_{gt}) + \beta_4 \ln(T_{gt}) \\ &\quad + v_{gt} \\ v_{gt} &\sim N(0, \sigma^2) \end{aligned} \tag{5.9}$$

No modelo de painel dinâmico, assim como no modelo de painel de dados linear, os efeitos não observados inerentes a cada região ( $\mu_g$ ) serão tratados pelo método de efeitos fixos ou efeitos aleatórios e a escolha do método será feita com base no teste de Hausman (1978). A partir disso, o estimador GMM de Arellano e Bond (1991) instrumentaliza as variáveis explicativas em diferença ( $\Delta X_{gt} = X_{gt} - X_{gt-1}$ ) que não são estritamente exógenas com suas defasagens disponíveis em nível. Arellano e Bond (*ibid.*) propõem a utilização de variáveis com defasagens em, pelo menos, dois períodos ( $t - 2$ ), como instrumento para a equação em primeira diferença.

#### 5.2.2.2 Modelo Durbin Espacial Dinâmico (SDM dinâmico)

Cientistas que estudam questões regionais têm demonstrado que a dependência espacial nos dados pode alterar, e até mesmo enviesar, os resultados obtidos por meio de métodos econométricos clássicos. Várias pesquisas, como por exemplo Rey e Montouri (1999) e Badinger *et al.* (2004), estabeleceram a importância de integrar defasagens espaciais e temporais na análise econométrica de dados regionais. Entretanto, a literatura sobre dinâmicas temporais e espaciais tem progredido de forma autônoma, com pouca interação entre esses dois aspectos (BEENSTOCK e FELSENSTEIN, 2007).

No caso do consumo regional de eletricidade no Brasil, é plausível afirmar — de acordo com o que foi tratado na seção 5.2.1 e considerando os resultados dos ensaios 1 e 2 — que existem *spillovers* espaciais. Entretanto, os modelos que tratam as dinâmicas espacial e temporal concomitantemente podem ser consideradas as exceções, sendo uma delas os modelos de painel dinâmico espacial.

Mais especificamente, Debarsy *et al.* (2012) consideram um modelo de painel dinâmico espacial autorregressivo que permite representar a dinâmica espacial por meio da inclusão de defasagens espaciais contemporâneas, tanto da variável dependente quanto das covariadas ( $\mathbf{W}y_{gt}$  e  $\mathbf{W}\mathbf{X}_{gt}$ ) enquanto a dinâmica temporal é modelada pela inclusão na regressão da variável defasada temporalmente ( $y_{gt-1}$ ). Ainda, a defasagem temporal da variável dependente defasada espacialmente ( $\mathbf{W}y_{gt-1}$ ) trata a dinâmica espacial e temporal de forma imbricada. Tal modelo foi denominado pelos autores como modelo Durbin espacial dinâmico (SDM dinâmico) e pode ser formalizado como segue:

$$Y_{gt} = \mu_g + \alpha Y_{gt-1} + \rho_1 \mathbf{W}Y_{gt} + \rho_2 \mathbf{W}Y_{gt-1} + \mathbf{X}_{gt}\boldsymbol{\beta} + \mathbf{W}\mathbf{X}_{gt}\boldsymbol{\Psi} + v_{gt} \quad (5.10)$$

$$v_{gt} \sim N(0, \sigma^2)$$

No caso da demanda regional de eletricidade, a justificativa para inclusão da defasagem espacial das variáveis dependente e explicativas ( $\mathbf{W}Y_{gt}$  e  $\mathbf{W}\mathbf{X}_{gt}$ ) consiste no fato de que o consumo de eletricidade em uma região, provavelmente, é influenciado pela média do consumo de eletricidade em regiões vizinhas em virtude de as regiões brasileiras serem inter-relacionadas social e economicamente. Já a inclusão de  $\mathbf{W}y_{gt-1}$  na especificação pretende testar a hipótese de que haveria uma inércia na demanda de eletricidade das regiões vizinhas capaz de impactar a demanda regional observada.

Sendo assim, a Equação (5.8) pode ser especificada levando em consideração o modelo regional de demanda de energia elétrica descrito na Equação (5.6) da seguinte forma:

$$\ln(D_{gt}) = \mu_g + \alpha \ln(D_{gt-1}) + \rho_1 \mathbf{W}\ln(D_{gt}) + \rho_2 \mathbf{W}\ln(D_{gt-1}) + \beta_1 \ln(P_{gt}) +$$

$$\beta_2 \ln(I_{gt}) + \beta_3 \ln(U_{gt}) + \beta_4 \ln(T_{gt}) + \Psi_1 \mathbf{W}\ln(P_{gt}) +$$

$$\Psi_2 \mathbf{W}\ln(I_{gt}) + \Psi_3 \mathbf{W}\ln(U_{gt}) + \Psi_4 \mathbf{W}\ln(T_{gt}) + v_{gt}$$

$$v_{gt} \sim N(0, \sigma^2) \quad (5.11)$$

O efeitos não observados serão tratados, mais uma vez, por meio dos modelos de FE ou RE. Para estimar os parâmetros da Equação (5.11) de forma eficiente e consistente será utilizado o método dos momentos generalizados (GMM) proposto Blundell e Bond (1998). Cabe ressaltar que a aplicação do SDM dinâmico é pioneiro no setor elétrico tanto em nível nacional quanto em nível internacional.

### 5.2.2.3 Modelo de Defasagem Espacial e Erro Autorregressivo Espacial com Componente Autorregressivo (SAC-AR(1))

Estabelecida a importância das interações espaciais para o consumo regional de eletricidade e, mais especificamente, caso os padrões de consumo de eletricidade observados nas regiões vizinhas estejam correlacionados com o consumo local e as variáveis não observadas estejam correlacionadas espacialmente, um modelo capaz de tratar ambos os efeitos espaciais é o modelo SAC. Tal modelo combina as abordagens autorregressivo espacial e de erros autorregressivos e, assim, permite modelar os transbordamentos espaciais tanto na variável endógena quanto no termo de erro.

Entretanto, como especificado na Equação (5.6), é plausível supor que o consumo de eletricidade atual possua um componente inercial com o período imediatamente anterior. Assim, torna-se necessário incluir o componente autorregressivo temporal na especificação econométrica. Com o intuito de contemplar o componente inercial do consumo de eletricidade, Cho *et al.* (2015) estenderam o modelo SAC, denominando-o de modelo SAC-AR(1).

A partir das definições feitas acima, o modelo SAC-AR (1), em sua forma matricial, pode ser especificado da seguinte forma:

$$\begin{aligned} Y_{gt} &= \mu_g + \alpha Y_{gt-1} + \rho \mathbf{W} Y_{gt} + \mathbf{X}_{gt} \boldsymbol{\beta} + \varepsilon_{gt}; \text{ onde } |\alpha| < 1 \text{ e } |\rho| < 1 \\ \varepsilon_{gt} &= \lambda \mathbf{W} \varepsilon_{gt} + v_{gt}; \text{ onde } |\lambda| < 1 \\ v_{nt} &\sim N(0, \sigma^2) \end{aligned} \quad (5.12)$$

Onde  $\varepsilon_{gt}$  é um vetor  $GT \times 1$  de resíduos defasados espacialmente e  $\lambda$  é o coeficiente autorregressivo espacial dos resíduos. O restante da notação permanece a mesma da Equação (5.11).

A Equação (5.12) pode ser facilmente extrapolada para estimar a demanda de eletricidade da “Distribuidora Equivalente Regional” como segue:

$$\begin{aligned} \ln(D_{gt}) &= \mu_g + \alpha \ln(D_{gt-1}) + \rho_1 \mathbf{W} \ln(D_{gt}) + \beta_1 \ln(P_{gt}) + \beta_2 \ln(I_{gt}) + \\ &\quad \beta_3 \ln(U_{gt}) + \beta_4 \ln(T_{gt}) + \varepsilon_{gt} \\ \varepsilon_{gt} &= \lambda \mathbf{W} \varepsilon_{gt} + v_{gt} \end{aligned} \quad (5.13)$$

Como nos demais modelos especificados até então, a heterogeneidade não observada ( $\mu_n$ ), inerente a cada Distribuidora, será tratada pelo modelo de FE ou RE. A estimação do SAC-AR (1) para painel de dados espaciais, especificada na Equação (5.13), será realizada por meio do método de máximo verossimilhança (ML) proposto por Elhorst (2010) e Lee e Yu (2010). A escolha do método ML é devido ao fato de o método ML tratar a endogeneidade da variável  $Wln(D_{gt})$  de forma simples além de ser um método bastante difundido na literatura.

