

UNIVERSIDADE FEDERAL DE ALFENAS

ULISSES DE SOUZA LIMA

**ANÁLISE ESPACIAL DA PRODUÇÃO MADEIREIRA PROVENIENTE DA
SILVICULTURA NOS ANOS DE 2009 E 2018**

Alfenas/MG

2020

ULISSES DE SOUZA LIMA

ANÁLISE ESPACIAL DA PRODUÇÃO MADEIREIRA PROVENIENTE DA
SILVICULTURA NOS ANOS DE 2009 E 2018

Dissertação apresentada como parte dos requisitos para obtenção do título de Mestre em Estatística Aplicada e Biometria pela Universidade Federal de Alfenas. Área de concentração: Estatística Aplicada e Biometria.

Orientador: Prof^a. Dr^a. Patrícia de Siqueira Ramos

Alfenas/MG

2020

Dados Internacionais de Catalogação-na-Publicação (CIP)
Sistema de Bibliotecas da Universidade Federal de Alfenas
Biblioteca Central – Campus Sede

L732a Lima, Ulisses de Souza
Análise espacial da produção madeireira proveniente da silvicultura nos anos de 2009 e 2018 / Ulisses de Souza Lima – Alfenas, MG, 2020.
72 f.: il. –

Orientadora: Patrícia de Siqueira Ramos.
Dissertação (Mestrado em Estatística Aplicada e Biometria) – Universidade Federal de Alfenas, 2020.
Bibliografia.

1. Agricultura Florestal. 2. Carvão Vegetal. 3. Ecologia florestal. I. Ramos, Patrícia de Siqueira. II. Título.

CDD- 577

Ulisses de Souza Lima

ANÁLISE ESPACIAL DA PRODUÇÃO MADEIREIRA PROVENIENTE DA SILVICULTURA NOS ANOS DE 2009 E 2018

A Banca examinadora abaixo-assinada aprova a Dissertação apresentada como parte dos requisitos para a obtenção do título de Mestre em Estatística Aplicada e Biometria pela Universidade Federal de Alfenas. Área de concentração: Estatística Aplicada e Biometria.

Aprovada em: 30 de setembro de 2020.

Profa. Dra. Patrícia de Siqueira Ramos
Instituição: Universidade Federal de Alfenas - UNIFAL-MG

Prof. Dr. Lincoln Thadeu Gouvêa de Frias
Instituição: Universidade Federal de Alfenas - UNIFAL-MG

Prof. Dr. Luiz Alberto Beijo
Instituição: Universidade Federal de Alfenas - UNIFAL-MG



Documento assinado eletronicamente por **Patrícia de Siqueira Ramos, Professor do Magistério Superior**, em 30/09/2020, às 17:05, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Luiz Alberto Beijo, Professor do Magistério Superior**, em 30/09/2020, às 17:26, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Lincoln Thadeu Gouvêa de Frias, Professor do Magistério Superior**, em 01/10/2020, às 14:23, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://sei.unifal-mg.edu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **0385313** e o código CRC **981741E3**.

AGRADECIMENTOS

Primeiramente, gostaria de agradecer a força maior que alguns chamam de Deus, outros Alá, uns Olorum e por aí vai. Sem essa energia espiritual talvez eu não teria capacidade de chegar até aqui.

Em seguida, mas não menos importante, gostaria de agradecer à minha querida família, especialmente pela perseverança no “ser possível”, em ir além, adiante das adversidades.

Mãe, obrigado pelo apoio, respeito, carinho e amor!

Pai (*in memoriam*), deu tudo certo!

Cris, bruxa da lua, aquela que dança com os lobos, sem a sua presença na minha vida nada disso teria sentido, te amo!

Agradecer aos meus filhos amados, Apolo e Dioniso (ainda um bebezinho na barriga da mamãe).

Meninas (Lali, Tatá e Aninha), obrigado pelos conselhos, ensinamentos e vivências, vocês são meus amores!

Gostaria de agradecer à Prof.^a Patrícia de Siqueira Ramos, pela generosidade, compreensão, dedicação, paciência e companheirismo. Acredito que essas são as virtudes das quais os grandes mestres são forjados. Sem o seu apoio esta jornada não seria realmente possível.

Agradecer também a todos os discentes e docentes do Programa de Pós-Graduação em Estatística Aplicada e Biometria (PPGEAB – UNIFAL/MG) com quem tive contato, em especial o Prof. Beijo, Prof. Fabrício, Prof. Denismar e o Prof. Eric, por serem parte importante na minha formação acadêmica.

Aos Professores Luiz Alberto Beijo e Lincoln Thadeu Gouvêa de Frias pelos direcionamentos apontados na conclusão deste trabalho. Me sinto verdadeiramente honrando pela participação de vocês, obrigado.

Aos amigos, que mesmo com a distância estão presentes todo dia no meu coração (Julita, Melzita, tia Mah, Tubia, Mamutrevas, Chainzeiras e o Curticeiras). Um abraço especial aos grandes amigos Vinicius e Daiane, pelo apoio, café e muita proza boa!

À Martha (PPGEAB), pelas várias vezes que me salvou. Valeu demais!

Enfim, gostaria de agradecer todos aqueles que de forma direta ou indireta contribuíram para a realização deste trabalho. Muito obrigado!

O presente trabalho foi realizado com o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

RESUMO

O setor de florestas plantadas com ênfase em produtos madeireiros exerce papel importante para a economia do Brasil, sendo um dos principais produtores mundiais. Os principais segmentos são os produtos de madeira em tora (celulose, serraria e painéis), madeira para carvão e lenha. A produção para essas finalidades é caracterizada por apresentar padrões espaciais entre as regiões produtoras. Portanto, o presente trabalho tem como objetivo analisar e verificar o comportamento em relação aos aspectos espaciais envolvidos na produção de madeira para lenha (m^3), tora (m^3) e carvão vegetal (toneladas) provenientes de plantios florestais nos municípios brasileiros entre os anos de 2009, caracterizado por uma profunda crise no setor de florestas plantadas, e o período mais atual, 2018, a partir do banco de dados da Produção de Extração Vegetal e Silvicultura (PEVS – IBGE). Dessa maneira, utilizou-se a análise exploratória de dados espaciais de área para verificar a existência de autocorrelação espacial entre a produção e os aglomerados de *clusters* espaciais obtidos através do índice global e local *I* de Moran e testados estatisticamente por meio do teste de pseudo-significância (1.000 permutações) com nível de significância de 5% ($\alpha = 0,05$). Os resultados obtidos demonstram que, além do fato da produção geral apresentar considerável crescimento entre os períodos analisados, existe dependência espacial positiva significativa para todas as variáveis analisadas. Assim, os padrões locais observados, principalmente em relação às aglomerações do tipo alto/alto, apresentam características relacionadas principalmente com as regiões onde a cadeia produtiva de celulose para madeira em tora, da indústria metalúrgica para o carvão vegetal e da produção agrícola de grãos no caso da lenha estavam bem estabelecidas no período. Portanto, o presente trabalho sugere que os grandes aglomerados produtivos para as variáveis da produção da silvicultura entre os anos de 2009 e 2018 estão presentes principalmente em grandes polos industriais, onde o mercado de madeira, de modo geral, atende à demanda regional.

Palavras-chave: Produção Florestal. Autocorrelação espacial. *I* de Moran.

ABSTRACT

The planted forest sector with an emphasis on wood products plays an important role for the economy of Brazil, being one of the main world producers. The main segments are roundwood products (cellulose, sawmill and panels), wood for charcoal and firewood. The production for these purposes is characterized by spatial patterns between the producing regions. Therefore, the present work aims to analyze and verify the behavior in relation to the spatial aspects involved in the production of firewood (m^3) in logs (m^3), coal (tons) from forest plantations in Brazilian municipalities between 2009, characterized by a deep crisis in the planted forest sector, and the most current period (2018) in the database of Vegetable Extraction and Silviculture (PEVS - IBGE). Thus, exploratory analysis of spatial area data was used to verify the existence of spatial autocorrelation between the production and also the spatial cluster obtained through Moran's I global and local index statistically tested by pseudo-significance test (1000 permutations) with a level of significance of 5% ($\alpha = 0,05$). The results obtained demonstrate that, in addition to the fact that the general production presents considerable growth between the analyzed periods, there is a significant positive spatial dependence for all variables and that the observed local patterns, mainly in relation to the high/high agglomerations, which have characteristics related mainly to the regions where the pulp production chain for roundwood (m^3), the metallurgy industry for charcoal (t) and agricultural production in the case of firewood (m^3) were well established in the period. Therefore, the present work suggests that the large productive clusters for the variables of forestry production between the years 2009 and 2018 are present mainly in large industrial hubs, where the wood market, in general, meets a regional demand.

Keywords: Forest Production. Spatial autocorrelation. Moran's I .

LISTA DE FIGURAS

Figura 1	– Tipos de convenção de contiguidade.....	24
Figura 2	– Áreas e matriz de proximidade contígua do tipo rainha.....	25
Figura 3	– Gráficos de dispersão de Moran.....	30
Figura 4	– Representação geográfica do valor global I de Moran (a) em relação ao Mapa LISA (b), para uma significância (α) qualquer.....	31
Figura 5	– Mapa do Brasil: áreas territoriais dos estados e municípios brasileiros.....	34
Figura 6	– Série histórica entre 2009 e 2018 da quantidade produzida de lenha (m^3) proveniente da silvicultura no Brasil.....	39
Figura 7	– Série histórica entre 2009 e 2018 da quantidade produzida de tora (m^3) proveniente da silvicultura no Brasil.....	40
Figura 8	– Série histórica entre 2009 e 2018 da quantidade produzida de tora (t) proveniente da silvicultura no Brasil.....	41
Figura 9	– Mapa de distribuição em relação aos municípios brasileiros da produção variável lenha da silvicultura (m^3) nos anos 2009 e 2018..	42
Figura 10	– Mapa de distribuição em relação aos municípios brasileiros da produção variável madeira em tora (m^3) nos anos 2009 e 2018.....	44
Figura 11	– Mapa de distribuição em relação aos municípios brasileiros da produção variável carvão vegetal (t) nos anos 2009 e 2018.....	46
Figura 12	– Diagramas de dispersão de Moran com os valores padronizados em relação ao ano de 2009 e 2018. Em que: a) Lenha proveniente da silvicultura (m^3); b) Madeira em tora (m^3); c) Carvão vegetal (t)...	48
Figura 13	– Mapa LISA ($\alpha = 0,05$) para a variável lenha (m^3) nos anos de 2009 e 2018.....	50
Figura 14	– Mapa LISA ($\alpha = 0,05$) para a variável lenha (m^3) com destaque para as regiões de maior importância no valor da produção nacional em relação aos clusters do tipo alto/alto em 2009.....	52
Figura 15	– Mapa LISA ($\alpha=0,05$) para a variável lenha (m^3) com destaque para a região de maior importância no valor da produção nacional em relação aos clusters do tipo alto/alto em 2018.....	53
Figura 16	– Mapa LISA ($\alpha = 0,05$) para a variável tora (m^3) nos anos de 2009 e 2018.....	54
Figura 17	– Mapa LISA ($\alpha=0,05$) para a variável madeira em tora (m^3) com destaque para a região de maior importância no valor da produção nacional em relação aos clusters do tipo alto/alto em 2009.....	56
Figura 18	– Mapa LISA ($\alpha=0,05$) para a variável madeira em tora (m^3) com destaque para a região de maior importância no valor da produção nacional em relação aos clusters do tipo alto/alto em 2018.....	57

Figura 19	– Mapa LISA ($\alpha=0,05$) para a variável produção de carvão vegetal (t) nos anos de 2009 e 2018.....	58
Figura 20	– Mapa LISA ($\alpha=0,05$) para a variável carvão vegetal (t) com destaque para a região de maior importância no valor da produção nacional em relação aos clusters do tipo alto/alto em 2009.....	60
Figura 21	– Mapa LISA ($\alpha=0,05$) para a variável carvão vegetal (t) com destaque para a região de maior importância no valor da produção nacional em relação aos clusters do tipo alto/alto em 2018.....	61

LISTA DE TABELAS

Tabela 1	– Estatísticas descritivas gerais da produção de madeira proveniente de plantios florestais no Brasil para finalidade de lenha (m ³), tora (m ³) e carvão vegetal (t) nos anos de 2009 e 2018.....	35
Tabela 2	– Valor do I de Moran global e seu respectivo valor-p para as variáveis deste estudo nos anos de 2009 e 2018.....	45
Tabela 3	– Número de municípios pertencentes aos quadrantes no diagrama de dispersão de Moran para as variáveis deste estudo nos anos de 2009 e 2018.....	47

SUMÁRIO

1	INTRODUÇÃO.....	14
2	REFERENCIAL TEÓRICO.....	16
2.1	A IMPORTÂNCIA DO SETOR FLORESTAL BRASILEIRO COM ÊNFASE NOS PRODUTOS MADEIREIROS MADEIREIRO ORIUNDOS DA SILVICULTURA.....	16
2.2	ANÁLISE ESPACIAL.....	18
2.3	ESTATÍSTICA ESPACIAL.....	19
2.3.1	Análise de dados de área.....	20
2.3.2	Análise Exploratória de Dados Espaciais.....	21
2.3.3	Autocorrelação Espacial.....	21
2.3.4	Matriz de Proximidade Espacial.....	23
2.3.5	Índice de I de Moran.....	25
2.3.5.1	I de Moran Global.....	25
2.3.5.2	I de Moran Local.....	27
2.3.5.3	Interferência sobre I de Moran Global e Local.....	28
2.3.5.4	Diagrama de dispersão de Moran.....	29
2.3.5.5	Mapa LISA.....	31
3	MATERIAL E MÉTODOS.....	33
3.1	ÁREA DE ESTUDO.....	33
3.2	DADOS.....	34
3.2	ANÁLISE.....	35
4	RESULTADOS E DISCUSSÃO.....	36
4.1	ANÁLISE DESCRITIVA.....	36
4.1.1	Mapas temáticos.....	41
4.1.1.1	Madeira para lenha (m ³).....	41
4.1.1.2	Madeira em tora (m ³).....	43
4.1.1.3	Carvão vegetal (t).....	45
4.2	ANÁLISE ESPACIAL.....	46
4.2.1	Índice de autocorrelação global e diagrama de dispersão.....	46
4.2.2	Mapas LISA.....	49
4.2.2.1	Madeira para lenha (m ³).....	50
4.2.2.2	Madeira em tora (m ³).....	54

4.2.2.3	Carvão vegetal (t).....	58
5	CONCLUSÃO.....	63
	REFERÊNCIAS.....	64
	APÊNDICES	69

1 INTRODUÇÃO

O Brasil representa um dos grandes produtores de madeira proveniente de plantios florestais. As características edafoclimáticas, relativas ao solo e clima, sua extensão territorial e o desenvolvimento tecnológico obtido nas áreas de silvicultura e manejo florestal fizeram do país um importante produtor mundial de florestas plantadas.

Deste modo, o setor de florestas plantadas do Brasil demonstra força diante do cenário macroeconômico atual. O PIB (Produto Interno Bruto) do setor para o ano de 2018 alcançou a marca de R\$ 73,8 bilhões, o que corresponde 1,1% do PIB nacional (IBÁ, 2018).

A atividade florestal compreende um variado conjunto de produtos e segmentos, que se caracterizam desde a produção até a transformação da madeira em celulose, papel, madeira serrada, carvão vegetal, lenha e painéis de madeira principalmente, além dos produtos não madeireiros. Cada uma dessas atividades em questão possuem uma dinâmica de mercado específica, em que as condições para o seu desenvolvimento estão associadas as regiões produtoras de floresta e determinada pela demanda e oferta de madeira.

Desse modo, conforme Moreira; Simioni; Oliveira (2017), faz-se necessário a formulação de estratégias específicas para cada região produtora em detrimento ao tipo de produto florestal característico a essas localidades. Dessa maneira, o uso da análise de dados espaciais vem a ser uma ferramenta essencial na compreensão dos fatores envolvidos na produção de madeira para as regiões produtoras, sendo capaz de propiciar análises de forma a encontrar certos padrões espaciais, auxiliando assim na elaboração dessas estratégias.

Nesse contexto, o presente estudo objetiva compreender, através da análise exploratória de dados espaciais, a forma como a produção de madeira advinda de plantações florestais no Brasil é afetada pela componente espacial em relação aos municípios, produtores ou não, vizinhos entre si. Foram comparados os anos de 2009, caracterizado pelo reflexo negativo da crise mundial de 2008, com o período mais atual até a publicação deste estudo, 2018, com a finalidade de comparar os padrões espaciais observados na produção de madeira em tora, lenha e carvão vegetal nos municípios brasileiros (PEVS – IBGE). Assim, para tal análise foram utilizados conceitos de estatística espacial para dados de área, onde o índice utilizado para

medir o efeito da dependência espacial foram I de Moran global e sua resultante local, importante na construção de mapas capazes de evidenciar o modo como as aglomerações espaciais se apresentam.

2 REFERENCIAL TEÓRICO

Nesse capítulo serão apresentados os fundamentos teóricos que orientaram esta pesquisa. Inicia-se com uma sessão sobre a importância do setor florestal brasileiro com ênfase nos produtos madeireiros oriundos da silvicultura. Em seguida discorre-se sobre os métodos quantitativos e descritivos da Análise Espacial. Por fim, contextualiza-se a Estatística Espacial, ressaltando os tópicos principais utilizados como a Análise Exploratória de Dados Espaciais, a Autocorrelação Espacial, a Matriz de Proximidade espacial e os Índices de *I* de Moran.

2.1 IMPORTÂNCIA DO SETOR FLORESTAL BRASILEIRO COM ÊNFASE NOS PRODUTOS MADEIREIROS ORIUNDOS DA SILVICULTURA

O setor florestal é considerado parte da sociedade atribuída ao uso e consumo dos recursos de base florestal, o que inclui grande diversidade de produtos e serviços, podendo serem obtidos diretamente da floresta, como principalmente madeira, resinas, óleos essenciais e frutos, ou de forma indireta, através dos serviços prestados pelas árvores e os ambientes florestais como consequência natural de seus efeitos sobre o meio (LADEIRA, 2002). Dessa maneira, o setor florestal é capaz de contribuir para o desenvolvimento de uma determinada região ou país, fornecendo produtos para consumo interno ou mesmo para exportação, auxiliando na geração de emprego e renda, na obtenção de receitas através da arrecadação de tributos e impostos, bem como na conservação dos recursos naturais (ARAUJO *et al.*, 2017).

Nesse contexto, o setor florestal brasileiro ocupa lugar de destaque diante o cenário mundial. Por se tratar de um país de proporção continental (o quinto maior do planeta), com grande cobertura de florestas e condições de solo e clima ideais para o cultivo de espécies arbóreas, o Brasil concentra grande quantidade de recursos florestais (MOREIRA; SIMIONI; OLIVEIRA 2017).

De acordo com o relatório da FAO (2015), o planeta possui aproximadamente 4 bilhões hectares de florestas existentes, e o Brasil apresenta 13% deste valor, o que garante a segunda posição entre os países com maior área de florestas no mundo, atrás somente da Rússia, com 20% do total. Ainda segundo o relatório, cerca de 60% de todo território brasileiro é coberto por florestas, das quais 57,4% são florestas naturais (nativas), incluindo a grande diversidade de formações vegetais naturais presentes, e os 1,6% restantes correspondem as áreas de florestas plantadas,

principalmente representadas por espécies comerciais de rápido crescimento.