### 5.2.3 Descrição da Base de Dados

A base de dados utilizada é constituída de um painel de dados mensal de janeiro de 2004 a dezembro de 2014 para as cinco unidades regionais brasileiras (Norte, Nordeste, Centro-Oeste, Sudeste e Sul). Dessa forma, o painel contém 132 observações para cada região totalizando 660 observações. As variáveis utilizadas para a estimação dos três modelos propostos são: consumo regional de energia elétrica; número de residências atendidas em cada região; tarifa média regional; renda média regional *per capita* da atividade formal; e temperatura média.

Em relação às fontes dos dados, as variáveis consumo regional de energia elétrica, número de residências atendidas em cada região e tarifa média regional são oriundas do Sistema de Apoio à Decisão (SAD) da Agência Nacional de Energia Elétrica (ANEEL). A renda média regional *per capita* da atividade formal foi obtida pela razão entre a massa salarial regional mensal e o número de trabalhadores na região. Os dados do salário regional mensal foram extraídos do Cadastro Geral de Empregados e Desempregados (CAGED). Já a quantidade mensal de trabalhadores foi obtida por meio da compatibilização dos dados de emprego da Relação Anual de Informações Sociais (RAIS) e do CAGED, ambos disponibilizados pelo Ministério do Trabalho (MT).

Com relação à variável climática, a temperatura média das regiões foi retirada do Banco de Dados Meteorológicos para Ensino e Pesquisa do Instituto Nacional de Meteorologia (BDMEP/INMET). O Quadro 5.1 faz um resumo esquemático das variáveis utilizadas nos modelos e suas respectivas fontes.

**Quadro 5.1:** Descrição das variáveis utilizadas.

Variável	Descrição	Unidade	Fonte dos dados
<i>D</i>	Consumo regional de energia elétrica	GWh	SAD/ANEEL
<i>P</i>	Tarifa média regional	R\$	SAD/ANEEL
<i>I</i>	Renda média regional <i>per capita</i>	R\$	CAGED/RAIS/MT
<i>U</i>	Número de residências atendidas	Quantidade	SAD/ANEEL
<i>T</i>	Temperatura média regional	°C	BDMEP/INMET

**Fonte:** Elaboração Própria.

### 5.3 RESULTADOS

Sabendo que a existência de efeitos não observados podem levar a estimações tendenciosas no consumo regional de eletricidade, foi realizado o teste de Hausman (1978) para identificar se tais efeitos seriam modelados de forma adequada por meio dos efeitos fixos ou dos efeitos aleatórios. O teste de Hausman rejeitou a hipótese nula de que os efeitos aleatórios seriam consistentes e, assim, o modelo de efeitos fixos é a melhor escolha para o tratamento dos efeitos não observados na demanda regional de eletricidade no Brasil. Portanto, a partir dessa constatação, os modelos de painel dinâmico, Durbin dinâmico e SAC-AR (1) foram estimados com correção dos efeitos não observados por meio da modelagem de efeitos fixos. Os resultados dos modelos estão reportados na Tabela 5.1.

A presença da defasagem temporal no lado direito da regressão dos modelos estimados opera como um regressor endógeno. Desse modo, com o objetivo de tratar essa endogeneidade temporal, o estimador de Arellano e Bover (1995), Blundell e Bond (1998), uma extensão do estimador de Arellano-Bond (1991), foi implementado para estimar o modelo de painel dinâmico. Esse estimador consiste na estimação em primeiras diferenças da Equação (5.9) por GMM. Com isso, o método remove os efeitos específicos não observados invariantes no tempo.

**Tabela 5.1:** Resultados das estimações dos modelos multivariados para a demanda regional de eletricidade.

Demanda [ $\ln(D_{gt})$ ]	Painel dinâmico <sup>a</sup>	SDM dinâmico <sup>b</sup>	SAC-AR(1) <sup>c</sup>
Demanda <sub>t-1</sub> [ $\hat{\alpha}\ln(D_{gt-1})$ ]	0,889*** (0,012)	0,713*** (0,023)	0,731*** (0,024)
Tarifa [ $\hat{\beta}_1\ln(P_{gt})$ ]	-0,078*** (0,014)	-0,152*** (0,026)	-0,166*** (0,030)
Renda [ $\hat{\beta}_2\ln(I_{gt})$ ]	0,030*** (0,005)	0,055*** (0,021)	0,097*** (0,025)
Unidades [ $\hat{\beta}_3\ln(U_{gt})$ ]	0,106*** (0,013)	0,39*** (0,046)	0,44*** (0,045)
Temperatura [ $\hat{\beta}_4\ln(T_{gt})$ ]	0,016** (0,008)	0,037*** (0,010)	0,059*** (0,001)
WTarifa [ $\hat{\Psi}_1\mathbf{W}\ln(P_{gt})$ ]		0,058*** (0,015)	
WRenda [ $\hat{\Psi}_2\mathbf{W}\ln(I_{gt})$ ]		-0,024* (0,013)	
WUnidades [ $\hat{\Psi}_3\mathbf{W}\ln(U_{gt})$ ]		-0,100*** (0,036)	
WTemperatura [ $\hat{\Psi}_4\mathbf{W}\ln(T_{gt})$ ]		0,011 (0,007)	
[ $\hat{\rho}_1\mathbf{W}\ln(D_{gt})$ ]		0,242*** (0,024)	0,014 (0,043)
[ $\hat{\rho}_2\mathbf{W}\ln(D_{gt-1})$ ]		-0,185*** (0,023)	
[ $\hat{\lambda}\mathbf{W}\varepsilon_{gt}$ ]			-0,206*** (0,056)
Constante	0,084** (0,042)	-0,221 (0,295)	—
AIC	-3,497	-3,710	-2,969
BIC	-3,489	-3,693	-2,959
MAPE	0,193	0,147	0,374
Número de observações	660	660	660

**Fonte:** Elaboração Própria.

**Notas:** Erros-padrão robustos entre parênteses;

\*\*\* p-valor<0,01, \*\* p-valor<0,05, \* p-valor<0,1;

<sup>a</sup> resultados obtidos por meio do comando *xtdpdsys* do STATA 12.

<sup>b</sup> resultados obtidos por meio do comando *spregdpd* do STATA 12.

<sup>c</sup> resultados obtidos por meio do comando *xsmlc* do STATA 12.

Entretanto, para que seus coeficientes possam ser interpretados, é necessário verificar sua consistência pelo teste de autocorrelação de Arellano-Bond. Embora os coeficientes sejam reportados para o nível das variáveis, o teste é realizado nos resíduos em diferença. As hipóteses testadas referem-se à ausência de correlação serial de primeira e de segunda ordem, sendo desejável rejeitar a primeira e não rejeitar a segunda. A

consistência do estimador Arellano-Bond depende, portanto, do pressuposto de inexistência de correlação serial de segunda ordem nos resíduos em primeira diferença,  $E(\Delta v_{g,t} \Delta v_{g,t-2}) = 0$ , que implica ausência de autocorrelação serial nos resíduos em nível, como pressupõe o método empregado. Os valores do teste de autocorrelação de Arellano-Bond para a primeira e a segunda ordem foram, respectivamente, -2,138\*\* e -0,461. Sendo assim, é possível afirmar que as estimativas são consistentes, pois não é possível rejeitar a hipótese nula de ausência de correlação serial de segunda ordem para a demanda residencial.

Contudo, cabe testar se os resíduos do painel dinâmico são autocorrelacionados espacialmente, tendo em vista que na presença de dependência espacial, as estimativas são ineficientes caso esta dependência se manifeste na forma de erro autorregressivo espacial. Tais estimativas podem, ainda, ser enviesadas se a dependência tomar a forma de defasagem espacial da variável dependente e/ou de transbordamentos espaciais das variáveis exógenas. Com base no teste de CD-Pesaran (6,60\*\*\*), existe dependência espacial *cross sectional* entre as regiões. Para confirmar essa dependência espacial, foi computada a estatística de autocorrelação espacial *I* de Moran (0,257\*\*\*) que também indicou a existência de dependência espacial nos resíduos ao nível de 1% de significância.

Sendo assim, é confirmada a necessidade de modelar a dependência espacial no consumo regional de eletricidade no Brasil também no contexto multivariado. Com o objetivo de incluir as interações espaciais existentes, os modelos SDM dinâmico e o SAC-AR (1) foram estimados com base nas Equações (5.11) e (5.13), respectivamente. Os resultados de ambos os modelos constam nas colunas três e quatro da Tabela 5.1 e, pelo fato de as variáveis estarem especificadas em logaritmo, seus coeficientes refletem diretamente as elasticidades da demanda.

Por meio dos resultados, é possível atestar que o modelo SDM dinâmico possui melhor qualidade de ajuste, pois apresentou os menores critérios de informação AIC e BIC. Outro resultado que confirma a escolha do modelo SDM dinâmico como o mais adequado para prever a demanda regional de eletricidade no Brasil refere-se à qualidade de previsão. A *performance* preditiva do SDM dinâmico mostrou-se superior aos demais modelos por ter apresentado o menor MAPE de previsão. Portanto, considerar as interações espaciais melhoram a acurácia de previsão de demanda regional de eletricidade no Brasil.



A melhora da acurácia de previsão via modelos espaciais também foi encontrado por Ohtsuka *et al.* (2010) para as Distribuidoras japonesas. No caso brasileiro, o resultado do ensaio 2 desta tese confirmou a superioridade da capacidade preditiva do modelo espaço-temporal (ARIMASp) para prever a demanda de eletricidade da “Distribuidora Equivalente do Sudeste”. Blásquez Gomez *et al.* (2013) para províncias espanholas e Cho *et al.* (2015) para regiões sul-coreanas encontraram evidências de que os modelos espaciais são mais adequados para estimar a demanda residencial de eletricidade.

De acordo com Le Sage e Pace (2009), os efeitos totais neste caso não são dados pelos coeficientes estimados. Em um modelo SDM, para se ter o impacto de ambos os efeitos, direto e indireto, proporcionados pela interação espacial entre as regiões, de uma variável explicativa  $\mathbf{X}_k$  sobre o consumo regional de eletricidade no Brasil, é necessário fazer a multiplicação dos parâmetros contemporâneos estimados pela transformação espacial  $(\mathbf{I}_g - \mathbf{W}\rho_1)^{-1}$ , sendo  $\mathbf{I}_g$  uma matriz identidade  $G \times G$ . Pelo fato de a matriz de ponderação espacial  $\mathbf{W}$  ser normalizada na linha, o multiplicador espacial passa a ser  $(\mathbf{I}_g - \rho_1)^{-1}$ .

Sendo assim, como apontado por Elhorst (2010), a interpretação dos resultados de um modelo SDM dinâmico precisa ser cuidadosa, em virtude da especificação deste modelo apresentar a variável dependente defasada temporalmente  $\ln(D_{gt-1})$ , espacialmente  $(\mathbf{W}\ln(D_{gt}))$  e defasada temporal e espacialmente  $\mathbf{W}\ln(D_{gt-1})$ , além das variáveis explicativas defasadas espacialmente  $(\mathbf{W}\ln(\mathbf{X}_{gt}))$ . Dessa forma, a interpretação dos efeitos marginais totais do modelo SDM dinâmico devem levar em consideração todos estes efeitos concomitantemente. Os efeitos marginais totais do modelo SDM dinâmico proposto por Elhorst (2010) são encontrados a partir da seguinte transformação da Equação (5.11):

$$\begin{aligned} \ln(D_{gt}) = & (\mathbf{I}_g - \rho_1\mathbf{W})^{-1}(\alpha\mathbf{I}_g - \rho_2\mathbf{W})\ln(D_{gt-1}) + (\mathbf{I}_g - \rho_1\mathbf{W})^{-1}(\beta_1 + \\ & \Psi_1\mathbf{W})\ln(P_{gt}) + (\mathbf{I}_g - \rho_1\mathbf{W})^{-1}(\beta_2 + \Psi_2\mathbf{W})\ln(I_{gt}) + (\mathbf{I}_g - \\ & \rho_1\mathbf{W})^{-1}(\beta_3 + \Psi_3\mathbf{W})\ln(U_{gt}) + (\mathbf{I}_g - \rho_1\mathbf{W})^{-1}(\beta_4 + \\ & \Psi_4\mathbf{W})\ln(T_{gt}) + (\mathbf{I}_g - \rho_1\mathbf{W})^{-1}\mathbf{v}_{gt} \end{aligned} \quad (5.14)$$

A partir dessa transformação, os resultados empíricos do modelo SDM dinâmico permitem também a decomposição das elasticidades da demanda em efeitos direto, indireto e total. De acordo com LeSage e Pace (2009), o efeito direto é a média dos elementos que aparecem na diagonal principal de  $(\mathbf{I}_g - \rho_1)^{-1}$ , isto é,  $\bar{E}_{direto} = N_G^{-1} \text{traço} \left[ (\mathbf{I}_g - \rho_1)^{-1} \right] \mathbf{I}_g \pi_k$  enquanto o efeito total trata-se da média da soma das linhas ou da média da soma das colunas da matriz  $(\mathbf{I}_g - \rho_1)^{-1}$ , ou seja,  $\bar{E}_{total} = N_G^{-1} (\mathbf{I}_g - \rho_1)^{-1} \mathbf{I}_g \pi_k$ . O efeito indireto é obtido pela diferença entre o efeito total e o efeito direto ( $\bar{E}_{indireto} = \bar{E}_{total} - \bar{E}_{direto}$ ).

No caso estudado, o  $\bar{E}_{direto}$  pode ser entendido como uma mudança em dada variável na  $n$ -ésima região sobre a demanda de eletricidade da  $n$ -ésima região. Já o  $\bar{E}_{indireto}$  refere-se a uma mudança em dada variável nas regiões vizinhas sobre a demanda de eletricidade na  $n$ -ésima região. O  $\bar{E}_{total}$  é uma mudança em dada variável na  $n$ -ésima região sobre a demanda de eletricidade da  $n$ -ésima região mais o efeito das regiões vizinhas, exercendo um efeito retroalimentador sobre a demanda de eletricidade da  $n$ -ésima região. A Tabela 5.2 apresenta a decomposição das elasticidades que foram estatisticamente significativas.

**Tabela 5.2:** Decomposição das elasticidades de demanda regional de eletricidade no Brasil estimadas por meio do modelo SDM dinâmico.

	Efeito direto	Efeito indireto	Efeito total
Demanda <sub>t-1</sub> [ $\hat{\alpha} \ln(D_{gt-1})$ ]	0,941	-0,244	0,697
Tarifa [ $\hat{\beta}_1 \ln(P_{gt})$ ]	-0,201	0,077	-0,124
Renda [ $\hat{\beta}_2 \ln(I_{gt})$ ]	0,073	-0,032	0,041
Unidades [ $\hat{\beta}_3 \ln(U_{gt})$ ]	0,515	-0,132	0,383
Temperatura [ $\hat{\beta}_4 \ln(T_{gt})$ ]	0,049	0,015	0,063

**Fonte:** Elaboração Própria.

É interessante perceber que políticas executadas em uma dada região com o objetivo de reduzir a demanda e/ou conservar energia não surtirão efeitos apenas na região onde a política foi implementada, mas também causarão efeitos nas regiões vizinhas. O efeito indireto explicita que, por exemplo, uma política de aumento da tarifário de 1% em uma região será capaz de diminuir a demanda de eletricidade das regiões vizinhas em 0,049%.

No que se refere ao efeito total da inércia temporal do consumo de eletricidade nas regiões do Brasil ( $\ln(D_{gt-1})$ ), seu impacto não é dado pelo seu coeficiente de 0,713, mas pelo valor de 0,697. Pode-se presumir que a inércia temporal do consumo regional é importante para explicar o consumo atual. Esse alto valor do coeficiente do consumo no período imediatamente anterior revela que os hábitos de consumo de eletricidade são relativamente estáveis nas residências brasileiras.

No caso da elasticidade-preço da demanda, o efeito total do preço da eletricidade sobre o consumo é de -0,124. Espera-se, portanto, que um aumento de 1% na tarifa seja acompanhado por uma queda de 0,124%, em média, na quantidade demandada, *ceteris paribus*. A inelasticidade da demanda em relação ao preço pode ser atribuída à ausência de fontes de energia substitutas e/ou alternativas à eletricidade nos domicílios brasileiros. Este resultado sugere que uma política de aumentos tarifários não seria eficaz como instrumento de redução do consumo de energia elétrica e, conseqüentemente, não garantiria melhorias nas condições de geração de eletricidade futura. Dada a inelasticidade-preço da demanda, espera-se que o sistema de Bandeiras Tarifárias, iniciado em 2015, tenha um impacto reduzido no consumo de eletricidade do país.

Em relação à renda, espera-se uma variação média de 0,041% no consumo de eletricidade decorrente de uma variação de 1% na renda *per capita*. Sendo assim, a demanda regional de eletricidade no Brasil é pouco sensível às modificações na renda dos trabalhadores formais. Uma das possíveis explicações para a inelasticidade da demanda em relação à renda pode ser atribuída ao racionamento de energia elétrica ocorrido em 2001 que foi capaz de mudar os hábitos de consumo de eletricidade dos consumidores brasileiros.

A inelasticidade da demanda de eletricidade no Brasil em relação ao preço e à renda está em consonância com os valores estimados pela literatura nacional, podendo ser citados os estudos de Modiano (1984), Andrade e Lobão (1997), Schdmit e Lima (2004) e Rodrigues *et al.* (2013).