Em relação às florestas naturais, o país detém a maior reserva de floresta tropical úmida do planeta (aproximadamente 30% do total), onde, além de possuir relevante importância quanto aos aspectos ambientais, do ponto de vista econômico, também apresenta elevado potencial produtivo (ARAGON, 2018). Estima-se que essa reserva possua em torno de 45 bilhões de metros cúbicos em capacidade de produção de madeira. Contudo, apesar de sua importância para o país, as florestas naturais do Brasil sofreram uma redução de mais de 15 milhões de hectares desde os anos 90 (FAO, 2015).

As florestas plantadas por sua vez, somam 264 milhões de hectares no mundo, o que equivale a 7% do total de florestas existentes (HORA, 2015). A finalidade principal desses plantios é a produção de madeira, pois cerca 76% de todas as florestas plantadas do planeta são destinadas a atividades relacionadas ao seu uso (FAO, 2015).

Segundo Araujo *et al.* (2017), os plantios florestais desempenham um papel de extrema importância do ponto de vista econômico, social e ambiental, não apenas no Brasil, mas também em diversos países onde espécies exóticas de rápido crescimento foram introduzidas. O sucesso das espécies de *eucalipto* e *pinus* se devem à sua extrema capacidade de adaptação, ao rápido crescimento e à possibilidade de utilização de sua madeira para diversos fins (VALVERDE, 2001).

No Brasil, 3% de área florestal do país é composta por plantios de florestas, o que corresponde a 9,9 milhões de hectares (IBÁ, 2018). Esse valor representa a nona posição entre os países com maior área de floresta plantada do mundo (FAO, 2015). Contudo, o país ainda conta a maior produtividade mundial de coníferas e folhosas em plantios florestais comerciais destinados a produção de madeira (SANTOS; SOARES; SOUSA, 2016).

O carvão vegetal de origem florestal é um importante recurso energético utilizado na indústria de base brasileira. O país está entre os principais produtores de celulose, papel e painéis de madeira no mundo, com exportações que trazem inegável contribuição para a balança comercial e geram muitos empregos e renda em todas as regiões do país. Dessa maneira, o setor florestal e a atividade de extração de madeira possuem uma dinâmica específica, determinada pela oferta de madeira e pela produtividade das florestas (UHLIG; GOLDENBERG; COELHO, 2008).

O setor brasileiro de árvores plantadas apresentou crescimento de 13,1% em

2018 com relação ao ano anterior, alcançando uma receita setorial de R\$ 86,6 bilhões. Essa evolução do segmento foi muito superior à média nacional, que registrou um aumento no Produto Interno Bruto (PIB) Nacional de 1,1%, enquanto o da agropecuária evoluiu 0,1%, o setor de serviços, 1,3% e a indústria em geral, 0,6%. O setor de árvores plantadas fechou 2018 com participação de 1,3% do PIB nacional e 6,9% do PIB industrial (IBÁ, 2018).

De modo geral, os investimentos em florestas plantadas apresentam algumas características que diferem bastante das culturas agrícolas em geral, como a ocorrência da maior parte dos custos das operações florestais até a idade corte se concentrarem na implantação do cultivo, e o retorno acontecer em apenas alguns períodos de tempo muitos anos após a implantação. A organização industrial do setor baseia-se em um grande número de empresas de pequeno porte, com menor capacidade gerencial para produção de madeira serrada, compensados e móveis (ANTONANGELO; BACHA, 1998). Por outro lado, o setor é dominado por poucas empresas de grande porte, integradas verticalmente, que atuam desde a produção até o comércio destinado ao consumo final.

2.2 ANÁLISE ESPACIAL

Análise espacial se refere a um conjunto de métodos quantitativos e descritivos que tratam de fenômenos associados a uma referência espacial ou geográfica. De modo geral, é uma ferramenta que possibilita a manipulação dos dados espaciais, e, com isso, extrair um conhecimento adicional como resposta. O que significa incluir desde procedimentos básicos de consultas espaciais em uma determinada área de interesse, como também geração de mapas e sumários estatísticos, além das análises mais complexas, como os modelos de regressão espacial (ASSUNÇÃO; REIS, 1999).

Os processos referentes a análise espacial incluem não somente os métodos de visualização, como também métodos matemáticos e estatísticos, com a finalidade de investigar o padrão espacial dos dados e sua correlação espacial, o que pode auxiliar na tomada de decisões gerenciais (CÂMARA, *et al.* 2004; BAILEY; GATRELL, 1995). Nesse sentido, a análise de dados procedentes de fenômenos ocorridos no espaço se revela importante nos mais diversos campos do conhecimento, seja nas ciências agrárias, meio ambiente, sociais, da saúde, entre outras (ALMEIDA, 2012).

2.3 ESTATÍSTICA ESPACIAL

A estatística espacial baseia-se no pressuposto de que os dados observados relativos a unidades próximas entre si estão associados de alguma maneira. Desta forma, ao serem realizadas inferências acerca do fenômeno de interesse é levado em consideração a sua localização característica, com a finalidade de analisar, descrever e modelar o seu comportamento em função dos efeitos espaciais existentes (CÂMARA *et al.*, 2004; DIGGLE, 2013).

De acordo com Getis (2008), muito dos aspectos teóricos e metodológicos na estatística clássica são baseados no pressuposto de que as observações são independentes entre si. A estatística espacial, por sua vez, fundamenta-se na dependência de tais observações devido às influências de dimensões espaciais como distâncias, áreas, pontos e superfícies (FISCHER; WANG, 2011).

Desta maneira, a estatística espacial é caracterizada como um conjunto de métodos, conceitos e técnicas em que os dados são indexados pela componente espacial, podendo assim ser modelada como um processo estocástico espacial (ODEN, 1995). A respeito disso, Cressie (1993) ressalta que, no mínimo, um processo estocástico é usado para resumir dados existentes ou para prever dados não observados.

Assim, um processo estocástico basicamente se refere a uma família de variáveis aleatórias \mathbf{Z} indexadas a um parâmetro D . Seja \mathbb{R} um local genérico no espaço euclidiano d -dimensional e $\mathbf{Z}(s)$ uma quantidade aleatória pertencente a coordenada espacial s . Desse modo, ao variar s no conjunto paramétrico $D \subset \mathbb{R}^d$ obtemos o processo espacial aleatório

$$\{\mathbf{Z}(s): s \in D \subset \mathbb{R}^d\} \quad (1)$$

Segundo Cressie (1993), a realização do processo descrito acima é denotada por sua forma generalizada $\{\mathbf{Z}(s): s \in D\}$, onde D representa os diferentes tipos de dados espaciais existentes, classificados principalmente em:

- a) Dados de processos pontuais, em que se refere a análise da localização da ocorrência de eventos em s , distribuídos na forma de ocorrência pontual de acordo com a referência espacial adotada;
- b) Dados de superfície aleatória (Geoestatística), caracterizados pela existência da continuidade espacial, ou seja, a coordenada localizada no ponto s pode assumir infinitos valores diante de uma configuração geográfica de natureza contínua;
- c) Dados de área, em que são obtidos usualmente através de levantamentos agregados por áreas de uma região, isto é, s representa determinada área de um polígono espacialmente distribuído.

Nesse sentido, para cada um desses tipos de dados espaciais apresentados existem métodos de análise estatística específicas. Para maior aprofundamento no assunto recomenda-se Cressie (1993).

Desse modo, para fins deste trabalho, esta revisão apresentará apenas a teoria e os métodos estatísticos acerca da análise exploratória espacial de dados de área.

2.3.1 Análise de dados de área

Segundo Câmara *et al.* (2004), dados de área referem-se a um mapa de uma região, particionado em áreas, onde, em cada uma delas, observa-se uma ou mais variáveis aleatórias e, possivelmente, covariáveis de interesse. O modelo de distribuição mais utilizado na análise de dados de área é o modelo de variação espacial discreta (HANNIG, 2003). Assim, considerando a ocorrência de um processo estocástico $\{Z_i, i = 1, 2, \dots, n\}$, onde Z_i é a realização de um processo espacial na área A_i , com n igual ao total de áreas A_i , temos:

$$\{Z(A_i) : A_i \in \mathbf{R} \subset \mathbb{R}^d\}, \quad \forall d \in \mathbb{Z}^+, \quad (2)$$

em que $Z(A_i)$ é o vetor das variáveis aleatórias na área i ; \mathbf{R} a região de interesse; \mathbb{R}^d o espaço vetorial real de dimensão d , com d pertencente aos números inteiros não negativos.

Conforme Câmara *et al.* (2004), dados de área são caracterizados pelo processo

estocástico espacial onde uma determinada região R é particionada em i polígonos ou áreas. Dessa forma, não se dispõe da localização exata dos eventos, mas de um valor geral em relação ao polígono ou área que se deseja inferir.

Um dos objetivos mais comuns em análise de dados de área é verificar a existência de um padrão espacial e de uma estrutura de correlação espacial nos valores observados de uma variável de interesse (ANSELIN, 2003).

2.3.2 Análise Exploratória de Dados Espaciais

A Análise Exploratória de Dados Espaciais (AEDE) compreende uma coleção de técnicas com finalidade de descrever, visualizar e verificar a existência de padrões espaciais, identificando localidades atípicas, denominadas de *outliers* espaciais, ou em associação, na forma *clusters* espaciais. A AEDE é importante nos estudos dos processos de difusão espacial, por indicar a existência de dependência espacial entre os objetos geográficos (ANSELIN, 1995; HAINING, 2003).

De acordo com Krempi (2004,), em uma AEDE são utilizadas técnicas de estatística espacial, apresentadas em forma de índices globais e locais (I de Moran, C de Geary, Variograma, entre outros), capazes de medir a autocorrelação espacial, auxiliando na identificação de agrupamentos entre objetos vizinhos. À vista disso, uma AEDE se caracteriza como ponto de partida fundamental em uma análise de estatística espacial (GETIS; ORD, 1995).

2.3.3 Autocorrelação Espacial

De acordo com Getis (2008), quando se trabalha com dados de natureza espacial podemos nos deparar com os efeitos espaciais. Assim, um aspecto fundamental na avaliação do padrão espacial é caracterizado pela existência ou não de dependência em relação ao espaço característico, ou seja, como os valores estão correlacionados espacialmente. Desse modo, a estrutura de dependência entre os valores observados nas várias localidades do fenômeno em estudo é analisada pela função de autocorrelação espacial (CÂMARA *et al.*, 2004).

Nesse sentido, conforme Almeida (2012), a dependência ou autocorrelação espacial existe sempre que o valor de uma variável em um lugar do espaço está relacionado com seu valor em outros lugares do espaço. Sendo assim, autocorrelação

descreve o grau que uma mesma variável aleatória, medida em pontos diferentes do espaço, tende a mudar.

O termo é derivado do conceito de correlação, que mensura a relação entre duas ou mais variáveis. Nesse contexto, é importante salientar que, antes do surgimento e consolidação da estatística espacial, alguns pesquisadores já se atentavam para o fato de que as variações espaciais poderiam influenciar os resultados das análises. R. Fisher, ao estabelecer os princípios da experimentação estatística em 1935, estava ciente da existência de dependência espacial em seus experimentos, pois se esforçava muito para removê-la.

Somente a partir da década de 1950 que começaram a surgir estudos considerando a presença de correlação espacial (CRESSIE, 1993). Isso se deve principalmente ao desenvolvimento de conceitos importantes nas áreas da Estatística e da Geografia (GETIS, 2008). Segundo o autor, a formulação teórica a respeito da autocorrelação temporal, fundamental em análise de séries temporais, e os avanços relacionados a geografia quantitativa foram essenciais na concepção e consolidação da estatística espacial.

Serrano e Valcarce (2000) consideram que é possível detectar uma certa semelhança entre os conceitos de autocorrelação espacial e temporal, na medida que em ambos os casos se produz um não cumprimento das hipóteses de independência entre as observações. Porém, conforme os mesmos autores, a diferença básica entre esses eles é que a dependência temporal é unidirecional, isto é, o passado explica o presente. Diferentemente da dependência espacial, caracterizada por ser multidirecional, em que uma região pode ser afetada por outra próxima de acordo com algum critério escolhido.

A autocorrelação espacial pode ser expressa por meio de um coeficiente da mesma forma como na estatística clássica, podendo ainda ser positiva ou negativa. Assim, de acordo com Almeida (2012), um coeficiente de autocorrelação espacial descreve como um conjunto de dados de um certo fenômeno está distribuído espacialmente. O que significa que é capaz de medir o nível de interdependência espacial entre as variáveis em questão. Quando positiva, a forma como um fenômeno se apresenta em determinada região é semelhante as regiões próximas entre si (clusters). Enquanto a autocorrelação espacial negativa, significa que há um padrão em que regiões próximas entre si possuem valores diferentes (outliers), porém em estreita associação.

Portanto, conforme Anselin (1995) para se obter um coeficiente ou indicador de autocorrelação espacial, é necessário que haja uma matriz de proximidade espacial e uma medida de covariância dos dados em relação a distribuição no espaço. As medidas ou coeficientes utilizados com maior frequência em análises de autocorrelação espacial de dados de área são: a estatística I de Moran (MORAN, 1948) e a estatística C de Geary (GEARY, 1954).

Entretanto, para efeito deste trabalho, esta revisão abordará a seguir somente o coeficiente I de Moran global e local como medida de autocorrelação espacial devido ao elevado uso desse índice na literatura, considerado o mais utilizado no mundo quando se trata de uma AEDE.

2.3.4 Matriz de Proximidade Espacial

Quando se trata do estudo da dependência espacial de dados de áreas, a questão principal deste tipo de análise é o conceito da matriz de proximidade espacial, também conhecida como matriz de vizinhança ou ponderação espacial. De modo geral, a matriz de vizinhança é essencial na identificação de autocorrelação espacial, podendo ser ligada pela lista de vizinhos de cada polígono, pela distância entre eles, ou também pela conectividade ponderada pelo comprimento da fronteira comum (CÂMARA *et al.*, 2004; DIGGLE; 2013).

Portanto, uma matriz de proximidade espacial é definida como matriz quadrada $W_{n \times n}$, com pesos espaciais w_{ij} representando algum grau de interação entre as regiões ou vizinhos de acordo com critério de proximidade adotado, mostrando a influência de uma área A_j sobre outra área A_i , onde $w_{ii} = 0$ (ALMEIDA, 2012). Segundo Krempi (2004), a matriz W pode ser construída de acordo com uma série de medidas de adjacência. As principais são:


- a) $w_{ij} = 1$, se o centroide de A_i está a uma distância d de A_j , e $w_{ij} = 0$ caso contrário;
- b) $w_{ij} = \frac{L_{ij}}{L_i}$, onde L_i e L_{ij} são o comprimento do perímetro de A_i e o comprimento da fronteira entre A_i e A_j respectivamente, e $w_{ij} = 0$ caso contrário;

- c) $w_{ij} = 1$, A_i está compartilhando uma fronteira em comum com A_j , e $w_{ij} = 0$ caso contrário.

Assim, as matrizes de proximidade espacial são construídas a partir de atributos físicos e geográficos. Isso significa que duas regiões são consideradas vizinhas se elas compartilharem algum tipo de fronteira ou distância entre si (CÂMARA *et al.*, 2004). No entanto, a medida de adjacência mais utilizada é aquela baseada no conceito de contiguidade, isto é, de acordo com a simples ideia de que duas ou mais regiões são vizinhas caso elas partilhem alguma fronteira física em comum, como é o caso da medida observada em c).

Desse modo, as medidas de contiguidade são classificadas de acordo com a forma como as fronteiras entre as áreas de interesse são selecionadas. Segundo Almeida (2012), essas medidas são convenções inspiradas no movimento de peças específicas em um tabuleiro de xadrez, tais como: o Bispo (*Bishop*), quando apenas os vértices entre as fronteiras são considerados; a Torre (*Rook*), em que são considerados os limites em comum entre as fronteiras com exceção dos vértices; por fim, a Rainha (*Queen*), considera tanto os vértices quanto as fronteiras em comum em relação aos vizinhos (FIGURA 1).

Figura 1 – Tipos de convenção de contiguidade

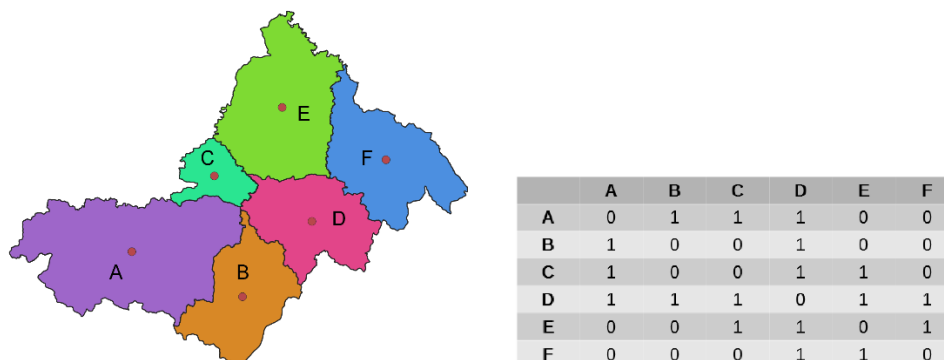


Fonte: Autor.

Como ilustra a Figura 1, dependendo do critério adotado, as análises poderão apresentar resultados completamente distintos. Porém, apesar de existirem esses três diferentes modos quanto a convenção das medidas de contiguidade, a do tipo Rainha (*Queen*) é tida como a medida de maior aplicação nas análises de dados espaciais de área, devido principalmente à sua fácil aplicabilidade quando não se possui regiões formadas por malhas regulares, o que de fato ocorre no mundo real. A Figura 2 mostra como uma matriz de proximidade espacial se apresenta quando duas ou mais regiões

vizinhas compartilham as fronteiras de acordo com a convenção *Queen*.

Figura 2 – Áreas e matriz de proximidade contígua do tipo rainha



Fonte: Autor.

Segundo Almeida (2012), é comum normalizar as linhas da matriz $W_{n \times n}$, isto é, dividir cada elemento ij pela soma total da linha a que pertence, da maneira que a soma de cada linha seja igual a um. Desse modo, é expressa como:

$$W_{ij} = \frac{w_{ij}}{\sum_j w_{ij}}, \quad (3)$$

logo,

$$\sum_j w_{ij} = 1. \quad (4)$$

2.3.5 Índice de I de Moran

O Índice ou coeficiente I de Moran avalia a relação de interdependência espacial entre todos os polígonos de uma determinada área de estudo, sendo uma medida de covariância na forma de produto cruzado (ALMEIDA, 2012). É considerado o índice de autocorrelação mais utilizado nas análises de dados espaciais de área, podendo ser obtido na forma de índice global e sua resultante local.