No que tange às unidades atendidas, não foram encontrados estudos que estimassem tal elasticidade na literatura nacional. Pela análise dos resultados, pode-se perceber que o incremento de 1% no total de novas ligações à rede aumenta o consumo regional de eletricidade em 0,383%. Ou seja, as novas ligações à rede elétrica impactaram

positivamente o consumo regional de eletricidade. Esse resultado é interessante, pois permite às Distribuidoras antecipar variações na demanda de eletricidade decorrente de programas de universalização de acesso — como o Programa Luz para Todos — e programas de redução de furtos de energia elétrica que incentivam a legalização do consumo — Programa Tarifa Social, por exemplo.

Quanto à temperatura, as mudanças climáticas globais têm ocasionado catástrofes naturais e níveis extremos — baixos ou altos — de temperatura. No Brasil, o Instituto Nacional de Pesquisas Espaciais (INPE) prevê um aumento de 3°C a 5°C na temperatura decorrentes do aquecimento global. Diante do exposto, a temperatura torna-se um dos principais *drivers* da demanda de eletricidade. Apesar disso, foram encontrados poucos estudos que consideram a influência da temperatura sobre a demanda de energia elétrica no Brasil. Podem ser citados os estudos de DePaula e Mendelsohn (2010), Hollanda *et al.* (2012) e Rodrigues *et al.* (2013) que incorporaram o clima como fator explicativo da demanda residencial de energia elétrica.

No presente ensaio foi encontrada uma relação positiva entre a demanda de eletricidade e a temperatura. Assim, uma variação percentual da demanda de energia de 0,063% é decorrente do aumento de 1% na temperatura. De outra forma, uma variação de 1°C na temperatura impacta a demanda de eletricidade em 0,299% o que evidencia uma potencial estratégia adaptativa do consumo regional de eletricidade brasileiro às projeções de mudanças climáticas no país.

Por fim, as interações espaciais são importantes fatores para explicar a demanda de eletricidade regional, visto que os parâmetros das defasagens espaciais do consumo ( $\hat{\rho}$ ) e dos transbordamentos das variáveis explicativas ( $\hat{\Psi}$ ) foram estatisticamente significativos. Os *spillovers* positivos no consumo residencial encontrados por este estudo podem indicar dependência das atividades socioeconômicas, tendências no estilo de vida e comportamento de consumo entre regiões vizinhas que resultam em padrões similares de demanda regional de eletricidade residencial (JEENINGA e HUENGES WAJER, 1999; CHO *et al.*, 2015).

## 5.4 CONSIDERAÇÕES FINAIS

Dada a importância do setor residencial como demandante de energia elétrica no Brasil, este estudo ajustou três modelos para prever a demanda regional de eletricidade, assim como estimar as respectivas elasticidades da demanda no período mensal de 2004 a 2014. Por meio dos resultados, foi confirmada a necessidade de modelar as interações espaciais existentes no consumo regional de eletricidade, sendo o modelo SDM dinâmico o mais apropriado. Este modelo apresentou melhor *performance* preditiva com MAPE de previsão de 0,147.

A partir dos resultados do SDM dinâmico, pôde-se perceber que o consumo de eletricidade do setor residencial possui uma grande inércia temporal. Além disso, a demanda regional de eletricidade no Brasil é inelástica ao preço. Este resultado revela que políticas de aumento tarifário, como as Bandeiras Tarifárias, surtirão efeitos inexpressivos na conservação de energia ou energia potencial no Brasil.

O consumo de eletricidade também mostrou-se pouco sensível em relação às variações na renda. Por outro lado, a elasticidade referente ao número de unidades atendidas parece indicar que programas de acesso à eletricidade e legalização do consumo impactam substancialmente a demanda de energia elétrica. Este resultado é importante não somente para as Distribuidoras, mas também para os agentes do SEB que planejam a oferta e o despacho de energia elétrica, afinal poderão se antecipar às variações na demanda decorrentes do aumento de unidades conectadas à rede.

A temperatura revelou-se como um importante *driver* para explicar a demanda regional de energia elétrica, sendo uma das principais preocupações dos agentes do SEB. No caso de uma variação média de 1°C na temperatura haverá impacto de 0,299% sobre a demanda de eletricidade. No contexto atual em que as mudanças climáticas globais tem provocado níveis extremos de temperatura, este resultado confirma a importância da inclusão da temperatura nos modelos de previsão de demanda. De acordo com as previsões do INPE, a temperatura tende a aumentar a demanda de eletricidade entre 0,90% e 1,49%, este resultado deve ser levado em consideração pelas Distribuidoras brasileiras.

Por fim, pode-se concluir que existe dependência espacial no consumo regional de eletricidade no Brasil. Portanto, a modelagem desta dependência é capaz de melhorar

os resultados dos modelos estimados. Os *spillovers* espaciais sugerem a existência de interação entre regiões vizinhas no que se refere às atividades socioeconômicas, ao estilo de vida e ao comportamento de consumo resultando em padrões similares de demanda regional de eletricidade residencial.

## **6. CONCLUSÃO, IMPLICAÇÕES POLÍTICAS E AGENDA DE PESQUISA FUTURA**

O atual Modelo Institucional do Setor Elétrico Brasileiro possui como principais objetivos universalização da oferta de energia elétrica, segurança do sistema e modicidade tarifária. Neste contexto, as Distribuidoras possuem papel decisivo para alcançar estas metas, visto que seu mercado consumidor, o setor residencial, é o segundo maior demandante de energia elétrica no Brasil. As Distribuidoras atuam no ambiente de contratação regulada visando atender 100% de seus mercados ou sofrem penalidades. Assim, a habilidade de fazer boas previsões é, sem dúvida, um dos maiores desafios das Distribuidoras.

Portanto, possuir ferramentas que forneçam as melhores previsões possíveis tornou-se o principal objetivo dos agentes do Setor Elétrico Brasileiro. Previsões acuradas garantem eficiências alocativa, produtiva e ambiental. A principal hipótese desta tese consistiu em testar a existência de dependência espacial na demanda regional de eletricidade no Brasil. A importância da confirmação desta hipótese para o Setor Elétrico é que, caso exista, a dependência espacial deve ser especificada nos modelos de previsão utilizados pelos agentes do Setor visando garantir os objetivos do atual Modelo Institucional.

De modo a verificar que a demanda de eletricidade regional é espacialmente dependente, o primeiro ensaio desta tese estendeu a estatística de autocorrelação espacial nos dados proposta por Moran (1948) para a estrutura de painel de dados nos contextos uni e bivariado. As principais vantagens da estatística proposta é verificar a interação espacial entre os diversos atributos no tempo e no espaço conjuntamente, além de minimizar o tempo dispendido pelo analista. Os resultados comprovaram a existência de dependência espacial negativa no consumo regional de eletricidade no Brasil. Diante disso, as interações espaciais devem ser incluídas nos modelos de previsão de demanda de eletricidade.

Coube ao segundo ensaio desta tese incluir a dependência espacial na especificação de modelos de previsão de demanda de eletricidade regional no Setor Elétrico Brasileiro no contexto univariado. A dependência espacial existente no Setor foi especificada por meio do modelo auto regressivo integrado e de média móvel espacial

(ARIMASp) proposto. Além de ser um método de previsão de fácil implementação e interpretação, o modelo ARIMASp foi capaz de fornecer previsões mais precisas ao apresentar menor MAPE de previsão quando comparado com o modelo auto regressivo integrado e de média móvel (ARIMA).

Em termos quantitativos, o modelo ARIMASp sobrestimou a demanda total de eletricidade no período analisado em 214,68 GWh enquanto a previsão do modelo ARIMA apresentou um déficit de 1.317,30 GWh. A previsão custo-efetiva obtida via modelo ARIMASp mostrou que as “Distribuidoras do Sudeste” não sofreriam qualquer perda financeira, caso utilizassem o ARIMASp em suas previsões de demanda de eletricidade.

O terceiro ensaio desta tese estendeu a análise realizada pelo ensaio dois para o contexto multivariado. Neste ensaio foram estimados três modelos para prever a demanda regional de eletricidade, assim como estimar as elasticidades de preço, renda, número de unidades conectadas e temperatura. O exercício empírico de comparação entre os modelos painel dinâmico, SDM dinâmico e SAC-AR(1) revelou que o modelo espaço-temporal SDM dinâmico foi aquele com melhor *performance* preditiva. Esse fato corrobora os resultados dos dois ensaios anteriores ao confirmar a necessidade de modelar a dependência espacial nos modelos de previsão de demanda de energia elétrica no Brasil.

A alta inércia temporal verificada no consumo regional indica que as residências brasileiras possuem hábitos de consumo relativamente estáveis. A demanda de eletricidade mostrou-se inelástica em relação ao preço, à renda e ao número de unidades conectadas à rede. Devido às mudanças climáticas globais, a temperatura tornou-se um importante *driver* para os agentes do setor elétrico planejarem as variações na demanda. No caso brasileiro, o aumento da demanda de eletricidade ficará compreendido entre 0,90% e 1,49% como consequência do aquecimento global. Por fim, a presença de *spillovers* espaciais conclui que existe interação entre regiões vizinhas resultando em padrões aglomerativos de demanda regional de eletricidade residencial.