2.3.5.1 I de Moran Global

Os indicadores globais de autocorrelação espacial fornecem um único valor como medida de associação espacial para todo o conjunto de dados, sendo útil na

caracterização geral de toda a região de estudo (ODEN, 1995). No caso do I de Moran global, este propicia uma medida global de associação linear entre os valores de uma variável observados numa determinada área e a média ponderada dos valores de seus vizinhos conforme descrito na a seguir:

$$I = \frac{n}{W_0} \frac{\sum_{i=1}^n \sum_{j=1}^n w'_{ij} (z_i - \bar{z})(z_j - \bar{z})}{\sum_{i=1}^n (z_i - \bar{z})^2}, \quad (5)$$

com o fator de normalização $W_0 = \sum_{i=1}^n \sum_{j=1}^n w'_{ij}$, onde n é o número de áreas, z_i o valor da variável considerado na área i , z_j é o valor do variável em relação aos vizinhos, \bar{z} o valor médio na região de estudo e w'_{ij} são os elementos da matriz normalizada de proximidade espacial. Esta estatística varia entre o intervalo -1 e 1 , em que valores perto de zero indicam a não existência de dependência espacial; valores próximos de 1 , indicam que essa dependência existe e é positiva, ou seja, há presença de *clusters* espaciais, onde os vizinhos possuem características semelhantes entre si; enquanto que valores próximos a -1 significa que essa relação também existe, mas é negativa, isto é, ocorre a dissimilaridade entre os vizinhos, caracterizados como *outliers* espaciais (CÂMARA *et al.*, 2004).

De acordo com Waller e Gotway (2004), a esperança a variância da distribuição do índice I de Moran são dadas, respectivamente, por:

$$E[I] = -\frac{1}{(n-1)}, \quad (6)$$

$$VAR[I] = \frac{n^2 W_1 - n W_2 + 3 W_0^2}{(n+1)(n-1) W_0^2} - \frac{1}{(n-1)^2}, \quad (7)$$

em que $W_1 = \frac{\sum_{j=1}^n \sum_{i=1}^n (w_{ij} + w_{ji})^2}{2}$, $W_2 = \sum_{j=1}^n \sum_{i=1}^n (w_{ij} + w_{ji})^2$, W_0 e n foram definidos na expressão 5.

Embora este índice possa expressar a existência ou não de autocorrelação espacial, não é capaz de caracterizar as áreas de forma individual, apenas indicando o comportamento geral dos dados e sua distribuição espacial (ANSELIN, 2003). Deste modo, se faz necessário o uso de métodos e ferramentas que consigam aumentar o

nível de resolução das análises, como os diagramas de dispersão e as estatísticas locais.

2.3.5.2 *I* de Moran Local

Indicadores locais produzem um valor específico para cada objeto, permitindo assim, a identificação de agrupamentos de objetos com valores dos atributos semelhantes ou não. O Índice *I* de Moran Local identifica a relação existente entre um determinado polígono e a sua vizinhança, a partir de matriz de proximidade local, por intermédio da covariância existente entre eles (ANSELIN, 1995). Segundo Almeida, (2012), valores globais podem ocultar os padrões locais de autocorrelação espacial. Deste modo, os indicadores locais suprem esta lacuna pois permitem um maior detalhamento para cada região, tornando possível a identificação da heterogeneidade espacial.

Assim, enquanto o Índice *I* de Moran global informa o nível de interdependência espacial entre todas as unidades de área em uma determinada região através de um coeficiente de inclinação da reta, o *I* de Moran local expressa a covariância entre uma determinada região em função de seus vizinhos e, conforme Anselin (1995), pode ser descrita como:

$$I_i = (z_i - \bar{z}) \sum_{j \in J_i} w_{ij} (z_j - \bar{z}), \quad (8)$$

onde J_i representa o conjunto de áreas vizinhas a área i , o somatório das j áreas pertencem as áreas J_i . Os demais já foram definidos anteriormente. De acordo com Waller e Gotway (2004), a esperança em relação a sua distribuição pode ser escrita como:

$$E[I_i] = - \frac{w_i}{(n-1)}, \quad (9)$$

sendo $w_i = \sum_j w'_{ij}$. Com isso, pode realizar um teste de associação espacial local. Embora, conforme citado por Anselin (1995), a distribuição exata desta estatística seja desconhecida.

2.3.5.3 Inferência sobre I de Moran Global e Local

Um dos aspectos mais relevantes em uma análise exploratória de dados espaciais é estabelecer a validade estatística quanto ao grau de dependência observado. Logo, após calcular os índices de autocorrelação espacial é necessário associa-los a uma distribuição de probabilidade. Para isso, conforme Waller e Gotway (2004), existem duas abordagens possíveis no estudo em análise de dados de áreas, que são: distribuição aproximada, através do teste de normalidade assintótica; ou teste de permutação aleatória, também conhecido como teste de pseudo-significância.

No teste de normalidade assintótica, os índices I de Moran global e local seguem respectivamente uma distribuição normal. Deste modo, a hipótese de interesse do teste reside na ausência de autocorrelação espacial caso a hipótese de nulidade não seja rejeitada. Assim, temos que:

$$H_0: E[I] = 0$$

$$H_1: E[I] \neq 0$$

Portanto, para um nível de significância α a probabilidade de se obter uma estatística de teste maior ou igual a observada será:

$$valor - p = \mathbb{P} \left[Z > \frac{I_{obs} - E[I]}{\sqrt{VAR[I]}} \right] \quad (10)$$

onde I_{obs} corresponde ao valor do índice I de Moran observado, e Z a variável aleatória normal padrão. Assim, rejeita-se H_0 se, para um teste de significância da forma bilateral, $valor - p \leq \alpha$.

Em relação ao teste de permutação aleatória utilizam-se métodos computacionais, isto é, são geradas aleatoriamente diferentes permutações para os valores observados para cada área presente na análise, e que cada uma dessas permutações é calculado o valor do índice I de Moran (CÂMARA *et al.*, 2004). Logo, ao passo que são realizadas um número satisfatório de permutações obtém-se uma

distribuição empírica de I e Moran.

Dessa maneira, através da distribuição obtida, pode ser aplicado um teste para determinar se os dados estão aleatoriamente distribuídos ou não, sob a hipótese H_0 de que não há autocorrelação e os dados são independentes, pois possuem a mesma probabilidade de ocorrência caso seja permutadas as diferentes áreas pertencente as análises. Portanto, para o teste de pseudo-significância tem-se que:

$$valor - p = \frac{I_j > I_{calculado}}{N + 1} \quad (11)$$

em que testa a autocorrelação positiva, e para negativa,

$$valor - p = \frac{I_j < I_{calculado}}{N + 1} \quad (12)$$

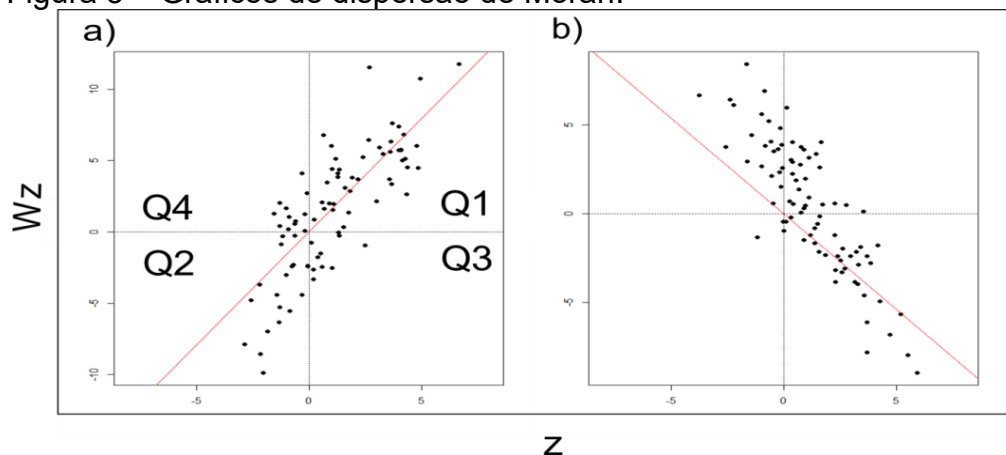
onde N se refere a quantidade de permutações realizadas, $I_{calculado}$ o índice I de Moran calculado para os dados sem permuta-los, I_j o índice I de Moran calculado para a permutação j , sendo $j = 1, \dots, N$.

2.3.5.4 Diagrama de dispersão de Moran

O diagrama de dispersão ou espalhamento de Moran é a interpretação do índice global I de Moran como um coeficiente de regressão linear, permitindo a visualização da associação entre o valor do atributo de cada elemento (z_i) com a média dos valores do atributo de seus vizinhos (Wz_i). É uma maneira adicional de visualizar a dependência espacial, normalmente construído com base nos valores normalizados, ele permite analisar o comportamento da variabilidade espacial (ANSELIN, 1995; ALMEIDA, 2012).

Na Figura 3 é apresentado um exemplo hipotético de um diagrama de dispersão de Moran em que são apresentados autocorrelação espacial positiva, com a predominância de *clusters* espaciais, e negativa, composta por majoritariamente *outliers* espaciais.

Figura 3 – Gráficos de dispersão de Moran.



Fonte: Autor.

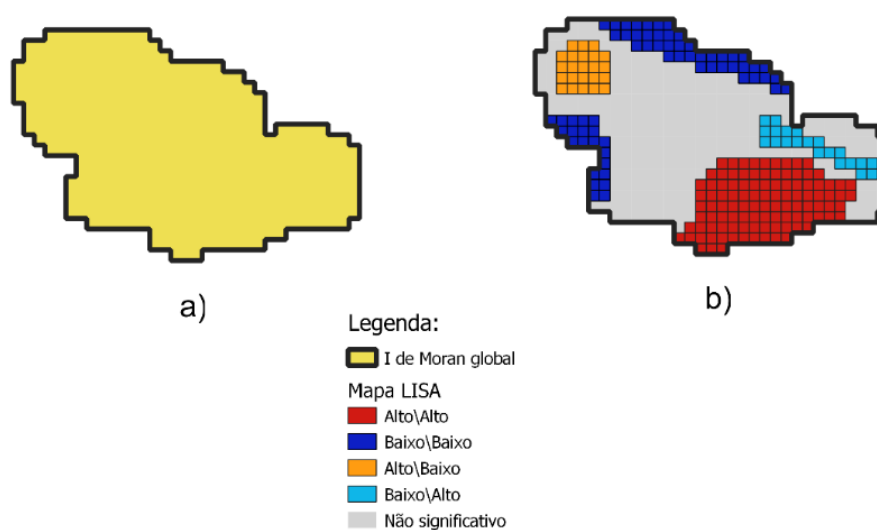
De acordo com a Figura 3, o eixo horizontal (z) equivale aos valores normalizados da variável de interesse para cada área e o eixo vertical (Wz) representa a média normalizada dessas áreas em relação aos seus vizinhos. A Figura 3.a representa autocorrelação positiva (I de Moran global > 0), enquanto na Figura 3.b, negativa (I de Moran global < 0). Desse modo, para a interpretação do gráfico de dispersão é necessário dividi-lo em quadrantes, onde conforme a Figura 3, o primeiro quadrante (Q1) constitui um agrupamento em que as unidades espaciais como também a média de seus vizinhos apresentam altos valores, denominado agrupamento alto/alto. O segundo (Q2), os valores para z e Wz são baixos, ou seja, um agrupamento baixo/baixo. Já os quadrantes Q3 e Q4 representam incidências destoantes em relação aos seus vizinhos. Assim, em Q3 tem-se que os valores das áreas em z são altos em contraste com os valores da média dos vizinhos, e no último quadrante (Q4) representa o contrário, caracterizando aglomerações alto/baixo e baixo/alto respectivamente.

Portanto, ao se utilizar o diagrama de espalhamento ou dispersão de Moran consegue-se visualizar, de maneira geral, o modo como a dependência espacial afeta as regiões de interesse. Segundo Silva et al. (2011), tal diagrama também é bastante útil na confecção de mapas de estatística local (mapa *LISA* principalmente) indicando as regiões que apresentam autocorrelação local significativamente diferente das demais.

2.3.5.5 Mapa LISA

O mapa *LISA*, termo em inglês para *Local Indicator of Spatial Association*, representa as áreas que possuem correlação local significativa. Estas áreas têm uma dinâmica especial própria e por isso é necessário que sejam analisadas de forma mais detalhada o possível (KREMPI, 2004). Portanto, para a confecção deste mapa é necessária a obtenção da estatística local significativa para uma significância α pré-estabelecida conforme a Figura 4.

Figura 4 – Representação geográfica do valor global I de Moran (a) em relação ao Mapa LISA (b), para uma significância (α) qualquer.



Fonte: Autor.

A Figura 4 ilustra, de forma geral e didática, a importância do mapa *LISA* em uma AEDE. Pois, através do teste de significância realizado na estatística local do I de Moran local é possível espacializar áreas ou regiões onde esses valores são significativos. Diferentemente do ocorre quando se possui apenas a informação do índice global I de Moran, sendo capaz de obter somente o valor de autocorrelação positiva ou negativa para toda região de interesse do estudo, como demonstra a Figura 4.a. No entanto, conforme a Figura 4.b, após aplicado o teste de significância ou pseudo-significância para cada valor da estatística local em relação aos seus

vizinhos, dado significância α previamente selecionada no estudo, ocorre a possibilidade da discriminação de quais são as áreas ou regiões que apresentam autocorrelação espacial. Nesse sentido, esses locais podem ser representados conforme o diagrama de dispersão de Moran, classificados nos quadrantes alto/alto, baixo/baixo, alto/baixo e baixo/alto.


3 MATERIAL E MÉTODOS

Nessa seção serão apresentados a área de estudo e os métodos de coleta e análise de dados utilizados nessa pesquisa.

3.1 ÁREA DE ESTUDO

A área de estudo do trabalho envolve praticamente todos os municípios do Brasil, excluindo somente algumas ilhas situadas na costa brasileira, como o arquipélago de Fernando de Noronha e Ilha Bela, a fim de se evitar algum tipo de viés que possa prejudicar as análises (Figura 5). O Brasil é um país de proporção continental, é o maior país da América do Sul e o quinto do planeta. É dividido em cinco macrorregiões caracterizadas pela alta diversidade e riqueza de seus ambientes distribuídas entre 27 unidades federativas. O clima no país é considerado tipicamente tropical, com predominância de altas temperaturas e elevada umidade. É a maior economia da América Latina e sétima do mundo. Os setores agrícola, manufatureiro, minerador e de serviços são os mais fortes no país (BRASIL, 2019). Para o presente trabalho foi elaborada uma revisão teórica sobre o setor florestal brasileiro com ênfase em plantios comerciais e os produtos madeireiros, bem como a análise exploratória de dados espaciais referentes a dados de área e suas principais ferramentas de análise estatística, utilizando métodos capazes de verificar a existência de autocorrelação espacial global bem com sua resultante local. Isto posto, para a aplicação prática dos conceitos abordados na seção anterior utilizaram-se os dados de produção da silvicultura para carvão, lenha e madeira em tora por município brasileiro para os anos de 2009 e 2018, através do banco de dados do IBGE da Produção da Extração Vegetal e da Silvicultura (IBGE, 2019).

Figura 5 – Mapa do Brasil: áreas territoriais dos estados e municípios brasileiros.



Fonte: Autor.

3.2 DADOS

Utilizou-se a produção total de florestas plantadas com ênfase em produtos madeireiros para finalidades de lenha, madeira em tora e carvão como variáveis de análise para todos municípios brasileiros. Desse modo, este trabalho teve como fonte o banco de dados do Sistema de Recuperação Automática (SIDRA) – IBGE, mais especificamente os dados da produção da silvicultura por município da Produção de Extração Vegetal e da Silvicultura dos anos de 2009 e 2018.

Em 2009, o setor madeireiro de florestas comerciais enfrentou a pior crise da última década em consequência da crise econômico-financeira mundial ocorrida no ano anterior, 2008, o que refletiu nos baixos valores de produção para o período (ABRAF, 2011). Assim, o presente trabalho considerou importante analisar o modo como esses valores se distribuem em relação aos municípios brasileiros no período de crise comparando posteriormente com a distribuição da produção de madeira no período mais atual na base dados, 2018. As informações sobre a quantidade de lenha, madeira em tora estão expressas em metros cúbicos (m^3), enquanto que para a variável carvão em toneladas (t).

É importante ressaltar que, em relação às técnicas de análise exploratória de dados espaciais, este estudo apresenta metodologia semelhante aos trabalhos de Felema *et al.* (2016), Clemente (2015) e Perobelli *et al.* (2007).

3.3 ANÁLISE

Após revisão literatura acerca do panorama do setor florestal madeireiro oriundo de florestas plantadas e da estatística espacial aplicada aos dados de áreas, foi realizada uma análise exploratória de dados espaciais (AEDE) em relação às variáveis de produção total da lenha, madeira em tora e carvão em relação a todos os municípios brasileiros.

Logo, para a realização das análises foi utilizada a linguagem *Python* (PYTHON, 2019) com os pacotes *Pysal*, específico para análise exploratória de dados espaciais, e *Geopandas*, usado na manipulação e visualização de dados espaciais.

Assim sendo, após a realização de uma análise exploratória preliminar, isto é, depois de obtidos as estatísticas gerais sobre os dados de cada variável de interesse, como a média, mediana, o desvio padrão, a produção máxima, mínima e total para os períodos analisados, elaborou-se um mapa temático de intervalos iguais ($k = 5$, para todas as variáveis) com finalidade de observar espacialmente os valores de produção distribuídos em classes de mesma amplitude. Feito isso, partiu-se para análise espacial propriamente dita, em que após definida a matriz de proximidade espacial do tipo contígua na forma rainha, calculou-se o índice I de Moran global, realizando o teste de pseudo-significância com 1.000 permutações a um nível de significância $\alpha = 5\%$.

Desse modo, após obtida a estatística global, e esta apresentar-se de forma significativa, isto é, rejeitar a hipótese de que os dados referentes a regiões de interesse possuem distribuição aleatória, realizaram-se as análises do I de Moran local. Para as análises e teste (pseudo-significância com 1.000 permutações e $\alpha = 5\%$) da estatística local foram construídos mapas LISA com o objetivo de identificar padrões ou *clustes* de autocorrelação local, bem como os *outliers* espaciais.

4 RESULTADOS E DISCUSSÃO

Nesse tópico serão discutidos os resultados obtidos na análise descritiva e na análise espacial da produção silvicultural – madeira para lenha, madeira em tora e carvão vegetal – estudada nesse trabalho.

4.1 ANÁLISE DESCRITIVA

A Tabela 1 apresenta as estatísticas descritivas gerais da produção nacional de produtos florestais madeireiros oriundos da silvicultura de acordo com a classificação adotada pelo PEVS – IBGE de 2009 e 2018.

Tabela 1 – Estatísticas descritivas gerais da produção de madeira proveniente de plantios florestais no Brasil para finalidade de lenha (m³), tora (m³) e carvão vegetal (t) nos anos de 2009 e 2018.