Conforme apontado pela revisão bibliográfica apresentada, apesar de alguns trabalhos evidenciarem a importância da inclusão do espaço na regressão para previsão de demanda de energia elétrica, ainda são escassos os estudos empíricos aplicados ao setor elétrico que incorporam a interação espacial em sua modelagem. Esta tese



contribuiu para a literatura de previsão de demanda de energia elétrica ao utilizar pioneiramente modelos econométrico-espaciais no Brasil. Além disso, demonstrou teoricamente como especificar a possível dependência espacial existente nos modelos de previsão de demanda de eletricidade a serem utilizados pelos agentes do Setor Elétrico Brasileiro. No contexto internacional, esta tese avançou metodologicamente tanto ao propor o modelo ARIMASp quanto ao utilizar o modelo espacial Durbin dinâmico para prever a demanda de energia elétrica.

Considerando os resultados dos três ensaios, é possível concluir que a interação espacial possui um papel importante na demanda de energia elétrica no Brasil e deve ser considerada pelos agentes para melhorar as previsões de demanda de eletricidade no Setor Elétrico Brasileiro. Os modelos espaço-temporais possuem *performance* preditiva superior aos modelos amplamente utilizados pelos agentes do Setor Elétrico até então. Diante disso, recomenda-se a utilização dos modelos espaço-temporais como ferramentas alternativas de previsão à Agência Nacional de Energia Elétrica, à Empresa Brasileira de Pesquisa Energética, ao Operador Nacional do Sistema Elétrico Brasileiro e às Distribuidoras.

Por fim, os resultados aqui relatados inauguram uma nova agenda de pesquisa para outras áreas do setor de energia nas quais previsões acuradas são importantes, tais como previsões de vazões, de radiação solar e de vento.

## REFERÊNCIAS

- ALFARES, H. K. e NAZEERUDDIN, M., 2002, “Electric Load Forecasting: literature survey and classification of methods,” *International Journal of Systems Science*, v. 33, n. 1, pp. 23-34.
- ALMESHAI EI, E. A., SOLTAN, H., 2011, “A methodology for Electric Power Load Forecasting”, *Alexandria Engineering Journal*, v. 50, pp. 137–144.
- ANDERSON, K.P., 1973, *Residential energy use: an econometric analysis*, In: The Rand Corporation, Santa Monica, California, EUA.
- ANDRADE, T.A., LOBÃO, W. J. A. *Elasticidade-Renda e Preço da Demanda Residencial de Energia Elétrica no Brasil*, IPEA Texto para Discussão nº 489. 1997.
- ANDRADE, F.F., CAMARGO, C.C.B. e TEIVE, R.C.G., “Previsão da Demanda de Consumidores Industriais de Energia Elétrica no Médio Prazo Baseada em Variáveis Econômicas e Climáticas”. *XVIII Congresso Brasileiro de Automática*, Bonito, MS, Brasil, setembro 2010.
- ANDRADE, L. C. M., 2010, *Abordagem NeuroFuzzy para Previsão de Demanda de Energia Elétrica no Curtíssimo Prazo*. Dissertação de M.Sc., Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, SP, Brasil.
- ANDRADE, L. C. M., FLAUZINO, R. A. e SILVA, I. N. “Sistemas Fuzzy para Previsão de Demanda de Energia Elétrica no Curtíssimo Prazo”. *9th Brazilian Conference on Dynamics Control and their Applications*, Serra Negra, Brasil, junho 2010.
- ARISOY, I., OZTURK, I., 2014, “Estimating industrial and residential electricity demand in Turkey: A time varying parameter approach.” *Energy*, v. 66, pp. 959-964.
- BAKIRTAS T.; KARBUZ S.; BILDIRICI M. “An econometric analysis of electricity demand in Turkey”. *METU Studies in Development (27/1-2)*, Ankara Turkey, 2000.
- BAKIRTZIS, A.G., PETRIDIS, V., KIARTZIS, S.J., 2006, A neural network short-term load forecasting model for the greek power system. *IEEE Transactions on Power Systems*, v. 11, pp. 858–863.
- BARAKAT, E. H.; QAYYUM, M. A.; HAMED, M. N. et al., 1990, “Short-term peak demand forecasting in fast developing utility with inherent dynamic load characteristics”. *IEEE Transactions on Power Systems*, v. 5, pp. 813-824.
- BASSI, D. e OLIVARES, O., 2006, “Medium Term Electric Load Forecasting Using TLFN Neural Networks”. *International Journal of Computers, Communications & Control*. V. I, n. 2, pp. 23-32.
- BLÁZQUEZ GOMEZ, L. M., FILIPPINI, M., HEIMSCH, F. Regional impact of changes in disposable income on Spanish electricity demand: A spatial econometric analysis. *Energy Economics*. 2013;40:S58–S66.
- BRASIL. Lei nº 10.848, de 15 de março de 2004. Dispõe sobre a comercialização de energia elétrica, altera as Leis nos 5.655, de 20 de maio de 1971, 8.631, de 4 de março

de 1993, 9.074, de 7 de julho de 1995, 9.427, de 26 de dezembro de 1996, 9.478, de 6 de agosto de 1997, 9.648, de 27 de maio de 1998, 9.991, de 24 de julho de 2000, 10.438, de 26 de abril de 2002, e dá outras providências. *Diário Oficial da República Federativa do Brasil*, Brasília, DF, 16 mar. 2004. Disponível em: <<http://www.aneel.gov.br/>>. Acesso em: janeiro de 2017.

BRASIL. Decreto nº 5.163, de 30 de julho de 2004. Regulamenta a comercialização de energia elétrica, o processo de outorga de concessões de autorizações de geração de energia elétrica, e dá outras providências. *Diário Oficial da República Federativa do Brasil*, Brasília, DF, 26 jul. 2005. Disponível em: <<http://www.aneel.gov.br/>>. Acesso em: janeiro de 2017.

CHEN, J. F.; WANG, W.M., HUANG, C. M., 1995, “Analysis of an adaptive time-series autoregressive moving-average (ARMA) model for short-term load forecasting”. *Electric Power Systems Research*, v. 34.

CHEN, N., WENCONG, L., YANG, J., LI, G., 2004, *Support Vector Machine in Chemistry*. 1 ed., Singapura, World Scientific Publishing Company.

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*. 2015;49:182–191.

CHO, M.Y.; HWANG, J.C.; CHEN, C.S. “Customer short-term load forecasting by using ARIMA transfer function model”. *Proceedings of the International Conference on Energy Management and Power Delivery*, pp. 317–322, 1995.

CHRISTIAANSE, W. R., 1971, “Short-Term Load Forecasting Using General Exponential Smoothing”, *IEEE Transactions on Power Apparatus and Systems*, v. 90, n. 2 (Mar/Abr).

EL-KEIB, A. A.; MA, X.; MA, H., 1995, “Advancement of statistical based modeling for short-term load forecasting”. *Electric Power Systems Research*, v. 35.

ELRAZAZ, Z. S., MAZI, A. A., 1989, “Unified weekly peak load forecasting for fast growing power system”. *IEE Proceedings*, v. 136.

FAN, J.Y.; MCDONALD, J.D., 1994, “A real-time implementation of short-term load forecasting for distribution power systems”, *IEEE Transactions on Power Systems*, v. 9, pp. 988–994.

FISHER, F.M., KAYSEN, C., 1962, *A Study in Econometrics: The Demand for Electricity in the United States*, Amsterdam, North-Holland.

GARCEZ, E.W.; GHIRARDI, A.G., 2003, “Elasticidades da demanda residencial de energia elétrica”, In *Encontro ANPEC*.

GHIASSI, M., ZIMBRA, D.K., e SAIDANE, H., 2006, “Medium term system load forecasting with a dynamic artificial neural network model”, *Electric Power Systems Research*, v. 76, pp. 302–316.