Ano	Variável	Nº de municípios produtores	Média	Desvio padrão	Mín.	Mediana	Máx.	Total
2009	Lenha	2.274	18.210,57	31.842,29	1	3.265,00	767.826,00	41.410.850,00
	Tora	2.015	53.057,77	23.729,17	1	1.250,00	4.411.647,00	106.911.408,00
	Carvão	851	3.970,05	19.542,40	1	90,00	305.295,00	3.378.520,00
2018	Lenha	2.551	20.619,82	29.328,05	3	7.000,00	1.222.200,00	52.601.179,00
	Tora	2.242	65.327,31	25.229,42	2	3.100,00	5.342.722,00	146.463.834,00
	Carvão	903	6.709,27	22.258,13	1	320,00	443.814,00	6.058.476,00

Fonte: Elaborado com base no banco de dados do SIDRA – IBGE (2019)


De acordo com a Tabela 1, em 2009, o Brasil registrou a produção de 41.410.850,0 m³ de lenha, 106.911.408,0 m³ de madeira em tora e 3.378.520,0 t de carvão vegetal, distribuídos respectivamente entre 2.274, 2.015 e 851 municípios produtores. Desse modo, a produção média entre os municípios produtores correspondeu a 18.210,57 m³ (lenha), 53.057,77 m³ (tora) e 3.970,05 t (carvão). Os municípios de Santa Cruz do Sul (RS), com o total de 767.826,0 m³ de lenha, Telêmaco Borba (PR), com 4.411.647,0 m³ de madeira em tora e Encruzilhada do Sul (RS), 3.378.520,0 toneladas de carvão vegetal foram os maiores produtores no período (IBGE, 2010).

Em 2018, observa-se um aumento na produção nacional e no número de municípios produtores de madeira proveniente da silvicultura para todas as variáveis (TABELA 1). Foram produzidos um total de 52.601.179,0 m³ de lenha, distribuídos entre 2.551 municípios; 146.463.834,0 m³ de madeira em tora, 2.242 municípios; e 6.058.476,0 t de carvão vegetal, 903 municípios. Assim, a produção média apresentou crescimento de 13,3% na produção de lenha, 23,12% de madeira em tora e 69% para o carvão vegetal. Em relação aos maiores produtores para o período, os municípios de Butiá (RS), produziu 1.222.200,0 m³ de lenha da silvicultura, o que corresponde um crescimento de 59% quando comparado ao município que mais produziu em 2009. No caso de madeira em tora o crescimento o município de Três Lagoas (MS) correspondeu a 129% (5.342.722,0 m³ produzidos) do valor observado anteriormente. Para o carvão vegetal cerca de 145% (443.814,0 t) (IBGE,2019).

No ano de 2009, o setor florestal, em conjunto com outros setores da economia brasileira, apresentou indicadores negativos como reflexo principal da crise financeira mundial de 2008. Assim, atingiu seu ápice no setor em 2009, impactando fortemente alguns segmentos como celulose, carvão vegetal e madeira processada (BERGER; JUNIOR, 2009).

A vista disso, apesar da profunda crise enfrentada, destaca-se que, de modo geral, o setor de produção madeireira oriunda de florestas comerciais no Brasil cresceu de forma substancial entre os períodos analisados. O Brasil vem aumentando a sua produção de lenha oriunda da silvicultura, com um crescimento de 27% em 2018 quando comparado com 2009. Os principais estados produtores, considerando a produção atual, são: Rio Grande do Sul (33,9% do total produzido), Paraná (16,4%), Santa Catarina (15,6%), Minas Gerais (13,3%), e São Paulo (11,7%) conforme a Figura 6.

Figura 6 – Série histórica entre 2009 e 2018 da quantidade produzida de lenha (m^3) proveniente da silvicultura no Brasil.




Fonte: Elaborado com base no banco de dados SIDRA – IBGE (2019).

Assim, de acordo a Figura 6, os estados pertencentes ao Sul do Brasil mantiveram-se entre os principais produtores de lenha da silvicultura ao longo dos últimos anos, principalmente os estados do Rio Grande do Sul e Paraná, se destacando como os maiores produtores do país por todo o período analisado. Ainda conforme a série, os estados de Minas Gerais e São Paulo também são importantes produtores nacionais de lenha proveniente da silvicultura, no entanto o estado mineiro se destaca por apresentar um crescimento médio da produção de 2,5% ao ano (IBGE, 2019).

Segundo Cunha *et al.* (2019), a lenha da silvicultura é principalmente utilizada em fornos para secagem de grãos, em indústrias alimentícias, no processo de beneficiamento de vários tipos de minérios, no uso comercial em geral, como em panificadoras, pizzarias, cerâmicas e olarias, entre outros.

Para o setor de madeira em tora proveniente de plantios comerciais, a produção em relação ao período analisado apresentou um crescimento de 37% (FIGURA 7). Em 2018, o estado do Paraná foi o maior produtor, com 23% do total, pouco à frente do estado de São Paulo (22%), Mato Grosso do Sul (14%), Santa Catarina (12,3%), Bahia (11,8%) e Espírito Santo (7,6%).

Figura 7 – Série histórica entre 2009 e 2018 da quantidade produzida de tora (m^3) proveniente da silvicultura no Brasil.



Fonte: Elaborado com base no banco de dados SIDRA – IBGE (2019).


De acordo com a Figura 7 a produção nacional de madeira em tora, que engloba basicamente os segmentos de celulose e madeira para outras finalidades (madeira processada), apresentou alguns altos e baixos em relação ao período analisado. Além da crise econômica de 2009, no ano de 2014 houve uma retração acentuada na produção, na ordem de 8,3% em relação ao ano anterior devido à desvalorização das principais *commodities* produzidas no país, dentre elas a pasta de celulose (IBÁ, 2014). No entanto, conforme Serrano (2015), a também desvalorização da moeda Real (BRA) em relação ao Dólar (USA) fez com que as exportações de papel e celulose aumentassem, e, conseqüentemente, a produção de madeira em tora (para celulose e papel). Atualmente, o Brasil é o segundo maior produtor de celulose do mundo, somente atrás dos EUA (IBÁ, 2019).

Os principais estados produtores de madeira em tora proveniente da silvicultura, apresentaram certa variação em relação ao período analisado. O estado do Paraná, com uma taxa média de crescimento equivalente a 2,1% ao ano, tornou-se o maior produtor nacional desde 2014, ultrapassando o estado de São Paulo, que observou queda de 17,5% no total produzido desde então. O estado do Mato Grosso do Sul merece destaque quanto a quantidade produzida pois apresentou um crescimento de 57% do quando comparado com 2009.

Quanto à produção de carvão vegetal da silvicultura, esta apresentou

crescimento ao longo da última década, passando de 3.378.520,0 para 6.058.476,0 t o que representa um aumento de 79,3% em relação a 2009 (FIGURA 8). O estado de Minas Gerais corresponde a 78% de toda a produção nacional em 2018, seguido pelo estado do Maranhão, com cerca de 8% do total.

Figura 8 – Série histórica entre 2009 e 2018 da quantidade produzida de tora (t) proveniente da silvicultura no Brasil.



Fonte: Elaborado com base no banco de dados SIDRA – IBGE (2019).

Conforme a Figura 8, a produção de todo o setor de carvão vegetal proveniente da silvicultura entre os anos de 2009 a 2018 pode é praticamente representada pela produção do estado de Minas Gerais, apresentando comportamento muito semelhante com o total produzido no Brasil ao longo desse período. Esse resultado pode estar associado à força do setor siderúrgico nesse Estado, principalmente quanto as regiões nordeste, central e metropolitana do estado, onde se localizam os principais polos produtores de ferro-gusa e aço do país, indústria dependente de carvão vegetal (CUNHA *et al.*, 2019).

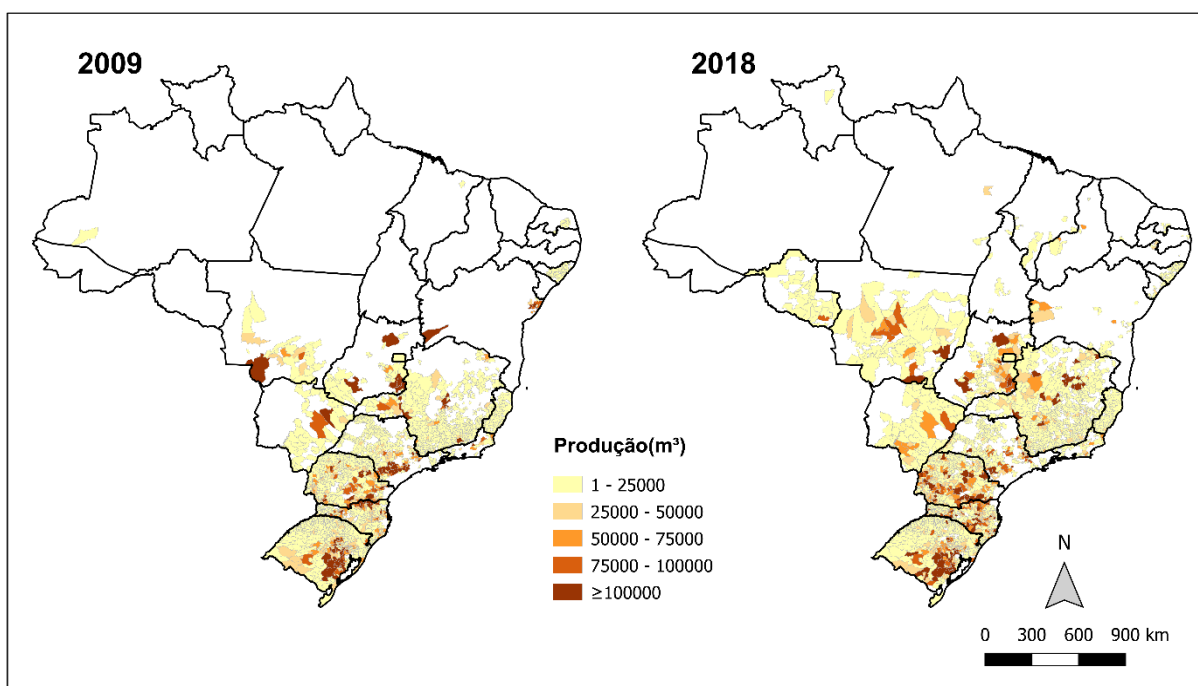
4.1.1 Mapas temáticos

A seguir serão apresentados os mapas temáticos da produção silvicultural brasileira de madeira para lenha, madeira em tora e carvão vegetal nos anos de 2009 e 2018.

4.1.1.1 Madeira para lenha (m³)

A Figura 9 ilustra a distribuição da produção de lenha (m^3) nos municípios brasileiros para os períodos de 2009 e 2018. Em 2009, o mapa retrata a distribuição da produção de lenha um ano após a grave crise financeira de 2008. O mapa de 2018, por sua vez, demonstra a distribuição da produção atual.

Figura 9 – Mapa de distribuição em relação aos municípios brasileiros da produção variável lenha da silvicultura (m^3) nos anos 2009 e 2018.



Fonte: Autor.

De acordo com a Figura 9, em 2009, os municípios que produziram em quantidade menor que 25.000 m^3 de lenha se distribuíram praticamente por toda região Sul, Sudeste, grande parte do Centro-Oeste e alguns poucos nas regiões Nordeste e Norte do país. Já os municípios que produziram entre 25.000 a 50.000 m^3 , grande parte pertence aos estados do Rio Grande do Sul, Santa Catarina e Paraná. Os municípios produtores pertencentes à classe de 50.000 a 75.000 m^3 estão localizados principalmente entre o Estado de São Paulo e a Região Sul do Brasil, com presença também nos estados do Rio de Janeiro, Minas Gerais, Goiás, Mato Grosso do Sul e Bahia. Para a quarta classe, de 75.000 a 100.000 m^3 , os municípios estão distribuídos predominantemente nos estados da região Sul do Brasil e no Estado do Mato Grosso do Sul. E por conseguinte, aqueles municípios que produziram em quantidade igual ou superior a 100.000,0 m^3 de lenha no ano de 2009 se distribuíram

mais de forma mais específica na região Centro Oriental, Sudeste Rio-Grandense (RS), na região Centro-Oriental Paranaense (PR), na mesorregião de Itapetininga (SP), na parte central do estado de Minas Gerais e em alguns outros pertencentes aos estados de Goiás, Mato Grosso, Mato Grosso do Sul e Bahia.

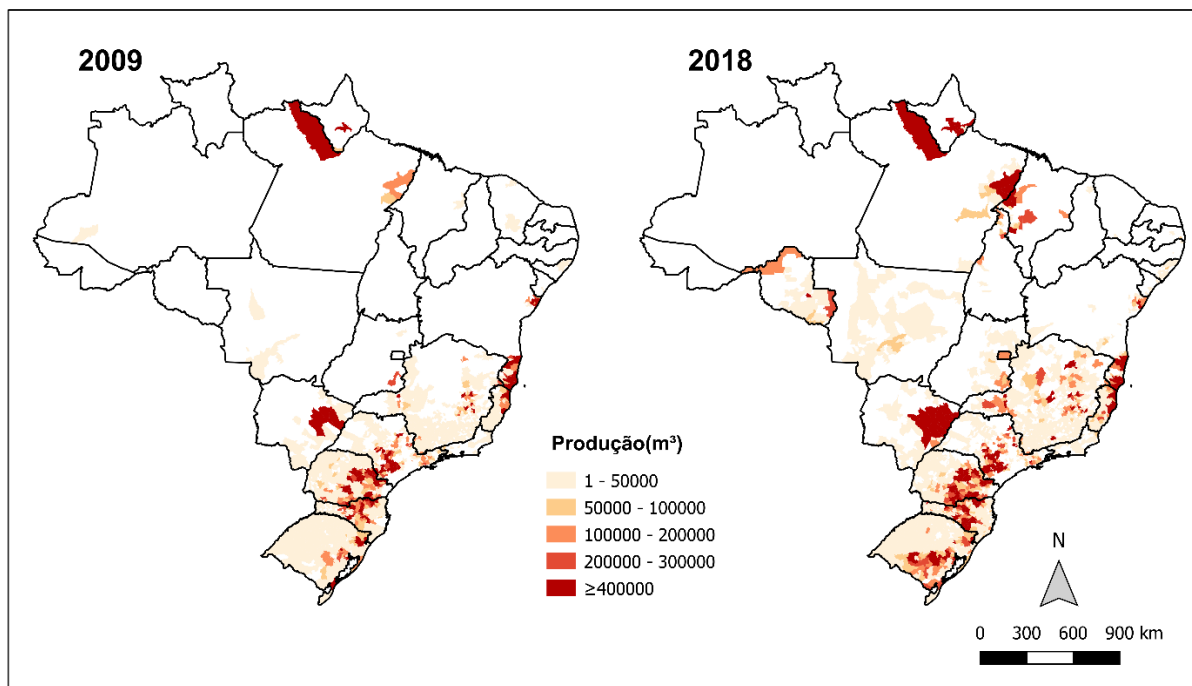
Para o ano de 2018, observa-se um número maior de municípios produtores (FIGURA 9). Desse modo, aqueles municípios pertencentes à primeira classe de produção se distribuíram em grande parte dos estados brasileiros, sobretudo aqueles pertencentes às regiões Sul, Sudeste e Centro-Oeste do Brasil, com exceção dos estados da Amazônia, Acre e Amapá, onde não houve produção. Na segunda classe, os municípios estão localizados predominantemente nos estados do Rio Grande do Sul, Santa Catarina, Paraná, São Paulo, Minas Gerais e Goiás. Já os municípios que compõe a classe seguinte, se distribuíram principalmente nos estados do Sul do país, mas também são presentes nos estados de São Paulo, Rio de Janeiro, Minas Gerais, Goiás, Mato Grosso, Mato Grosso do Sul, Bahia e Sergipe. A quarta classe também apresentou a predominância de municípios pertencentes à Região Sul do Brasil. Na última classe, por sua vez, apresentou um aumento considerável no número de municípios que produziram quantidades iguais ou maiores que 100.000,00 m³, quando comparada com o ano de 2009, especialmente em relação à Região Metropolitana de Porto Alegre (RS), o Sul Goiano (GO) e o Oeste Paranaense (PR).

Diante disso, em relação aos períodos analisados, observa-se um aumento geral de aproximadamente 13% no número de municípios brasileiros produtores de lenha da silvicultura, com destaque para as regiões produtoras tradicionais do país como os estados pertencentes a Região Sul, São Paulo e Minas Gerais, apresentando crescimento na concentração da produção, e também da região Centro-Oeste e Nordeste Brasil, onde apresentou elevada expansão dos municípios produtores.

4.1.1.2 Madeira em tora (m³)

No caso da madeira em tora (m³), observa-se também um crescimento no valor da produção total, na produção individual e na expansão dos municípios produtores entre os anos de 2009 e 2018 (FIGURA 10).

Figura 10 – Mapa de distribuição em relação aos municípios brasileiros da produção variável madeira em tora (m^3) nos anos 2009 e 2018.



Fonte: Autor.

Conforme a Figura 10, no ano de 2009, a grande parte da produção e dos municípios produtores de madeira em tora para o período está localizada na região Sul e Sudeste. Assim, para a primeira classe, que compreende o intervalo de 1 a 50.000,0 m^3 , observa-se uma concentração de municípios na região Sul do Brasil até a parte sul do estado do Mato Grosso do Sul, alcançando também muitos municípios do estado de São Paulo, Minas Gerais, Espírito Santo. Na classe seguinte, de 50.000,0 a 100.000,0 m^3 , os municípios estão distribuídos nos estados do Espírito Santo, São Paulo, Paraná, Santa Catarina, Rio Grande do Sul e Pará. Quanto aos municípios pertencentes ao intervalo de 100.000,0 a 150.000,0 m^3 , estão em grande nos estados do Paraná, Santa Catarina e São Paulo. A quarta classe, de 150.000,0 a 200.000,0 m^3 , possui principalmente municípios pertencentes ao estado do Paraná. Quanto aos municípios com produção superior ou igual a 200.000,00 m^3 , estão distribuídos no Sudeste e Centro-Oriental Paranaense, na região de Itapetininga (SP), no Sul Baiano, na porção norte do estado do Espírito Santo, Leste do Mato Grosso do

Sul, na região do Vale do Rio Doce (MG) e do Baixo Amazonas (PA).

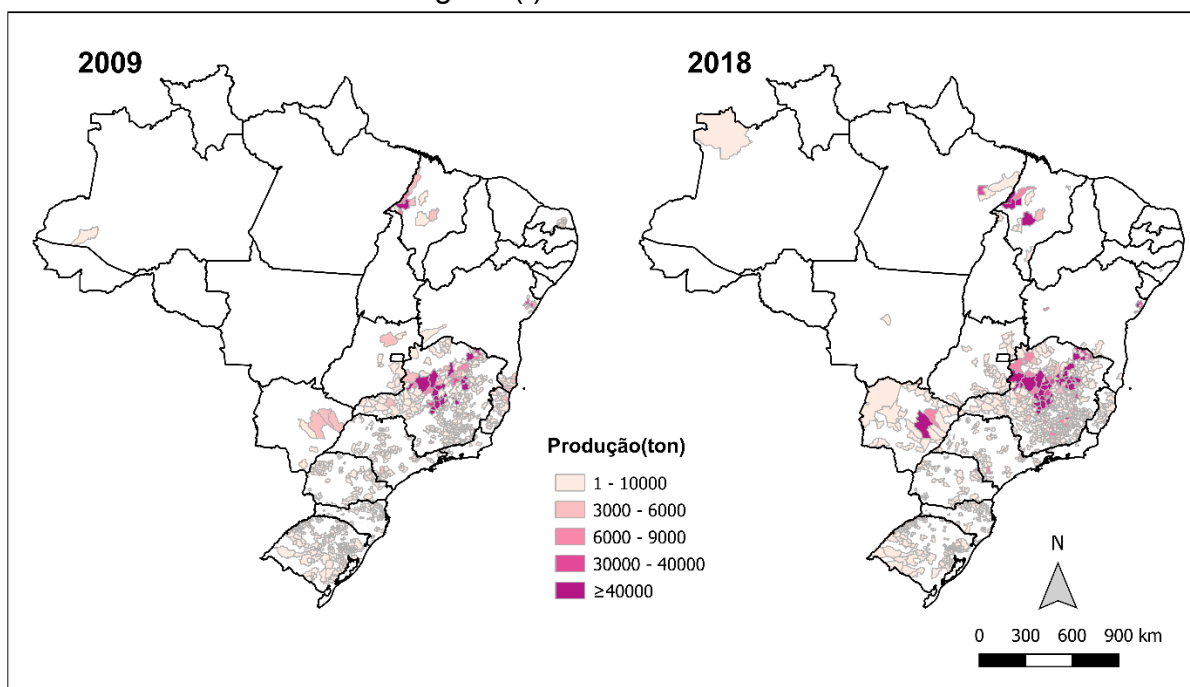
Em 2018, percebe-se grande expansão da produção de madeira em tora, especialmente em relação à Região Centro-Oeste e Norte do Brasil quando comparado ao período anterior analisado (FIGURA 10). Na primeira classe de produção, pode-se observar um número maior de municípios nos estados de Goiás, Mato Grosso do Sul, Mato Grosso, Rondônia e Pará. Na segunda classe, os municípios se distribuíram praticamente por todos os estados das Regiões Centro-Oeste, Sudeste e Sul do país, principalmente nos estados do Paraná, Santa Catarina, Rio Grande do Sul e Minas Gerais. A classe posterior apresenta a maior parte dos municípios localizados nos estados do Paraná e Santa Catarina, mas ocorre também na região central e oeste do estado de Minas Gerais, na porção Leste de Goiás e Leste do estado do Mato Grosso do Sul. Na quarta classe, os municípios se distribuem principalmente na região Centro Oriental e Serrana Paranaense, no Sul Baiano e na parte central de Minas Gerais. Já os municípios com produção igual ou superior a 200.000,00 m³, representam a expansão de regiões consolidadas entre os maiores produtores do país. Desse modo, as regiões de maior produção para o ano de 2018 correspondem com as descritas para o ano de 2009, no entanto ocorre um crescimento de municípios vizinhos que apresentam elevada produção.

Os principais municípios produtores atualmente estão situados principalmente nos estados do Paraná e Mato Grosso do Sul. Isso confirma a grande expansão do setor de madeira em tora nestas localidades, principalmente para finalidade de produção da celulose (HORA, 2017).

4.1.1.3 Carvão vegetal (t)

Quanto ao carvão vegetal de origem da silvicultura, constata-se que os municípios pertencentes ao estado de Minas Gerais são os grandes produtores do país para ambos os períodos analisados (FIGURA 11). Assim, em 2009, apenas o município de Açailândia (MA) estava entre os 10 maiores que não pertenciam ao Estado mineiro. No período seguinte, o município de Grajaú (MA) foi o único entre os maiores produtores de carvão de origem florestal do país também fora do estado de Minas Gerais.

Figura 11 – Mapa de distribuição em relação aos municípios brasileiros da produção variável carvão vegetal (t) nos anos 2009 e 2018.



Fonte: Autor.

Ainda conforme a Figura 11, em 2018, apenas 17 municípios pertencem às classes de produção maiores que 40.000,0 toneladas, o que corresponde apenas 6 municípios a mais que no período anterior. Os municípios de João Pinheiro, Itamarandiba, Três Marias, Lassance e Carbonita, se mantiveram como os grandes produtores do país em ambos os períodos analisados.

4.2 ANÁLISE ESPACIAL

A seguir serão apresentados os resultados da análise espacial da produção florestal brasileira analisada nesse estudo.

4.2.1 Índice de autocorrelação global e diagrama de dispersão

Para esta análise foi utilizado o índice de autocorrelação global I de Moran com objetivo em identificar a existência de padrões espaciais estatisticamente significativos, seja na forma de agrupamentos de áreas com valores semelhantes (*clusters*) ou anômalos (*outliers*). Desse modo, os resultados do índice I de Moran global e seus respectivos valores – p obtidos através do teste de pseudo-significância (1.000 permutações) para as variáveis da produção madeireira da silvicultura são

apresentados na Tabela 2.

Tabela 2 – Valor do I de Moran global e seu respectivo valor- p para as variáveis deste estudo nos anos de 2009 e 2018.

Ano	Variável	I de Moran	valor – p
2009	Lenha	0,399	< 0,001
	Tora	0,294	< 0,001
	Carvão	0,277	< 0,001
2018	Lenha	0,308	< 0,001
	Tora	0,378	< 0,001
	Carvão	0,340	< 0,001

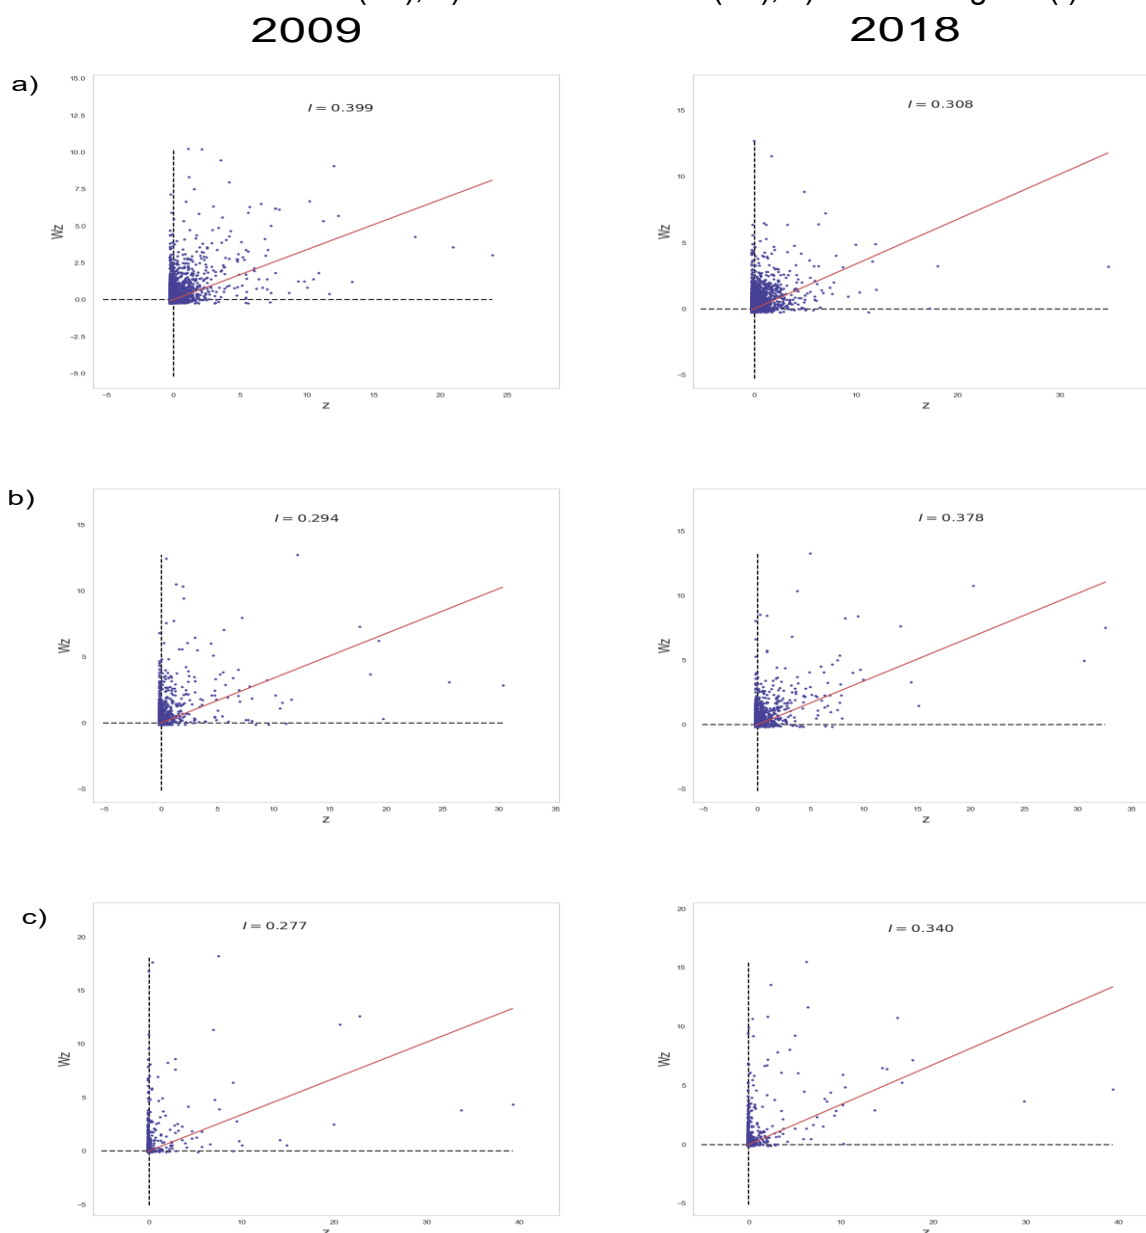
Fonte: Autor.

Conforme a Tabela 2, observa-se a ocorrência de autocorrelação espacial global positiva com nível de significância de 5% para os dois períodos analisados e para todas as variáveis em questão. Segundo Assunção e Reis (1999), o índice I de Moran global positivo indica a predominância de *clusters* espaciais. Dessa maneira, os municípios com alta produção de madeira tendem a estar agrupados entre si, do mesmo modo dos que possuem baixa ou até mesmo nenhuma produção.

Esses resultados confirmam o observado por Perobelli *et al.* (2007). Segundo os autores, que utilizaram o índice global e local I de Moran em suas análises, por meio de uma análise exploratória espacial (AEDE) é possível confirmar a presença da dependência espacial na produtividade agrícola no Brasil e seus respectivos *clusters*. No entanto, pesquisas sobre o comportamento espacial da produção e produtividade de madeira proveniente da silvicultura se encontra em estágios incipientes e carecem de informação quanto ao uso de AEDE.

Os resultados apresentados no diagrama de dispersão de Moran mostram uma inclinação positiva da curva (FIGURA 12). Fato que confirma a existência de autocorrelação espacial positiva em todas as variáveis nos dois períodos analisados.

Figura 12 – Diagramas de dispersão de Moran com os valores padronizados em relação ao ano de 2009 e 2018. Em que: a) Lenha proveniente da silvicultura (m³); b) Madeira em tora (m³); c) Carvão vegetal (t).



Fonte: Autor

Em 2018, foram 753 municípios presentes no quadrante do tipo alto/alto para a produção de lenha da silvicultura, o que representou um aumento de aproximadamente 21% em relação ao ano de 2009 (TABELA 3). Para o quadrante correspondente ao tipo alto/baixo observou-se um aumento de 560% no número de municípios, sobretudo nas regiões Sudeste e Centro-Oeste do Brasil. No quadrante baixo/baixo, se encontra a maioria dos municípios brasileiros para ambos os períodos, confirmando que a maior parte da produção de lenha ocorre de forma concentrada em

regiões altamente produtivas. No quadrante do tipo baixo/alto ocorre também um aumento quanto ao número de municípios, fato que pode estar relacionado com expansão de municípios que produzem em grandes quantidades (IBGE, 2019).

Tabela 3 – Número de municípios pertencentes aos quadrantes no diagrama de dispersão de Moran para as variáveis deste estudo nos anos de 2009 e 2018.

Quadrante	Lenha (m ³)		Tora (m ³)		Carvão vegetal (t)	
	2009	2018	2009	2018	2009	2018
	alto/alto	622	753	322	414	184
alto/baixo	163	916	61	128	50	62
baixo/baixo	4.150	3.824	4.788	4.477	5.021	4.950
baixo/alto	634	760	398	549	307	322

Fonte: Autor.

Ainda conforme a Tabela 3, para a produção de madeira em tora, foram registrados 414 municípios no quadrante alto/alto, o que corresponde um aumento de 29% quando comparando com 2009. A quantidade de municípios presente no quadrante do tipo baixo/baixo pouco mudou. Esses resultados podem estar associados a expansão da produção de madeira em tora, uma vez que o número de municípios pertencentes ao quadrante alto/baixo foi maior que o dobro entre os períodos analisados. No caso da produção do Carvão Vegetal, o crescimento de 27% no número dos municípios pertencentes ao quadrante alto/alto pode ter influenciado de maneira positiva no índice *I* de Moran para a variável em 2018, que também observou um crescimento de 25% em relação ao período anterior.

4.2.2 Mapas LISA

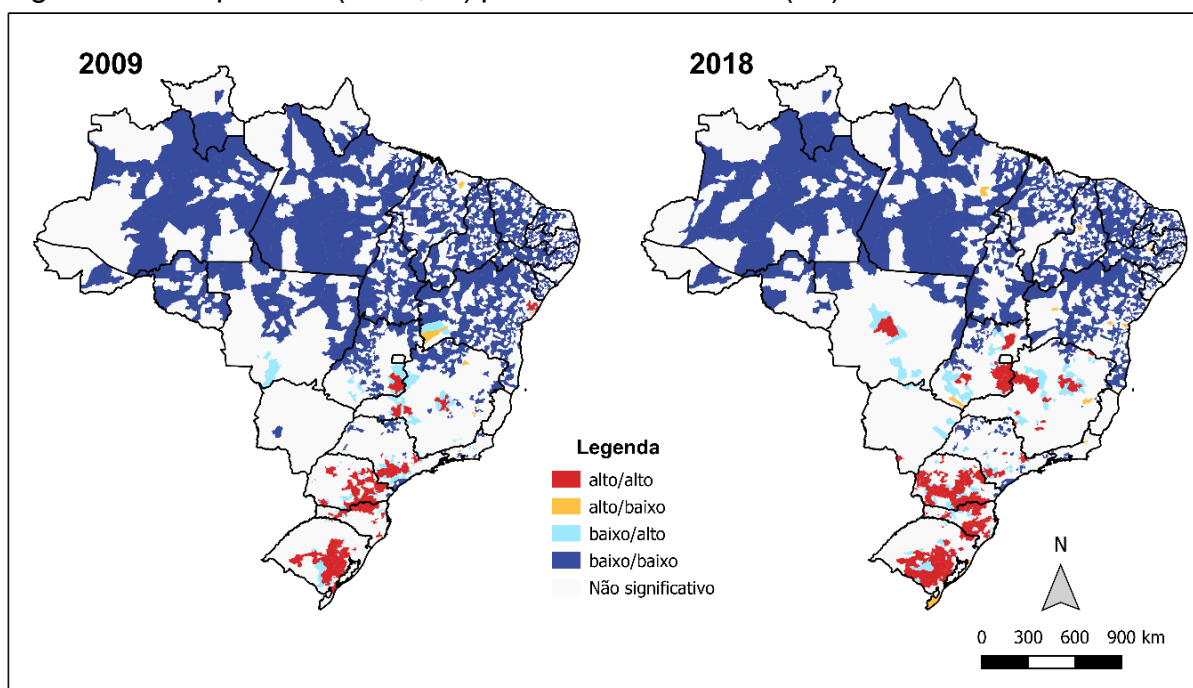
Os resultados apresentados anteriormente não informam quais são os municípios significativos, sendo necessário discriminá-los por meio dos indicadores locais LISA, capazes de proporcionar a identificação das regiões de agrupamentos

espaciais e suas áreas correspondes.

4.2.2.1 Madeira para lenha (m³)

O resultado do mapa LISA para a variável madeira destinada a lenha em relação aos períodos analisados se apresenta a partir da Figura 13.

Figura 13 – Mapa LISA ($\alpha = 0,05$) para a variável lenha (m³) nos anos de 2009 e 2018.



Fonte: Autor.

Desse modo, conforme ilustra a Figura 13, para a variável lenha advinda da silvicultura o mapa LISA no ano de 2009 demonstra que as regiões sul do estado de São Paulo, parte do eixo norte-sudeste do Paraná, norte de Santa Catarina, o centro-leste e sudeste do Rio Grande do Sul, concentram a maior parte dos municípios significativos em relação aos *clusters* do tipo alto/alto, sendo responsáveis por 74% de toda a produção nacional de lenha. No período seguinte, em 2018, observa-se um aumento considerável quanto ao número municípios do tipo alto/alto, principalmente no Sul do Brasil, onde regiões pertencentes ao oeste do Paraná, sul de Santa Catarina e o extremo sul do Estado do Rio Grande do Sul passaram a apresentar municípios do tipo alto/alto. Além disso, pode-se observar também um deslocamento em relação ao período anterior quanto aos municípios significativos tipo alto/alto em Minas Gerais, onde em 2018 ocorre uma concentração maior na parte oeste do estado, formando

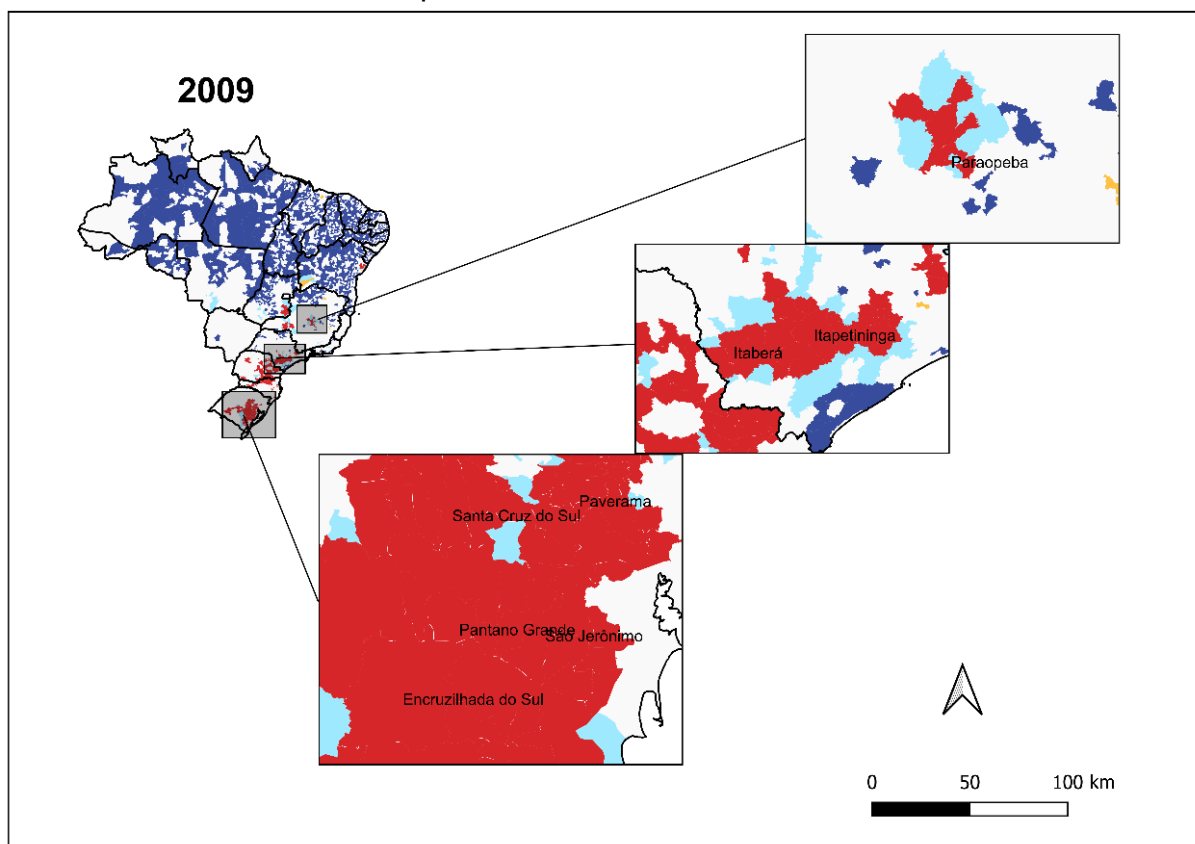
um aglomerado com alguns municípios vizinhos da região do Leste e Sul Goiano (Estado de Goiás).