- GREWAL, M.S; ANDREWS, A.P., 2008, *Kalman Filtering Theory and Practice Using MATLAB*, 3ed., New Jersey, John Wiley & Sons.
- HAHN, H.; MEYER-NIEBERG, S.; PICKL, S., 2009, “Electric load forecasting methods: Tools for decision making”, *European Journal of Operational Research*, v.199, pp. 902–907.
- HOUTHAKKER, H. S., 1951, “Some calculations of electricity consumption in great Britain”, *Journal of the Royal Statistical Society*.
- HOUTHAKKER, H. S.; TAYLOR, L. D., 1970, *Consumer Demand in the United States 1929-1970, Analysis and Projections*, 2ed., Harvard University Press.
- HOUTHAKKER, H.S., VERLEGER, P.K. AND SHEEHAN, D.P., 1974, “Dynamic Demand Analyses for Gasoline and Residential Electricity”, *American Journal of Agricultural Economics*, v. 56, pp. 412-418.
- HUANG, S. R., 1997, “Short-term load forecasting using threshold autoregressive models”. *IEE Proceedings: Generation, Transmission, and Distribution*, v. 144, pp. 477-481.
- HUNT, S.; SHUTTLEWORTH, G., 1996, *Competition and Choice in Electricity*, 1 ed., New York, J. Wiley.
- INFIELD, D. G.; HILL, D. C., 1998, “Optimal smoothing for trend removal in short term electricity demand forecasting”. *IEEE Transactions on Power Systems*, v. 13, pp. 1115-1120.
- INGLESI-LOTZ, R., 2011, “The evolution of price elasticity of electricity demand in South Africa: A Kalman filter application”. *Energy Policy* v. 39, pp. 3690–3696.
- IRFFI, G.; CASTELAR, I.; SIQUEIRA, M. L et al., 2009, “Previsão da demanda por energia elétrica para classes de consumo na região Nordeste usando OLS dinâmico e mudança de regime”, *Economia Aplicada*, v. 13, n. 1, pp. 69-98.
- JAMIL, F.; AHMAD, E., 2011, “Income and price elasticities of electricity demand: Aggregate and sector-wise analyses” *Energy Policy*, v. 39, pp. 5519-5527.
- JUBERIAS, G.; YUNTA, R.; GARCIA MORINO, J. et al., 1999, “A new ARIMA model for hourly load forecasting”. *IEEE Transmission and Distribution Conference Proceedings*, v. 1, pp. 314-319.
- KIARTZIS, S.J.; BAKIRTZIS, A.G., 2000, “A fuzzy expert system for peak load forecasting: Application to the greek power system”, In: *Proceedings of the 10th Mediterranean Electrotechnical Conference*, pp. 1097–1100.
- KRYKHTINE, F. L. P., MORIM, A. C. D., VALE, N. G. P., et al. “Aplicando Lógica Fuzzy em um Modelo de Seleção Multicritério para Multiclientes”. *Gestão e Tecnologia para a Competitividade*, Rio de Janeiro, RJ, Brasil, 23-25 Outubro 2013.
- LEITE, S. Q., 2006, *Projeções para a demanda por energia elétrica no Brasil, 2006-2015*. Dissertação M.Sc. Faculdades Ibmecc, Rio de Janeiro, Brasil.

- LIM, K-M.; LIM, S-Y.; YOO, S-H., et al., 2014, “Short- and long-run elasticities of electricity demand in the Korean service sector”, *Energy Policy*, v. 67, pp. 517–521.
- LIU, K.; SUBBARAYAN, S.; SHOULTS, R. R. *et al.*, 1996, “Comparison of very short-term load forecasting”. *IEEE Transactions on Power Systems*, v. 11, pp. 877-882.
- LOTERO, R. C., 1999. *A Eficiência Econômica na Reestruturação do Setor Elétrico Brasileiro: uma abordagem através da economia dos custos de transação*. Tese D. Sc., Programa de Pós-Graduação em Engenharia de Produção, Universidade Federal de Florianópolis, Santa Catarina, Brasil.
- LYMAN, R. A., 1973, “*Price Elasticities in the Electric Power Industry, Department of Economics*”, University of Arizona.
- MCDONALD, J. R., LO, K. L., SHERWOOD, P. M., 1989, “Application of short-term adaptive forecasting techniques in energy management for the control of electric load”. *Transactions of the Institute of Measurement and Control*, v. 11, pp. 79-91.
- MIRANDA, V.; MONTEIRO, C., 2000, “Fuzzy inference in spatial load forecasting”. In *Proceedings of IEEE Power Engineering Winter Meeting*, pp. 1063–1068.
- MODIANO, E. M., 1984, *Elasticidade renda e preços da demanda de energia elétrica no Brasil*. Rio de Janeiro: Departamento de Economia da PUC. (Texto para Discussão, n. 68).
- MOGHRAM, I. e RAHMAN, S., 1989, “Analysis and evaluation of five short-term load forecasting techniques”. *IEEE Transactions on Power Systems*, v. 4, pp. 1484-1491.
- MORAN, P.A.P. Some Theorems on Time Series: II The Significance of the Serial Correlation Coefficient. *Biometrika*. 1948;35(3/4):255-60.
- OHTSUKA, Y., OGA, T., KAKAMU, K. Forecasting electricity demand in Japan: A Bayesian spatial autoregressive ARMA approach. *Computational Statistics and Data Analysis*. 2010;54:2721-35.
- OHTSUKA, Y., KAKAMU, K. Space-Time Model Versus VAR Model: Forecasting Electricity Demand in Japan. *Journal of Forecasting*. 2013;32:75–85.
- PARK, D. C.; EL-SHARKAWI, M. A.; MARKS, R. J. et al., 1991, “Electric load forecasting using an Artificial Neural Network”. *IEEE Transactions on Power Systems*, v. 6, pp. 442-449.
- SANTOS, C. S., 2003, *A Regulação da Distribuição de Energia Elétrica Brasileira: relações entre agências e a qualidade dos serviços de concessionárias*. Tese D.Sc., Universidade Federal da Bahia, Escola de Administração, Salvador, Bahia, Brasil.
- SILVA, M.F.A., 2007, *Modelo para planejamento de demanda de energia elétrica considerando o comportamento dos consumidores nos ambientes de contratação*. Dissertação M.Sc., Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal do Rio Grande do Sul, Porto Alegre, Brasil.
- SINGH, A. K., IBRAHEEM, KHATOON, S. et al., 2013, “An Overview of Electricity Demand Forecasting Techniques”, *Network and Complex Systems*, v.3, n.3, pp. 38-48.

- SOUZA, F.C. and LEGEY, L.F.L. Dynamics of risk management tools and auctions in the second phase of the Brazilian Electricity Market reform. *Energy Policy*. 2010;38:1715-33.
- TAO, X.; RENMU, H.; PENG, W. et al. "Input Dimension Reduction for Load Forecasting based on Support Vector Machines," In *Proc. IEEE Int. Conf. Elect. Utility Deregulation, Restruct. Power Tech*, Hong Kong, pp. 510–514, 2004.
- TAYLOR, L. D., 1975, "The Demand for electricity: a Survey", *The Bell Journal of Economics*, v. 6, pp. 74-110.
- TAYLOR, L., 1977, *The Demand for Energy: A Survey of Price and Income Elasticities*, In *International Studies of the Demand for Energy*, W.D. Nordhaus (editor). Amsterdam: North Holland.
- TORRINI, F. C.; SOUZA, R. C.; CYRINO OLIVEIRA, F. L.; MOREIRA PESSANHA, J. F. et al., 2016, "Long term electricity consumption forecast in Brazil: A fuzzy logic approach", *Socio-Economic Planning Sciences*, v. 54, pp. 18-27.
- WILLIS, H.L., 2002, *Spatial Electric Load Forecasting*, 2.ed., New York, Marcel Dekker.
- WILLS, J., 1977, *Residential Demand for Electricity in Massachusetts*, Working Paper n. MIT-EL 77-016WP.
- WILSON, J W., 1971, "Residential demand for electricity", *Quartely Review of economic and Business*, v.11 n.1, pp. 7-12.
- YANG, H.T., HUANG, C.M., HUANG, C.L., 1996, "Identification of ARMAX model for short-term load forecasting: An evolutionary programming approach", *IEEE Transactions on Power Systems*, v. 11, pp. 403–408.
- ZADEH, L. A., 1965, "Fuzzy Sets", *Information and Control*, pp. 338-353.
- ZAHEDI G, AZIZI S, BAHADORI A, ALKAMEL A, WAN ALWI SR., 2013, "Electricity demand estimation using an adaptive neuro-fuzzy network: a case study from the Ontario province e Canada", *Energy* v. 49, pp. 323-328.
- ZHAO, H.; REN, Z., HUANG, W., 1997, "Short-term load forecasting considering weekly period based on periodical auto regression". *Proceedings of the Chinese Society of Electrical Engineers*, v. 17, pp. 211-213.
- ZHENG, T., GIRGIS, A. A., MAKRAM, E. B., 2000, "A hybrid wavelet Kalman filter method for load forecasting". *Electric Power Systems Research*, v. 54, pp. 11-17.
- ZHOU, S.; TENG, F. "Estimation of urban residential electricity demand in China using household survey data". *Energy Policy*, 2013, vol. 61, issue C, pages 394-402.