Já as regiões que apresentaram *clusters* espaciais do tipo baixo/baixo se caracterizam por estarem majoritariamente distribuídos nas regiões Norte e Nordeste do país nos dois períodos analisados, com exceção de alguns municípios do tipo baixo/baixo presentes no Norte de Minas Gerais e na parte norte e litorânea do estado de São Paulo e Rio de Janeiro.

Em relação aos *outliers*, apenas o município de Jamborandi (Bahia) apresentou comportamento significativo para alto/baixo no ano de 2009. No período posterior analisado, além do município citado anteriormente, Mata de São João (BA), Paty dos Alferes (RJ), Engenheiro Caldas, Bom Jesus do Galho, em Minas Gerais e Urbano Santos, no Leste Maranhense. Já os municípios que apresentaram comportamento significativo do tipo baixo/alto foram aqueles onde principalmente não houve a produção de lenha e eram vizinhos de grandes produtores.

Ao considerar os municípios que mais produziram madeira para lenha no período de 2009 observa-se que os principais aglomerados do tipo alto/alto correspondem às regiões de maiores produção do país, conforme ilustrado na Figura 14. Assim, os municípios de maior produção de madeira para lenha nesse ano compõem aglomerados significativos do tipo alto/alto. Os municípios de Santa Cruz do Sul, Encruzilhada do Sul, São Jerônimo, Pântano Grande e Paverama, pertencentes ao Estado do Rio Grande do Sul, Itaberá e Itapetininga, no Estado de São Paulo, e Paraopeba em Minas Gerais, estão entre os dez maiores produtores do país para o período. Esses municípios compõem importantes aglomerados na produção de madeira para lenha no país em 2009, correspondendo a 38% do total produzido.

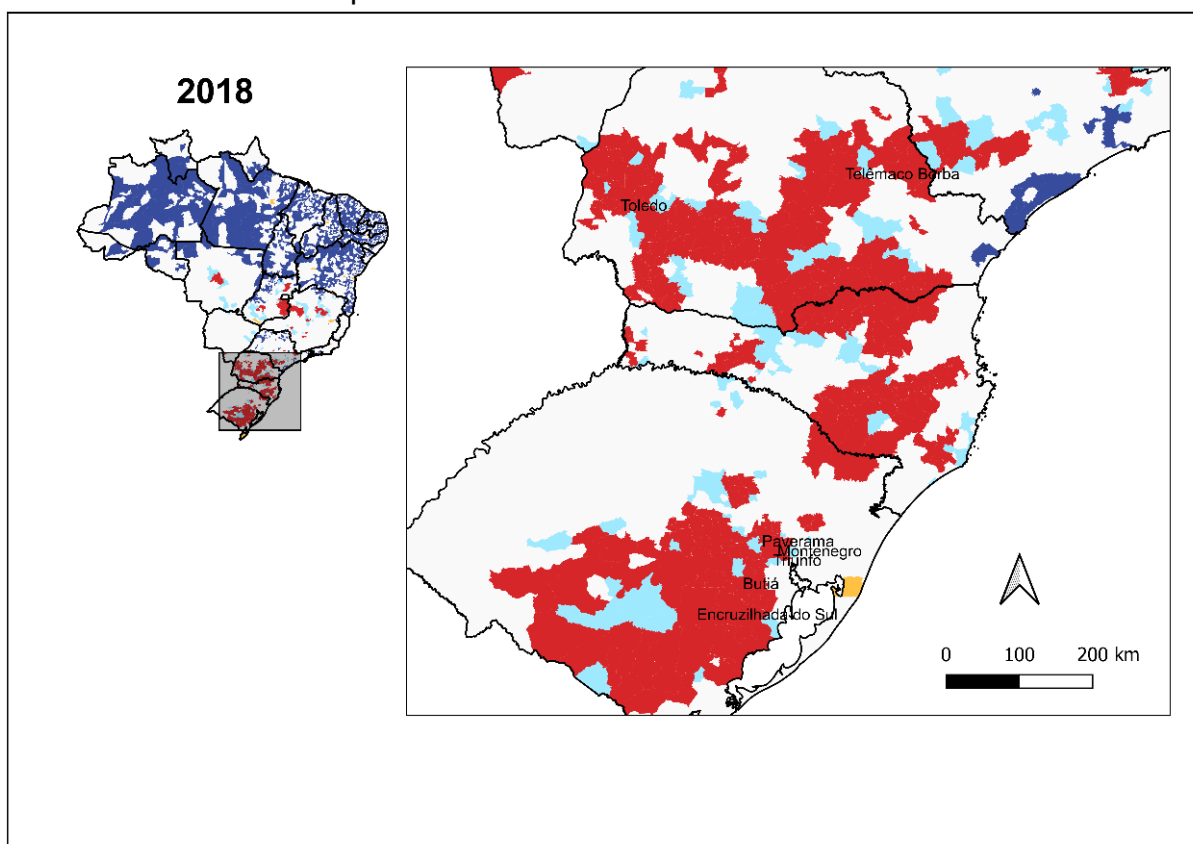
Figura 14 – Mapa LISA ($\alpha = 0,05$) para a variável lenha (m^3) com destaque para as regiões de maior importância no valor da produção nacional em relação aos clusters do tipo alto/alto em 2009.



Fonte: Autor.

Em 2018, os municípios que mais produziram madeira pra fins de lenha da silvicultura se concentraram na porção sul do país. Desse modo, pode-se observar a existência de aglomerações significativas do tipo alto/alto relativamente próximas (FIGURA 15).

Figura 15 – Mapa LISA ($\alpha=0,05$) para a variável lenha (m^3) com destaque para a região de maior importância no valor da produção nacional em relação aos clusters do tipo alto/alto em 2018.



Fonte: Autor.

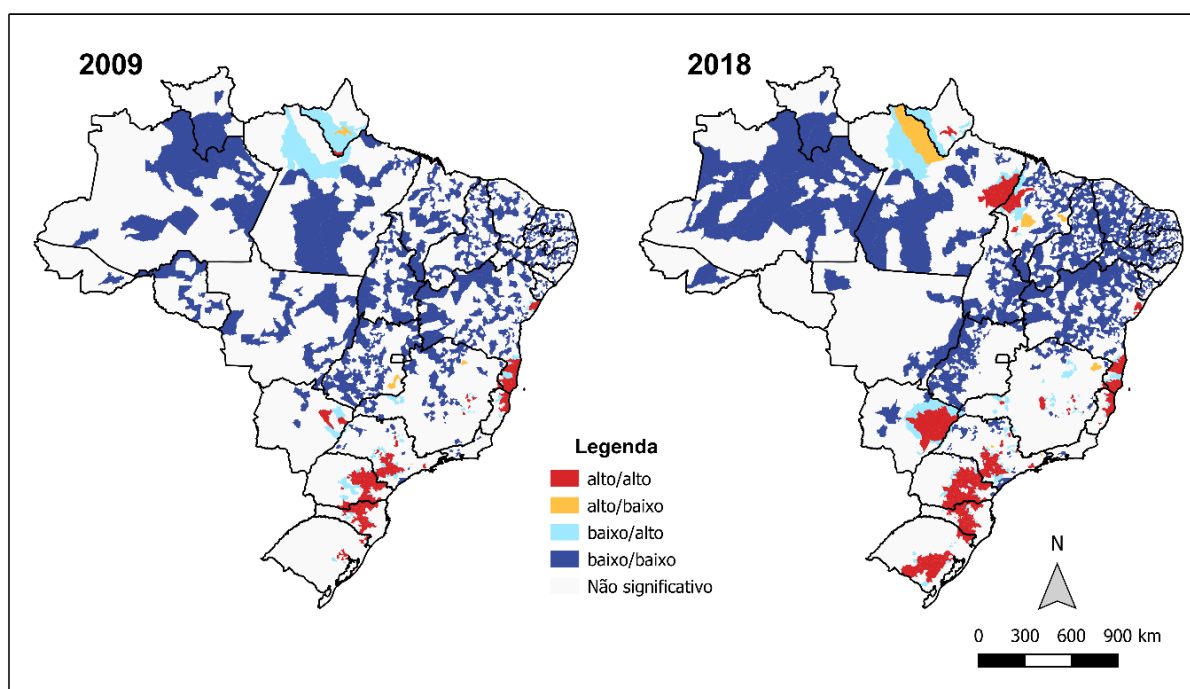
Assim, de acordo com a Figura 15, os municípios de Butiá, Montenegro, Paverama, Encruzilhada do Sul e Triunfo, no Rio Grande do Sul, Telêmaco Borba e Toledo no Paraná representam grandes aglomerações do tipo alto/alto, que se estenderam por quase toda região Sul do Brasil em 2018, responsáveis por 43,6% de toda a produção no período. O estado do Rio Grande do Sul se destaca dos demais por apresentar uma certa estabilidade quanto às aglomerações do tipo alto/alto se comparado ao ano de 2009. Disso, é importante ressaltar que, em relação ao período anterior, os municípios significativos para o *cluster* alto/alto de madeira para lenha se deslocaram para as regiões Sul e Centro-Oeste do país.

Esses resultados corroboram com o trabalho de Simioni *et al.* (2017). Ao comparar a produção de lenha da silvicultura ao longo dos anos 2000 a 2011, observaram que os estados do Paraná, Santa Catarina e Rio Grande do Sul constituem em grandes polos produtores tradicionais do país.

4.2.2.2 Madeira em tora (m³)

Quanto à produção de madeira em tora, a Figura 16 apresenta os mapas LISA obtidos para os dois períodos neste estudo.

Figura 16 – Mapa LISA ($\alpha = 0,05$) para a variável tora (m³) nos anos de 2009 e 2018.



Fonte: Autor.

Conforme Figura 16, no ano de 2009, as principais regiões significativas do tipo alto/alto estão localizadas na porção sul dos estados da Bahia e São Paulo, no norte do estado do Espírito Santo, no eixo norte-sul da parte oriental do Estado do Paraná e também na região central de Santa Catarina. Alguns outros municípios significativos para o tipo alto/alto se apresentaram de forma isolada no leste do Estado do Mato Grosso do Sul, no Nordeste Baiano e na região do Rio Doce em Minas Gerais.

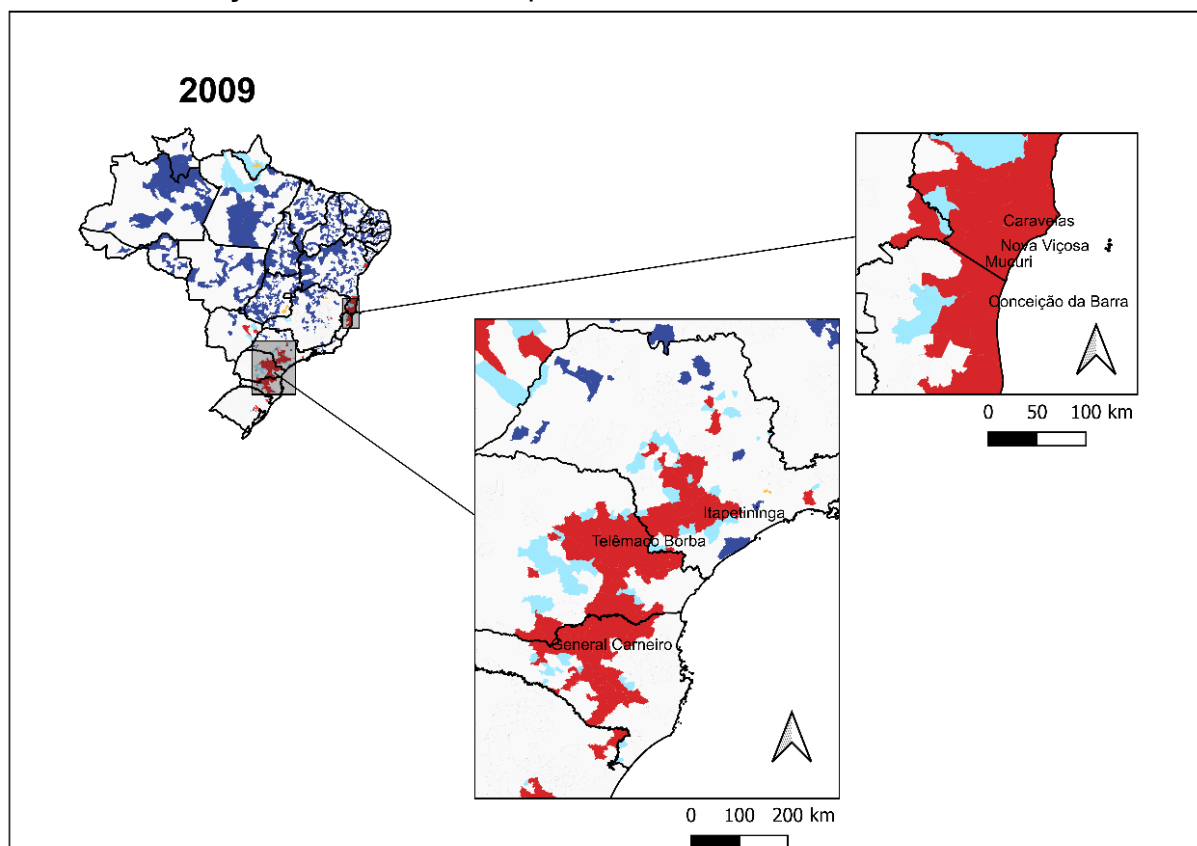
Na década seguinte, o padrão observado quanto à disposição dos municípios do tipo alto/alto se manteve relativamente próximo ao período anterior em relação aos Estados do Espírito Santo, Bahia, São Paulo, Paraná e Santa Catarina, só que agora nota-se também grandes aglomerados pertencentes a região centro-sul do Estado do Rio Grande do Sul, leste do Mato Grosso do Sul, na porção nordeste do estado do Pará e no Oeste Maranhense. Quanto aos municípios do tipo alto/alto isolados em 2018, esses também podem ser observados no Sul do Amapá e Maranhão.

Para os municípios do tipo baixo/baixo, a Figura 16 demonstra que a maioria pertence às regiões Centro Oeste, Norte e Nordeste do Brasil para ambos os períodos analisados. A grande parte desses municípios, além de estarem próximos entre si, não produziram nenhuma quantidade de madeira. Nesse contexto, cabe ressaltar que a estatística local em 2018 foi significativa para o padrão do tipo baixo/baixo, fato que condiz com o histórico de produção de madeira em tora proveniente da silvicultura nessas regiões, onde são locais em que a produção apresentou um baixo valor ou nunca ocorreu, com exceção do estado do Mato Grosso do Sul (grande produtor nacional).

Quanto aos *outliers* espaciais significativos do tipo alto/baixo, em 2009 apenas os municípios de Porto Grande (Sul do Amapá), Ipameri (Sul Goiano), Riacho dos Machados (Norte de Minas) e Caieiras (Região Metropolitana de São Paulo) apresentaram esse comportamento. Em 2018, os municípios de Almeirim (Baixo Amazonas), Grajaú (Centro Maranhense), Parnarama (Leste Maranhense), Jequitinhonha (Região do Jequitinhonha, Minas Gerais), Bocaina (Bauru) e Cachoeira Paulista (Vale do Paraíba Paulista) em São Paulo apresentaram o comportamento significativo para o tipo alto/baixo. Já os *outliers* do tipo baixo/alto, observa-se que os municípios significativos nos períodos analisados foram majoritariamente vizinhos de grandes aglomerados do tipo alto/alto, com exceção de alguns municípios localizados de maneira isolada na parte norte do Estado do Pará, sul do Amapá e Minas Gerais.

Com relação aos aglomerados formados por municípios significativos do tipo alto/alto, em 2009 pode-se observar duas macrorregiões principais (FIGURA 17). A primeira é composta por 117 municípios produtores e se estende através de um eixo contínuo, que compreende parte sudeste do Estado São Paulo, atravessa o Paraná e termina no sul de Santa Catarina, sendo representado basicamente pelos municípios de Telêmaco Borba (Centro Oriental Paranaense), General Carneiro (Sudeste Paranaense) e Itapetininga (Região de Itapetininga, São Paulo), com produção equivalente a 41,4% do total para o período. A segunda macrorregião, é composta por 24 municípios localizados entre o norte do Estado do Espírito Santo até o Sul Baiano, e corresponde a 19,2% do total da produção de madeira em tora para o ano de 2009, sendo representados pelos municípios de Conceição da Barra (ES), Mucuri, Nova Viçosa e Caravelas (BA).

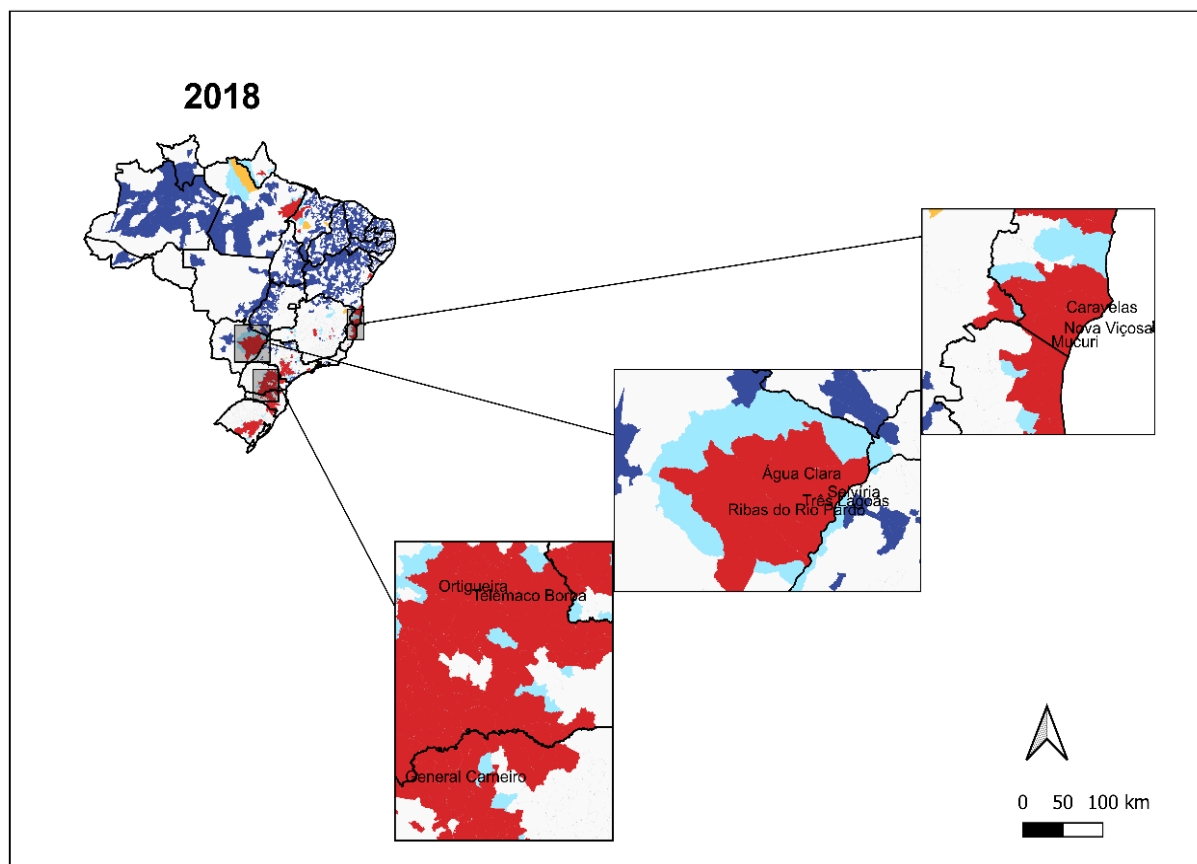
Figura 17 – Mapa LISA ($\alpha=0,05$) para a variável madeira em tora (m^3) com destaque para a região de maior importância no valor da produção nacional em relação aos clusters do tipo alto/alto em 2009.