## Referências do Ensaio 1

- ALMEIDA, E. *Econometria Espacial Aplicada*, 1 ed., Campinas, Editora Alínea, 2012.
- AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA (Brasil) (ANEEL). Aspectos Institucionais: Sistema Interligado Nacional. Disponível em: <[http://www2.aneel.gov.br/aplicacoes/atlas/aspectos\\_institucionais/2\\_1\\_1.htm](http://www2.aneel.gov.br/aplicacoes/atlas/aspectos_institucionais/2_1_1.htm)>. Acesso em: 04 de janeiro de 2017.
- ANSELIN, L. *Spatial econometrics: methods and models*. 1 ed., Boston, Kluwer Academic, 1988.
- ANSELIN, L. Spatial Dependence and Spatial Structural Instability in Applied Regression Analysis, *Journal of Regional Science*, Vol.30, n.2, p.185-207, 1990.
- ANSELIN, L., Interactive techniques and exploratory spatial data analysis. In: P. Longley, M. Goodchild, D. Maguire and D. Rhind (Eds.), *Geographical Information Systems: Principles, Techniques, Management and Applications*, 1 ed., New York, Wiley, 1999.
- ANSELIN, L. e BERA, A. “Spatial dependence in linear regression models with an introduction to spatial econometrics” In: ULLAH, A. e GILES, D. E. (eds). *Handbook of applied economic statistics*. New York, Marcel Dekker, 1998.
- ARBIA, G., *Introductory Spatial Econometrics with Application to Regional Convergence*. Springer-Verlag, 2005.
- ARBIA, G. *Spatial Econometrics*. Springer, 2006.
- ARBIA, G.; PIRAS, G. *Convergence in per-capita GDP across European regions using panel data models extended to spatial autocorrelation effects*. ISAE Working Papers 51, ISTAT - Italian National Institute of Statistics - (Rome, ITALY), 2005.
- BAILEY, T.; GATRELL, A. *Interactive Spatial Data Analysis*. London, Longman Scientific and Technical, 413 p., 1995.
- BALTAGI, B.H., SONG, S.H., KOH, W. Testing panel data regression models with spatial error correlation. *Journal of Econometrics*. Vol. 117, p. 123–150, 2003.
- BALTAGI, B.H.; SONG, S.H.; JUNG, B.C.; KOH, W. Testing for Serial Correlation, Spatial Autocorrelation and Random Effects Using Panel Data. *Journal of Econometrics*, Vol. 140, n. 1, p. 5-51, 2007.
- BAUMONT, C. *Spatial effects in housing price models: do house prices capitalize urban development policies in the agglomeration of Dijon (1999)?* Université de Bourgogne, 2004.
- FISCHER MM, GETIS A. *Handbook of applied spatial analysis: software tools, methods and applications*. Springer Verlag; 2010
- FISCHER MM, WANG J. *Spatial data analysis: models, methods and techniques*. Springer; 2011
- DIEESE, Departamento Intersindical de Estatística e Estudos Socioeconômicos. *Boletim do Setor Elétrico*. Maio, 2013.
- FOTHERINGHAM, A.S.; BRUNSDON, C.; CHARLTON, M.E. *Geographically Weighted Regression: The Analysis of Spatially Varying Relationships*, Chichester: Wiley, 2002.

- HSIAO, C. *Analysis of Panel Data*. Cambridge: Cambridge University Press, Second Edition, 2003.
- LE GALLO, J.; ERTUR, C. Exploratory spatial data analysis of the distribution of regional per capita GDP in Europe, 1980-1995. *Papers in Regional Science*, v. 82. p. 175-201, 2003.
- LESAGE, J. P.; PACE, R. K. *Introduction to Spatial Econometrics*. CRC Press, Boca Raton, 2009.
- LONG, R., SHAO, T., CHEN, H. Spatial econometric analysis of China's province-level industrial carbon productivity and its influencing factors. *Applied Energy*. 2016;166:210-9.
- MORAN, P.A.P. Some Theorems on Time Series: II The Significance of the Serial Correlation Coefficient. *Biometrika*, Vol. 35, No. 3/4, p. 255-260, 1948.
- REN, T.; LONG, Z.; ZHANG, R.; CHEN, Q. Moran's I test of spatial panel data model - Based on bootstrap method. *Economic Modelling*, Vol. 41, p. 9-14, 2014.
- SALISU, A.; OLOFIN, S.; KOUASSI, E. Testing for Cross-Sectional Dependence in a Random Effects Model. *Open Journal of Statistics*, Vol. 2, p. 88-97, 2012.
- TIAN W, SONG J, LI Z. Spatial regression analysis of domestic energy in urban areas. *Energy*. 2014;76:629-40.
- WANG, S., WANG, S. Spatial interaction models for biomass consumption in the United States. *Energy*. 2011;36:6555-8.
- WOOLDRIDGE, J. M. *Econometric Analysis of Cross Section and Panel Data*, 1 ed., MIT Press, 2002.

## Referências do Ensaio 2

- ANSELIN, L. *Spatial econometrics: methods and models*. 1 ed, Boston: Kluwer Academic, 1988.
- ANSELIN, L.; BERA, A. Spatial dependence in linear regression models with an introduction to spatial econometrics. In: Ullah A, and Giles D, E, (eds,) *Handbook of Applied Economic Statistics*, Marcel Dekker, New York; 1998, p. 237-289.
- BLUM, H.; LEGEY, L. F. L. The challenging economics of energy security: Ensuring energy benefits in support to sustainable development. *Energy Economics*, 2012;34:1982-9.
- BOX, G. E. P.; JENKINS, G. M. *Time series analysis forecasting and control*. Holden-Day, San Francisco, 1976.
- DICKEY, D.; FULLER, W. Distribution of the estimators for autoregressive time series with a unit root. *Journal of the American Statistical Association*, 1979;74(366):427-431.
- ENDERS, W. *Applied Econometric Time Series*. 3rd ed, New York: John Wiley & Sons, 2010.



- HAHN, H.; MEYER-NIEBERG, S.; PICKL, S. Electric load forecasting methods: Tools for decision making. *European Journal of Operational Research*, 2009, 199:902–7.
- HAMILTON, J. D. *Time Series Analysis*. Princeton: Princeton University Press, 1994.
- OHTSUKA, Y.; OGA, T.; KAKAMU, K. Forecasting electricity demand in Japan: A Bayesian spatial autoregressive ARMA approach. *Computational Statistics and Data Analysis*, 2010;54:2721-35.
- OHTSUKA, Y.; KAKAMU, K. Space-Time Model Versus VAR Model: Forecasting Electricity Demand in Japan. *Journal of Forecasting*, 2013;32:75–85.
- PIRES, J.C.L. *The Reform Process within the Brazilian Electricity Sector*. BNDES/PNUD, Brasília-DF, 1999, Available at [http://www.bnades.gov.br/SiteBNDES/export/sites/default/bndes\\_en/Galerias/Download/studies/studie01.pdf](http://www.bnades.gov.br/SiteBNDES/export/sites/default/bndes_en/Galerias/Download/studies/studie01.pdf), 1999.
- SOUZA, F.C.; LEGEY, L.F.L. Dynamics of risk management tools and auctions in the second phase of the Brazilian Electricity Market reform. *Energy Policy*, 2010;38:1715-33.

### Referências do Ensaio 3

- ALMESHAI EI, E.A.; SOLTAN, H. 2011, “A methodology for Electric Power Load Forecasting”, *Alexandria Engineering Journal*, v. 50, pp. 137–144.
- AMARAWICKRAMA, H.A.; HUNT, L.C., 2008, “Electricity demand for Sri Lanka: A time series analysis”, *Energy*, v. 33, pp.724–739.
- ANDERSON, K.P. 1973. *Residential energy use: an econometric analysis*, In: The Rand Corporation, Santa Monica, California, EUA.
- ANDRADE, T.A.; LOBÃO, W.J. A. *Elasticidade-Renda e Preço da Demanda Residencial de Energia Elétrica no Brasil*, IPEA Texto para Discussão nº 489. 1997.
- ARELLANO, M.; BOND, S. 1991. “Some tests of specification for panel data: Monte Carlo evidence and an application to employment equations”. *Review of Economic Studies* 58: 277-297.
- ARELLANO, M.; BOVER, O..1995. “Another look at the instrumental variable estimation of error-components models”. *Journal of Econometrics* 68: 29-51.
- ARISOY, I. OZTURK, I., 2014, “Estimating industrial and residential electricity demand in Turkey: A time varying parameter approach”. *Energy*, v. 66, pp. 959-964.
- BADINGER H.; MÜLLER W.G.; TONDL G., 2004, “Regional convergence in the European Union 1985-1999: a spatial dynamic panel analysis”. *Regional Studies*, v. 38, pp. 241-253.
- BALTAGI, B.H., 2008, “Forecasting with Panel Data”. *Journal of Forecasting*, v. 27, pp. 153–173.
- BEENSTOCK, M.; FELSENSTEIN, D. 2007, “Spatial Vector Autoregressions”, *Spatial Economic Analysis*, v. 2, pp. 167-196.

- BLÁZQUEZ GOMEZ, L. M., FILIPPINI, M., HEIMSCH, F. “Regional impact of changes in disposable income on Spanish electricity demand: A spatial econometric analysis”. *Energy Economics*. 2013;40:S58–S66.
- BLUNDELL, R.; BOND, S. 1998. “Initial conditions and moment restrictions in dynamic panel data models”. *Journal of Econometrics* 87: 115-143.
- CHRISTIAANSE, W. R. (1971). “Short-term load forecasting using general exponential smoothing”. *IEEE Transactions on Power Apparatus and Systems*, PAS-90, 900 – 902.
- CHO, S.-H., TAEYOUNG, K., HYUN, J. K., KIHYUN, P., ROLAND, K. R. “Regionally-varying and regionally-uniform electricity pricing policies compared across four usage categories”. *Energy Economics*. 2015;49:182–191.
- DEBARSY, N.; ERTUR, C.; LESAGE, J.P. “Interpreting dynamic space-time panel data models”. *Statistical Methodology*. 2012;9(1–2):158–171.
- DEPAULA, G.; MENDELSON, R.O. “Development and the Impact of Climate Change on Energy Demand: Evidence from Brazil” 2010. *Climate Change Economics (CCE)*, Forthcoming. Available at SSRN: <https://ssrn.com/abstract=1856403>.
- ELHORST, J.P. (2010) “Dynamic panels with endogenous interaction effects when T is small”. *Regional Science and Urban Economics* 40(5):272-282.
- ELHORST, J.P. *Spatial Econometrics from Cross-Sectional Data to Spatial Panels*. SpringerBriefs in Regional Science: Heidelberg, 2010.
- EL-KEIB, A. A.; MA, X.; MA, H., 1995, “Advancement of statistical based modeling for short-term load forecasting”. *Electric Power Systems Research*, Volume 35, Issue 1, October 1995, Pages 51-58.
- ELRAZAZ, Z. S.; MAZI, A. A. “Unified weekly peak load forecasting for fast growing power system”. *IEE Proceedings D C*, 136, 1989, pp. 29-41.
- EMPRESA DE PESQUISA ENERGÉTICA – EPE - (Brasil). Balanço Energético Nacional 2016: Ano base 2015 / Empresa de Pesquisa Energética. – Rio de Janeiro : EPE, 2016. Brazilian Energy Balance 2016 Year 2015 / Empresa de Pesquisa Energética – Rio de Janeiro: EPE, 2016. 292 p. Disponível em: [https://ben.epe.gov.br/downloads/Relatorio\\_Final\\_BEN\\_2016.pdf](https://ben.epe.gov.br/downloads/Relatorio_Final_BEN_2016.pdf)
- FRANCISCO, C.M. *Connecting Renewable Power Plant to the Brazilian Transmission Power System*. The institute of Brazilian business and public management issues, The Minerva program, Washington, DC, USA, 2012.
- GARCEZ, E.W.; GHIRARDI, A.G., 2003, “Elasticidades da demanda residencial de energia elétrica”, In Encontro ANPEC.
- GARCÍA-ASCANIO, C.; MATÉ, C. “Electric power demand forecasting using interval time series: A comparison between VAR and iMLP”. *Energy Policy*, 2010, vol. 38, issue 2, pages 715-725.
- HOUTHAKKER, H. S., 1951, “Some calculations of electricity consumption in great Britain”, *Journal of the Royal Statistical Society*.
- HOUTHAKKER, H. S., 1980, “Residential Electricity Revisited”, *The Energy Journal*, v. 1, n. 1.

- HOUTHAKKER, H. S.; TAYLOR, L. D., 1970, *Consumer Demand in the United States 1929-1970, Analysis and Projections*, 2ed., Harvard University Press.
- HOUTHAKKER, H.S., VERLEGER, P.K. AND SHEEHAN, D.P., 1974, “Dynamic Demand Analyses for Gasoline and Residential Electricity”, *American Journal of Agricultural Economics*, v. 56, pp. 412-418.
- HAUSMAN, J. A. “Specification tests in econometrics”. *Econometrica*, vol. 46, n. 6, p. 1251– 1272, 1978.
- HOLLANDA, L., DIAS, V. P., SARAIVA, J. D. Essays on Economic Regulation: Chapter 2 – A Microdata Approach to Household Electricity Demand in Brazil Rio de Janeiro: Escola de Pós-Graduação em Economia da Fundação Getulio Vargas (EPGE), 2012. (Tese de doutorado).
- INFIELD, D. G.; HILL, D. C., 1998, “Optimal smoothing for trend removal in short term electricity demand forecasting”. *IEEE Transactions on Power Systems*, v. 13, pp. 1115-1120.
- IRFFI, G.; CASTELAR, I.; SIQUEIRA, M. L et al., 2009, “Previsão da demanda por energia elétrica para classes de consumo na região Nordeste usando OLS dinâmico e mudança de regime”, *Economia Aplicada*, v. 13, n. 1, pp. 69-98.
- JEENINGA, H., HUENGES WAJER, B.P.F. 1999. “Domestic electricity consumption and life style”. *European Council for an Energy Efficient Economy (ECEEE) Summer Study Proceedings*  
<[http://www.eceee.org/library/conference\\_proceedings/eceee\\_Summer\\_Studies/1999/Panel\\_3/p3\\_7](http://www.eceee.org/library/conference_proceedings/eceee_Summer_Studies/1999/Panel_3/p3_7)>.
- JUBERIAS, G.; YUNTA, R.; GARCIA MORINO, J. *et al.*, 1999, “A new ARIMA model for hourly load forecasting”. *IEEE Transmission and Distribution Conference Proceedings*, v. 1, pp. 314-319.
- LESAGE, J. P.; PACE, R. K. *Introduction to Spatial Econometrics*. CRC Press, Boca Raton, 2009.
- LEE L.F.; YU, J. 2010. Some Recent Developments in Spatial Panel Data Models. *Regional Science and Urban Economics*. Volume 40, Issue 5, September 2010, Pages 255–271.
- LIM, K-M.; LIM, S-Y.; YOO, S-H., *et al.*, 2014, “Short- and long-run elasticities of electricity demand in the Korean service sector”, *Energy Policy*, v. 67, pp. 517–521.
- MODIANO, E. M., 1984, *Elasticidade renda e preços da demanda de energia elétrica no Brasil*. Rio de Janeiro: Departamento de Economia da PUC. (Texto para Discussão, n. 68).
- OHTSUKA, Y.; OGA, T.; KAKAMU, K. “Forecasting electricity demand in Japan: A Bayesian spatial autoregressive ARMA approach”. *Computational Statistics and Data Analysis*, 2010;54:2721-35.
- PESARAN, M.H. (2004) “General Diagnostic Tests for Cross Section Dependence in Panels”. IZA Discussion Paper No. 1240.
- REY, S. J., MONTOURI, B. D., 1999, “US regional income convergence: A spatial econometric perspective”, *Regional Studies*. v. 33, n.2, pp. 143-156.

- RODRIGUES, L. A.; FERES, J. G.; MATTOS, L. B. . “Aquecimento Global e a Demanda Residencial de Energia Elétrica no Brasil”. In: *41 Encontro Nacional de Economia da ANPEC, 2013*, Foz do Iguaçu. Foz 41 ANPEC, 2013. v. 41.
- SCHMIDT, C. A. J.; LIMA, M. A. “A demanda por energia elétrica no Brasil”. *Revista Brasileira de Economia*, Rio de Janeiro, v. 58, n.1, p. 67-98, Jan./Mar. 2004.
- SOUZA, F.C.; LEGEY, L.F.L. “Brazilian electricity market structure and risk management tools”. *IEEE Power and Energy Society General Meeting—Conversion and Delivery of Electrical Energy in the 21st Century*, 459631; 2008 July 20–24; Pittsburgh, Pennsylvania, USA.
- SOUZA, F.C. and LEGEY, L.F.L. Dynamics of risk management tools and auctions in the second phase of the Brazilian Electricity Market reform. *Energy Policy*. 2010;38:1715-33.
- TAYLOR, L. D., 1975, “The Demand for electricity: a Survey”, *The Bell Journal of Economics*, v. 6, pp. 74-110.
- WILSON, J W., 1971, “Residential demand for electricity”, *Quartely Review of economic and Business*, v.11 n.1, pp. 7-12.
- WOOLDRIDGE, J.M. *Econometric Analysis of Cross Section and Panel Data*, 1<sup>st</sup> ed,, MIT Press, 2002.
- ZHOU, S.; TENG, F. “Estimation of urban residential electricity demand in China using household survey data”. *Energy Policy*, 2013, vol. 61, issue C, pages 394-402.