Fonte: Autor.

Os aglomerados do tipo alto/alto para o ano de 2018 se apresentaram de forma mais abrangente em relação ao observado anteriormente (FIGURA 19). Assim, em 2018 constata-se a ocorrência de cinco macrorregiões com aglomerações entre municípios significativos do tipo alto/alto, localizados entres os Estados de São Paulo, Paraná e Santa Catarina; Rio Grande do Sul; Mato Grosso do Sul; Bahia e Espírito Santo; Pará e Maranhão. Embora essas macrorregiões sejam de grande importância, quando se leva em consideração a quantidade de madeira produzida, observa-se que apenas três desses aglomerados são fundamentais para a produção de madeira em tora no país, conforme a Figura 18.

Figura 18 – Mapa LISA ($\alpha=0,05$) para a variável madeira em tora (m^3) com destaque para a região de maior importância no valor da produção nacional em relação aos clusters do tipo alto/alto em 2018.



Fonte: Autor.

Portanto, de acordo com a Figura 18, em 2018 o aglomerado do tipo alto/alto que pertence ao eixo São Paulo, Paraná e Santa Catarina ainda se caracteriza por importante produtor de madeira em tora. Porém, o município de Itapetininga (SP) não mais representa a região como em 2009, sendo ultrapassado pelo município de Ortigueira (Centro Oriental Paranaense). Isso faz com que o estado do Paraná seja centro produtivo dessa região, que conta com 146 municípios e corresponde a aproximadamente 38% do total produzido para o período. A segunda macrorregião de maior importância dentre os aglomerados do tipo alto/alto nesse ano pertence aos municípios da região do Leste do Mato Grosso do Sul, representado por Três Lagoas, Selvíria, Água Clara e Ribas do Rio Claro. Esse aglomerado possui apenas dez municípios, no entanto corresponde a 12,1% de toda a produção em 2018. O terceiro aglomerado, é formado por municípios do tipo alto/alto localizados entre o norte do Espírito Santo e o sul da Bahia. Essa região também é um importante produtor nacional, visto que em 2009 os indicadores locais LISA confirmaram a existência de

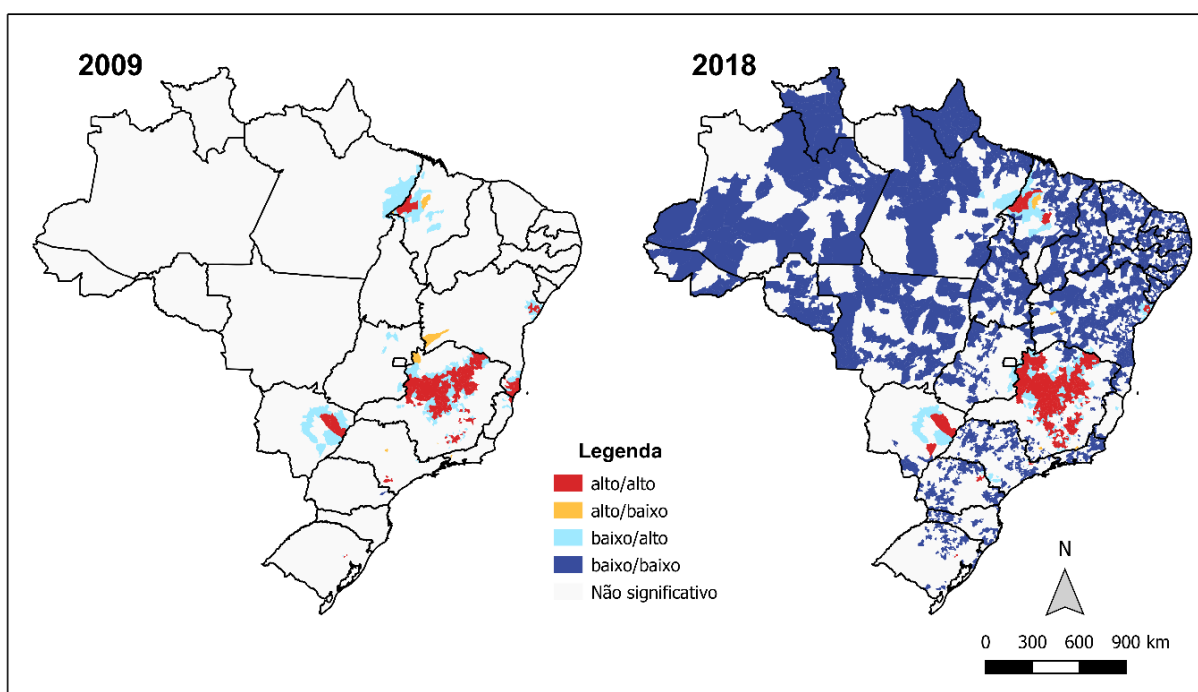
aglomeração do tipo alto/alto entre os municípios próximos, contando com 24 cidades produtoras e produção de 10,2% do total em 2018. Os principais produtores e representantes da região são os municípios de Mucuri, Nova Viçosa e Caravela, todos pertencentes ao Sul Baiano.

Diante disso, os resultados obtidos confirmam que a produção de madeira em tora proveniente da silvicultura se concentra nos grandes polos produtores, onde as maiores indústrias do setor atuam. Principalmente as grandes empresas de celulose e papel como a Klabin na região do município de Telêmaco Borba (PR), Suzano Papel e Celulose, na microrregião de Três Lagoas (MS) e Veracel Celulose, situada no Sul Baiano (HORA, 2017).

4.2.2.3 Carvão vegetal (t)

Por fim, a Figura 19 mostra o mapa LISA para os anos de 2009 e 2018 da produção de madeira para carvão registrada por município.

Figura 19 – Mapa LISA ($\alpha=0,05$) para a variável produção de carvão vegetal (t) nos anos de 2009 e 2018.



Fonte: Autor.

De acordo com a Figura 19, em 2009, as regiões dos Estados de Minas Gerais, Bahia, São Paulo, Maranhão, Espírito Santo, Rio Grande do Sul e Mato Grosso do Sul

apresentaram municípios e ou aglomerações do tipo alto/alto. O Estado de Minas Gerais se destacou por apresentar o maior número dos municípios significativos alto/alto no período, formando um grande aglomerado na parte central, noroeste e norte do estado. O sul da Bahia e norte do Espírito Santo também apresentaram um aglomerado de municípios do tipo alto/alto. Alguns outros municípios importantes para a produção nacional apresentaram *clusters* alto/alto de maneira isolada, como no caso de Três Lagoas, Leste do Mato Grosso do Sul, e Açailândia, no Oeste Maranhense.

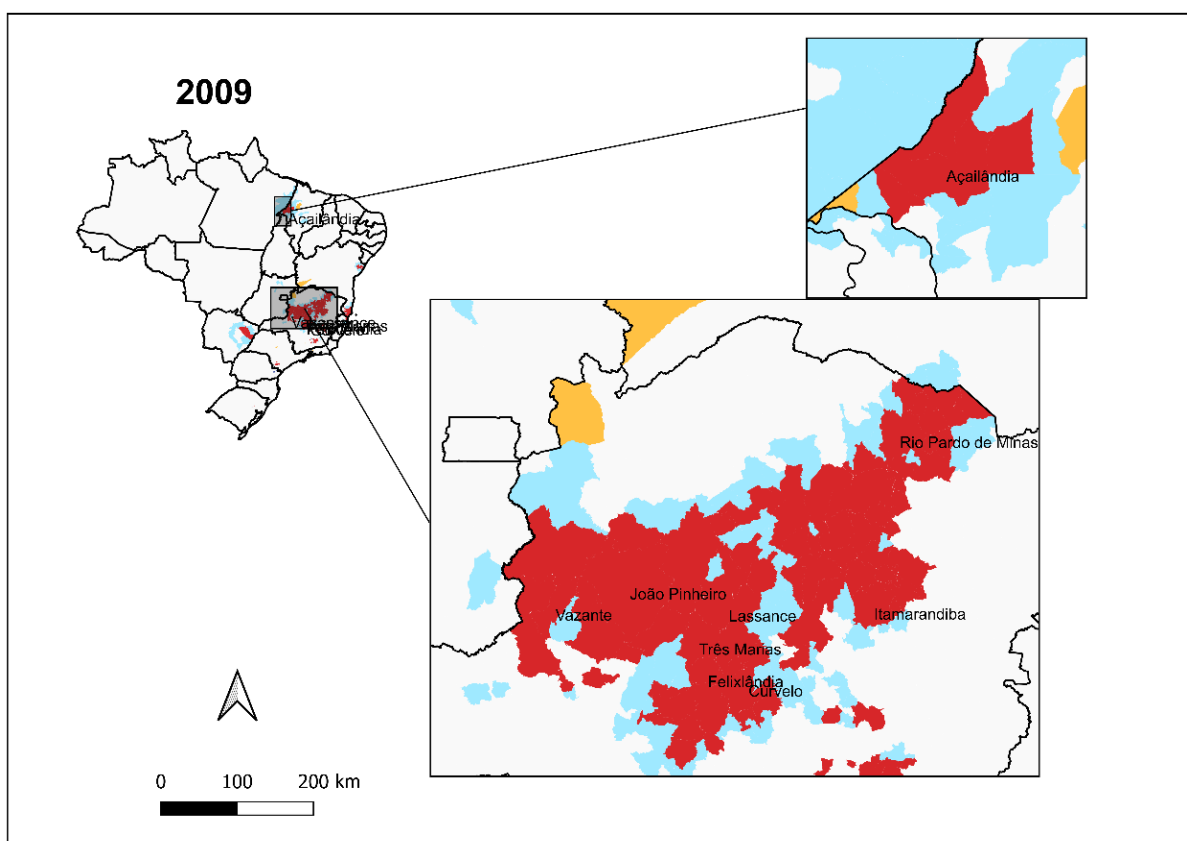
Em 2018, Minas Gerais continuou com o maior número de municípios significativos alto/alto, expandindo para a porção sul e leste do estado. Em relação aos estados produtores, quando comparado com o período anterior, não houve grandes alterações, com exceção o estado do Espírito Santo, onde não foram registrados municípios significativos. Quanto a composição dos municípios alto/alto, nota-se algumas diferenças importantes em relação ao ano de 2009, principalmente nos estados da Bahia, Maranhão e São Paulo. Nos estados da Bahia e São Paulo observa-se um número menor de municípios significativos quando comparando ao período anterior analisado. No caso do Estado do Maranhão, constata-se um número maior de municípios do tipo alto/alto na parte oeste do estado quando comparado ao período anterior (FIGURA 19).

Para o *cluster* espacial do tipo baixo/baixo, apenas os municípios de Bocaiúva do Sul, pertencente à Região Metropolitana de Curitiba, e Lupionópolis, no Norte Central Paranaense, apresentaram significância no ano de 2009. No período posterior analisado, o índice local foi significativo para a grande maioria dos municípios pertencentes às regiões Norte e Nordeste do Brasil, como também muitos outros municípios pertencentes aos estados de Mato Grosso, Goiás, São Paulo, Rio de Janeiro, Paraná, Santa Catarina e Rio Grande do Sul.

Quanto aos *outliers* espaciais da produção de madeira para carvão apresentados na Figura 19, a grande parte dos municípios que apresentaram agrupamento do tipo baixo/alto foram justamente aqueles próximos aos municípios ou aglomerados do tipo alto/alto e não produziram valor algum para ambos os períodos analisados. Quanto aos *outliers* do tipo alto/baixo observa-se apenas os municípios de Bariri (Bauru, SP), São Bento do Abade (Sul de Minas, MG), Buritis (Noroeste de Minas, MG), Jaborandi (Extremo Oeste Baiano, BA), Volta Redonda (Sul Fluminense, RJ), Santa Luzia e São Pedro da Água Branca (Oeste Maranhense, MA) para o ano de 2009 e nenhum em 2018.

Em relação aos aglomerados do tipo alto/alto para o ano de 2009, observa-se duas regiões distintas: a primeira, é uma grande região formada por municípios da parte central, noroeste e norte do estado de Minas Gerais, a seguinte, em proporção menor, compreende alguns municípios do Oeste Maranhense (FIGURA 20).

Figura 20 – Mapa LISA ($\alpha=0,05$) para a variável carvão vegetal (t) com destaque para a região de maior importância no valor da produção nacional em relação aos clusters do tipo alto/alto em 2009.



Fonte: Autor.

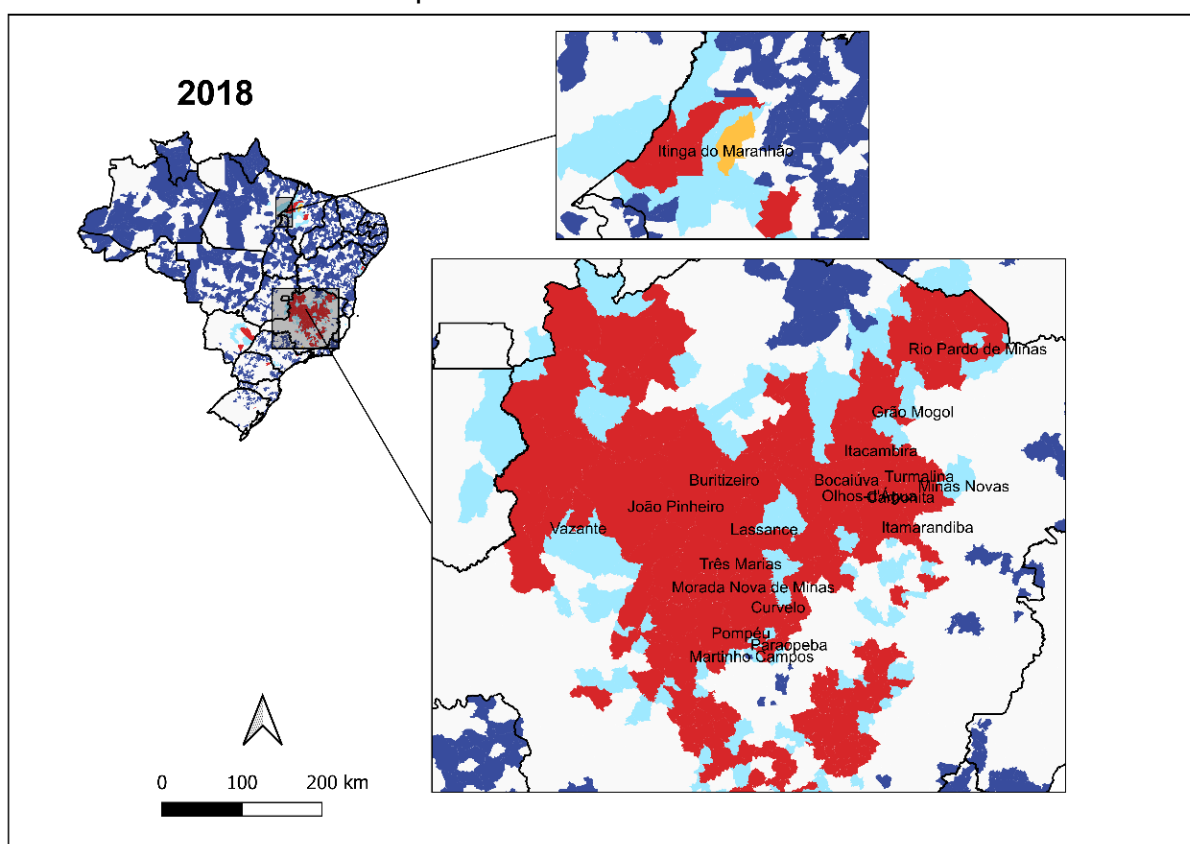
Desse modo, conforme a Figura 20 ilustra, o aglomerado do tipo alto/alto pertencente ao estado mineiro possui 85 municípios e conta com cerca de 78% de toda a produção nacional de madeira para carvão proveniente da silvicultura em 2009. Os municípios de Lassance e Rio Pardo de Minas no Norte de Minas; Curvelo, Três Marias e Felixlândia, localizados na Região Central Mineira; João Pinheiro, no Noroeste de Minas, e Itamarandiba, na Região do Jequitinhonha, representam esse grande aglomerado de municípios significativos do tipo alto/alto.

A outra região representada na Figura 20 é composta pelos municípios de Açailândia, Bom Jesus das Selvas, Cidelândia e Itinga do Maranhão, todos

pertencentes ao Oeste Maranhense, apresentando aproximadamente 3,6% do total produzido para o período.

Em 2018, os aglomerados do tipo alto/alto se mantiveram entre os estados e praticamente entre mesmas regiões quando comparado ao período anterior. No entanto, houve considerável expansão dos municípios desse tipo, sobretudo no Estado de Minas Gerais (FIGURA 21).

Figura 21 – Mapa LISA ($\alpha=0,05$) para a variável carvão vegetal (t) com destaque para a região de maior importância no valor da produção nacional em relação aos clusters do tipo alto/alto em 2018.



Fonte: Autor.

Desse modo, em Minas Gerais observa-se que o aglomerado formado por municípios do tipo alto/alto abrange quase todas as mesorregiões do estado, é composta por 159 municípios e corresponde a 76,6% da produção total em 2018, sendo representado pelos municípios de João Pinheiro e Vazante, no Noroeste Mineiro; Itamarandiba, Carbonita, Turmalina e Minas Novas, na Região do Jequitinhonha; Três Marias, Curvelo, Pompéu e Martinho Campos, na Central Mineira; Lassance, Buritizeiro e Olhos d'Água, Norte de Minas e Paraopeba, na Região Metropolitana de Belo Horizonte. Quanto ao segundo aglomerado, este é

praticamente o mesmo do observado em 2009, porém, há o acréscimo do município de Barra do Corda, pertencente ao Centro Maranhense. Assim, esse aglomerado possui apenas cinco municípios e representa cerca de 4% da produção de madeira para carvão em 2018.

De acordo com Simioni *et al.* (2017), por concentrar grande parte da produção siderúrgica do país, o estado de Minas Gerais possui plantios próprios que atendem à demanda regional, na tentativa de reduzir os custos envolvidos na siderurgia do aço. Desse modo, o presente trabalho corrobora com a conclusão anterior.

5 CONCLUSÃO

O presente trabalho pretendeu verificar o comportamento das produções de lenha (m^3), tora (m^3) e carvão vegetal (t) proveniente de plantio florestais no território brasileiro para os anos de 2009 e 2018, através da análise exploratória de dados espaciais (AEDA) na identificação de autocorrelação espacial e dos *clusters* ou *outliers* espaciais.

Nesse sentido, o estudo conseguiu identificar, por meio do índice global *I* de Moran, a existência de autocorrelação espacial em relação a todas variáveis e períodos analisados. Mais especificamente, autocorrelação espacial positiva, onde constatou-se a que predominância de regiões do tipo alto/alto e baixo/baixo. O que no caso da produção proveniente da silvicultura esse resultado geral se reflete no fato de que muitas das regiões que apresentaram elevada produção para ambos os períodos analisados são locais historicamente estabelecidos, com exceção da região do leste do Mato Grosso do Sul no ano de 2018, impulsionado pela indústria da celulose e papel.

Outro resultado importante quanto à produção de madeira da silvicultura diz respeito à região Sul do Brasil. O presente trabalho verificou que as regiões pertencentes principalmente à parte centro-leste dos estados do Paraná e na porção extremo sul do estado do Rio Grande do Sul são importantes centros na produção de florestas plantadas do país, principalmente em relação à produção de lenha (m^3) e madeira em tora (m^3). Em relação à produção de carvão vegetal (t) da silvicultura, os municípios pertencentes às porções nordeste, norte e centro de Minas Gerais apresentaram um grande aglomerado do tipo alto/alto para os dois períodos analisados, justamente em regiões onde a indústria siderúrgica é forte.

Portanto, através do uso da análise exploratória de dados espaciais, verificou-se significativa a relação espacial entre as regiões de grande produção de madeira da silvicultura. No entanto, para futuras oportunidades, este trabalho merece avançar na investigação através de análises mais robustas com o uso de técnicas em estatística multivariada ou mesmo o uso de modelos de regressão espacial.

REFERÊNCIAS

- ASSOCIAÇÃO BRASILEIRA DE FLORESTAS PLANTADAS– (ABRAF). **Anuário Estatístico da ABRAF 2011– Ano base 2010**. Brasília, 2011. Disponível em: <https://www.brazilianjournals.com/index.php/BJAER/article/view/329>. Acesso em: 15 maio. 2020.
- ALMEIDA, E. **Econometria Espacial Aplicada**. 1. ed. São Paulo: Editora Alvíia, 2012. v. 1.
- ANSELIN, L. Local indicators of spatial association–lisa. **Geographical analysis**, Princeton, v. 27, n. 2, p. 93–115, 1995. Disponível em: https://dces.webhosting.cals.wisc.edu/wp-content/uploads/sites/128/2013/08/W4_Anselin1995.pdf. Acesso em: 02 fev. 2020.
- ANSELIN, L. Spatial externalities, spatial multipliers, and spatial econometrics. **International Regional Science Review**, Califórnia, v. 26, n. 2, p. 153 – 166, 2003. Disponível em: http://web.pdx.edu/~crkl/SEAUG/papers/Anselin_IRSR_2003.pdf. Acesso em: 14 mai. 2020.
- ANTONÂNGELO, A.; BACHA, C. J. C. As fases da silvicultura no Brasil. **Revista brasileira de economia**, Rio de Janeiro - RJ, v. 52, n. 1, p. 207-238, 1998. Disponível em: <http://bibliotecadigital.fgv.br/ojs/index.php/rbe/article/view/721/8086> . Acesso em: 14 jan. 2020.
- ARAGÓN, L. E. A dimensão internacional da amazônia: um aporte para sua interpretação. **Revista Nera**, Presidente Prudente, ano. 21, n. 42, p. 14-33, 2018. Disponível em: <http://revista.fct.unesp.br/index.php/nera/article/view/5676/4254>. Acesso em: 29 nov. 2019.
- ARAUJO, V. A. de; GARCIA, J. N.; CORTEZ-BARBOSA, J.; GAVA, M.; SAVI, A. F.; MORALES, E. A. M.; LAHR, F. A. R.; VASCONCELOS, J. S.; CHRISTOFORO, A. L. Importância da madeira de florestas plantadas para a indústria de manufaturados. **Pesquisa Florestal Brasileira**, Colombo - PR, v. 37, n. 90, p. 189-200, 2017. Disponível em: <https://pfb.cnpf.embrapa.br/pfb/index.php/pfb/article/view/824/573>. Acesso em: 05 dez. 2019.
- ASSUNÇÃO, R. M.; REIS, E. A. A new proposal to adjust moran's i for population density. **Statistics in Medicine**, Hanover, v. 18, p. 2147–2162, 1999. Disponível em: http://www.dpi.inpe.br/cursos/ser301/referencias/AssuncaoReis_Revisao_I_Moran_de_Texas_1999.pdf. Acesso em: 13 dez. 2019.
- BAILEY, T. C.; GATRELL, A. C. **Interactive Spatial Data Analysis**. 1. ed. New York: Routledge, 1995.
- BERGER, R.; JUNIOR, J. B. P. **Importância econômica e social do setor florestal**. Curitiba: 2009.

BRASIL, **Florestas do Brasil em Resumo: 2019**. Brasília, 2019. Disponível em: <http://www.florestal.gov.br/publicacoes/1737-florestas-do-brasil-em-resumo-2019>. Acesso em: 18 dez. 2019.

CÂMARA, G. *et al.* **Análise Espacial de Dados Geográficos**. Brasília: EMBRAPA, 2004.

CUNHA G., LOPES I., OLIVEIRA R., PÁSCOA K., GOMIDE L. Panorama do Setor Florestal Brasileiro com Ênfase no Estado de Minas Gerais. **Enciclopédia Biosfera**. Jandaia - GO, v.16, n. 29; p.1582, 2019. Disponível em : <http://www.conhecer.org.br/enciclop/2019a/agrar/panorama%20do.pdf>. Acesso em: 19 dez. 2019.

CLEMENTE, A. M. **Utilização da estatística espacial para analisar a dinâmica do feijão e da soja no Brasil, entre os anos de 1990 a 2013**. 52p. Dissertação (Mestrado em Geografia)—Universidade de Brasília, Brasília, 2015.

CRESSIE, N. A. C. **Statistics for Spatial Data**. Revised edition. Iowa State University: A Wiley-Interscience Publication, 1993.

DIGGLE, P. J. **Statistical Analysis of Spatial and Spatio-Temporal Point Patterns**. Third. Lancaster University England, UK: A CHAPMAN & HALL BOOK, 2013.

Food and Agriculture Organization of the United Nation (FAO) - **Global Forest Resources Assessments**, 2015. Disponível em: <http://www.fao.org/3/a-i4793e.pdf>. Acesso em: 24 nov. 2019.

HORA, A. B. da. Análise da formação da base florestal plantada para fins industriais no Brasil sob uma perspectiva histórica. **BNDES Setorial**, Rio de Janeiro – RJ, v. 42, p. 383-426, 2015. Disponível em: https://web.bndes.gov.br/bib/jspui/bitstream/1408/9615/2/BNDES%20Setorial%2042%20An%C3%A1lise%20da%20forma%C3%A7%C3%A3o%20da%20base%20florestal%20plantada%20para%20fins%20industriais%20%5B...%5D_P_BD.pdf. Acesso em: 25 de jan. 2020.

HORA, A. B. da. **Panoramas setoriais 2030: papel e celulose**. Rio de Janeiro: Banco Nacional de Desenvolvimento Econômico e Social, 2017.

FELEMA, J.; MEDEIROS, E. R.; FERREIRA, CARLOS ROBERTO; CAMARA, MARCIA REGINA GABARDO DA; NASCIMENTO, SIDNEI PEREIRA. Um estudo da produtividade do feijão, do milho e da soja na agricultura paranaense, nos anos de 2000 a 2010: uma análise espacial. **ENSAIOS FEE (IMPRESSO)**, Porto Alegre – RS, v. 36, p. 817-842, 2016. Disponível em: <https://revistas.fee.tche.br/index.php/ensaios/article/view/3061>. Acesso em: 15 jun. 2020.

FISCHER, M. M.; WANG, J. **Spatial data analysis: models, methods and techniques**. London: Springer Science & Business Media, 2011.

GEARY, R. C. The contiguity ratio and statistical mapping. **The incorporated statistician**, New York, v. 5, n. 3, p. 115–146, 1954. Disponível em: <<https://www.jstor.org/stable/2986645>>. Acesso em: 26 jan. 2020.

GETIS, A. A History of the Concept of Spatial Autocorrelation: A Geographer's Perspective. **Geographical Analysis**, Princeton, v. 40 p. 297–309, 2008. Disponível em: <https://onlinelibrary.wiley.com/doi/10.1111/j.1538-4632.2008.00727.x> Acesso em: 13 fev. 2020.

GETIS, A.; ORD, J. K. Local spatial autocorrelation statistics: Distributional issues and an application. **Geographical Analysis**, Princeton, v. 27, p. 286–306, 1995. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1111/j.1538-4632.1995.tb00912.x>. Acesso em: 18 dez. 2019.

HAINING, R. **Spatial Data Analysis: Theory and Practice**. New York: Cambridge University Press, 2003.

IBÁ – INDÚSTRIA BRASILEIRA DE ÁRVORES – **Relatório IBÁ 2014**. Brasília: IBÁ, 2014. Disponível em: http://iba.org/images/shared/iba_2014_pt.pdf. Acesso em: 10 jan. 2020.

IBÁ – INDÚSTRIA BRASILEIRA DE ÁRVORES – **Sumário executivo IBÁ 2018**. Brasília: IBÁ, 2018. Disponível em: <https://iba.org/datafiles/publicacoes/relatorios/digital-sumarioexecutivo-2018.pdf>. Acesso em: 20 jan. 2020.

IBÁ – INDÚSTRIA BRASILEIRA DE ÁRVORES – **Relatório IBÁ 2019**. Brasília: IBÁ, 2016. Disponível em: <https://iba.org/datafiles/publicacoes/relatorios/iba-relatorioanual2019.pdf>. Acesso em: 10 jan. 2020.

IBGE. **Produção da Extração Vegetal e da Silvicultura (PEVS - 2009)**. Brasil, 2010. Disponível em: <https://sidra.ibge.gov.br/pesquisa/pevs/quadros/brasil/2009>. Acesso em: mai. de 2020.

IBGE. **Produção da Extração Vegetal e da Silvicultura (PEVS - 2018)**. Brasil, 2019. Disponível em: <https://sidra.ibge.gov.br/pesquisa/pevs/quadros/brasil/2018>. Acesso em: abr. de 2019.

KREMPI, A. P. **Explorando Recursos de Estatística Espacial para Análise da Acessibilidade na Cidade de Bauru**. 82p. Dissertação (Mestrado em engenharia civil - Área: Transportes) – Universidade de São Paulo - USP, São Paulo, 2004.

LADEIRA, H. P. **Quatro décadas de engenharia florestal no Brasil**. Viçosa: Sociedade de Investigações Florestais, 2002. 207 p.

MORAN, P. A. P. The interpretation of statistical maps. **Journal of the Royal Statistical Society**. San Diego, Series B (Methodological), v. 10, n. 2, p. 243–251, 1948. Disponível em: <https://www.jstor.org/stable/pdf/2983777.pdf?seq=1>. Acesso em: 21 nov. 2019.

MOREIRA, J. M. M. Á. P.; SIMIONI, F. J.; OLIVEIRA, E. B. de. Importância e desempenho das florestas plantadas no contexto do agronegócio brasileiro. **Floresta**, Curitiba – PR, v. 47, n. 1, p. 85-94, 2017. Disponível em: <https://revistas.ufpr.br/floresta/article/view/47687/31915>. Acesso em: 17 out. 2019.

ODEN, N. Adjusting moran's i for population density. **Statistics in Medicine**, Hanover, v. 14, p. 17–26, 1995. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1002/sim.4780140104>. Acesso em: 15 out. 2019.

PEROBELLI, F. S. et al. A análise espacial da produtividade do setor agrícola brasileiro: 1991-2003. **Nova Economia**, Belo Horizonte – MG, v. 17, n. 1, p. 65-91, 2007. Disponível em: https://www.google.com/url?sa=t&rct=j&q=&esrc=s&source=web&cd=&ved=2ahUKEwjnINf6i7TrAhUGneAKHaO9AulQFjADegQIAhAB&url=https%3A%2F%2Fperiodicos.utfpr.edu.br%2Frbpd%2Farticle%2Fdownload%2F7988%2F6258&usq=AOvVaw3hvf p3q_cbrJDqbA-0AYAW. Acesso em: 15 mai. 2020

PYTHON SOFTWARE FOUNDATION. **The Python Language reference: version 3.8**. 2019. Disponível em: docs.python.org. Acesso em: 07 jan. 2020.

SANTOS, R. Q.; SOARES, N. S.; SOUSA, E. P. de. Determinantes da Oferta de Exportação de Papel no Brasil. **Revista de Estudos Sociais**, Cuiabá – MT, v. 18, n. 36, p. 88-106, 2016. Disponível em: <http://periodicoscientificos.ufmt.br/ojs/index.php/res/article/view/3292>. Acesso em: 11 dez. 2019.

SERRANO, R. M.; VALCARCE, E. V. **Técnicas econométricas para el tratamiento de dados espaciales: la econométrica espacial**. Edicions Universita de Barcelona, 2000.

SIMIONI, F. J.; SPANIOL, J. S.; MOREIRA, J. M. M. A. P.; FACHINELLO, A. L.; BUSCHINELLI, C. C. de A.; MATSUURA, M. I. da S. F. Evolução e concentração da produção de lenha e carvão vegetal da silvicultura no Brasil. **Ciência Florestal**, Santa Maria – RS, v. 27, n. 2, p. 731-742, 2017. Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1980-50982017000200731&lng=en&nrm=iso. Acesso em: 20 Mar. 2020.

UHLIG, A.; GOLDEMBERG, J.; COELHO, S. T. O uso de carvão vegetal na indústria siderúrgica brasileira e o impacto sobre as mudanças climáticas. **Revista brasileira de energia**, Itajubá – MG, v. 14, n. 2, p. 67-85, 2008. Disponível em: http://ambienteregionalagulhasnegras.acendebrasil.com.br/media/academicas/v14n02_o-uso-de-carvao-vegetal-na-industria-siderurgica-brasileira-e-o-impacto-sobre-as-mudancas-climaticas_1.pdf. Acesso em: 27 out. 2019.

VALVERDE, S. R. **As plantações de eucalipto no Brasil**. Sociedade Brasileira de Silvicultura, São Paulo, 2001. Disponível em: http://www.sbs.org.br/destaques_plantacoes_nobrasil.html. Acesso em: 5 out. 2019.

WALLER, L. A.; GOTWAY, C. A. **Applied Spatial Statistics for Public Health Data.**
New Jersey: John Wiley & Sons, 2004.

APÊNDICE A – Roteiro de programação em Python

Nesta seção serão disponibilizados os roteiros de programação em Python (versão ≥ 3.8) utilizado neste trabalho.

```
## Importação das bibliotecas necessárias
import pandas as pd
import numpy as np
import geopandas as gp
import seaborn as sns
import pysal as ps
from libpysal.weights import Queen
import libpysal as lps
from esda.moran import Moran, Moran_Local
from spplot.esda import plot_moran, moran_scatterplot,
lisa_cluster, plot_local_autocorrelation
import mapclassify
sns.set(style='whitegrid')

## Entrada dos dados
link = 'C:\~\dissertacao\dados\'
madeira_all = pd.read_csv(link+'madeira-2018.csv') # base de
dados
brsh = gp.read_file(link+'br.json') # Arquivo de imagem vetorial

## Preparar os dados para a análise
brsh = brsh.rename(columns={'CD_GEOCMU': 'mun'}) # renomear a
coluna do arquivo vetorial para padronizar com os dados
brsh.mun = brsh.mun.astype(int) # condicionar o código por
município como número inteiro
brsh = brsh.drop('NM_MUNICIP', axis=1) # retira coluna
```

```
NM_MUNICIP
```

```
brsh = brsh.drop([1525,3499]) # retira F. Noronha e Ilha bela
br = gp.GeoDataFrame(madeira_all.query('ano ==
2018').merge(brsh, how='right')) # seleção do período a ser
analisado em todas variáveis do estudo
br = br.fillna({'carvao':0, 'lenha':0, 'tora':0}) # preencher
os dados vazios com zeros
```

```
## Mapa temático de intervalos iguais
```

```
# variável produção de lenha
```

```
br.plot(column='lenha', figsize=(20, 20), cmap='BuGn',
legend=False,
classification_kwds=dict(bins=[1,250000,500000,750000,1000000,
1250000]), linewidth=0.1,scheme="User_Defined",
edgecolor='k').axis('off');
```

```
# variável produção de tora
```

```
br.plot(column='tora', figsize=(20, 20), cmap='YlOrRd',
scheme="User_Defined", legend=False,
classification_kwds=dict(bins=[1,1100000,2200000,3300000,440000
00,5500000]),linewidth=0.10, edgecolor='k').axis('off');
```

```
# variável produção de carvão
```

```
br.plot(column='carvao', figsize=(20, 20), cmap='YlGnBu',
scheme="User_Defined", legend=False,
classification_kwds=dict(bins=[1,100000,200000,300000,400000,5
00000]),linewidth=0.10, edgecolor='k');
```

```
## Análise exploratória espacial
```

```
# matriz de proximidade espacial, com medida de contiguidade
do tipo Queen
```

```

w = Queen.from_dataframe(br)
w.transform = 'r'

# I de Moran global - todas variáveis (p=0.05; 1000
simulações)

pd.DataFrame({'Variável' : ['Carvão', 'Lenha', 'Tora'],
'I.Moran': [Moran(br['carvao'].values, w).I,
Moran(br['lenha'].values, w).I,
Moran(br['tora'].values, w).I], 'p.value':
[Moran(br['carvao'].values, w).p_sim,
Moran(br['lenha'].values, w).p_sim, Moran(br['tora'].values,
w).p_sim]})

## Diagrama de dispersão de Moran

plot_moran(Moran(br['carvao'].values, w), figsize=(10,4),); #
Carvão
plot_moran(Moran(br['lenha'].values, w), figsize=(10,4)); #
Lenha
plot_moran(Moran(br['tora'].values, w), figsize=(10,4)); #
Tora

## Mapa Lisa (p=0.05; 1000 simulações)
#lenha
lisa_cluster(Moran_Local(br['lenha'].values, w), br, p=0.05,
figsize = (20,20));
#tora
lisa_cluster(Moran_Local(br['lenha'].values, w), br, p=0.05,
figsize = (20,20));

```

```
#carvão  
lisa_cluster(Moran_Local(br['carvao'].values, w), br, p=0.05,  
figsize = (20,20));
```